

Stanislav
Katina

Miroslav
Králík

Adela
Hupková

Aplikovaná štatistická inferencia I

```
zW<- (p1.hat-p2.hat) / sqrt (sg.sq)
p.hodn<-1-pnorm (abs (zW) )
IS<-p1.hat-p2.hat+c (-1,1) *qnorm (0.975)
(sg.sq)
Ztest<-c (IS, zW, p.hodn)
#alternativnyZ-testaIS
p.hat<- (N1*p1.hat+N2*p2.hat) / (N1+N2)
sg.sq.alt<-p.hat* (1-p.hat) * (1/N1+1/N2)
zW.alt<- (p1.hat-p2.hat) / sqrt (sg.sq.alt)
p.hodn.alt<-1-pnorm (abs (zW.alt) )
ISalt<-p1.hat-p2.hat+c (-1,1) *qnorm (0.975) *sqrt (sg.sq.alt)
Ztest.alt<-c (ISalt, zW.alt, p.hodn.alt)
#vysledky
Z.test<-rbind (Ztest, Ztest.alt)
dimnames (Z.test) [[2]]<-c („DH“, „HH“, „stat“, „p-hodnota“)
dimnames (Z.test) [[1]]<-c („Ztest (p1-hat, p2-hat)“, „Ztest (p1-hat, p2-hat)“)
#odhady
odhady<-c (p.hat, p1.hat, p2.hat, exp (p.hat), sqrt (sg.sq), sqrt (sg.sq.alt))
names (odhady) <-c („p“, „p1“, „p2“, „exp (p)“, „sd“, „sd.alt“)
VYSL<-list (odhady=round (odhady, 4), Ztest=round (Z.test, 4))
return (VYSL)

test.relat.rizika<-function (n1, n2, Y1, Y2, N1, N2) {
  p1.hat<-n1/N1
  p2.hat<-n2/N2
  p.hat<- (N1*p1.hat+N2*p2.hat) / (N1+N2)
  lnRR.hat<-log (RR.hat)
  #lnRRklasickyZ-testaIS
  sg.sq.lnRR<- (1-p1.hat) / (N1*p1.hat) + (1-p2.hat) / (N2*p2.hat)
  zW.lnRR<-lnRR.hat / sqrt (sg.sq.lnRR)
  p.hodn.lnRR<-1-pnorm (abs (zW.lnRR) )
  IS.lnRR<-exp (lnRR.hat+c (-1,1) *qnorm (0.975) *sqrt (sg.sq.lnRR) )
  Ztest.lnRR<-c (IS.lnRR, zW.lnRR, p.hodn.lnRR)
  #lnRRalternativnyZ-testaIS
  sg.sq.alt.lnRR<- (1-p.hat) / p.hat * (1/N1+1/N2)
  zW.alt.lnRR<-lnRR.hat / sqrt (sg.sq.alt.lnRR)
  p.hodn.alt.lnRR<-1-pnorm (abs (zW.alt.lnRR) )
  ISalt.lnRR<-exp (lnRR.hat+c (-1,1) *qnorm (0.975) *sqrt (sg.sq.alt.lnRR) )
  Ztest.alt.lnRR<-c (ISalt.lnRR, zW.alt.lnRR, p.hodn.alt.lnRR)
  #RRalternativnyZ-testaIS
  sg.sq.alt.FR<-RR.hat^2*sg.sq.alt.lnRR
  zW.alt.FR<- (RR.hat-1) / sqrt (sg.sq.alt.FR)
  p.hodn.alt.FR<-1-pnorm (abs (zW.alt.FR) )
  ISalt.FR<-FR.hat+c (-1,1) *qnorm (0.975) *sqrt (sg.sq.alt.FR)
  Ztest.alt.FR<-c (ISalt.FR, zW.alt.FR, p.hodn.alt.FR)
  #vysledky
  Z.test<-rbind (Ztest.lnRR, Ztest.alt.lnRR, Ztest.alt.FR, Ztest.alt.FR)
  dimnames (Z.test) [[2]]<-c („DH“, „HH“, „stat“, „p-hodnota“)
  dimnames (Z.test) [[1]]<-c („Ztest (p1-hat, p2-hat)“, „Ztest (p1-hat, p2-hat)“, „Ztest (RR)“, „Ztest (RR)“)
  #odhadyRR
  odhady<-c (p.hat, p1.hat, p2.hat, exp (p.hat), sqrt (sg.sq.lnRR), sqrt (sg.sq.alt.lnRR), sqrt (sg.sq.alt.FR), sqrt (sg.sq.alt.FR))
  names (odhady) <-c („p“, „p1“, „p2“, „exp (p)“, „sd“, „sd.alt (lnRR)“, „sd.alt (FR)“, „sd.alt (FR)“)
```

Aplikovaná štatistická inferencia I

Biologická antropológia očami matematickej štatistiky

Stanislav Katina
Miroslav Králík
Adela Hupková

Masarykova univerzita, 2015

Aplikovaná štatistická inferencia I

Biologická antropológia očami matematickej štatistiky

Všetky práva vyhradené. Táto kniha ani žiadna jej časť nesmie byť reprodukováaná, kopírovaná či akýmkoľvek iným spôsobom rozširovaná bez výslovného súhlasu vydavateľa.

Autori © Stanislav Katina, Miroslav Králík, Adela Hupková

Recenzenti prof. RNDr. Gejza Wimmer, DrSc.; doc. RNDr. Milan Thurzo, CSc.

Jazyková korektúra Mgr. Lenka Moravčíková

Obálka © Adela Hupková

Sadzba, typografická úprava Stanislav Katina

Vydavateľstvo © Masarykova univerzita, 2015, 1. vydanie

ISBN 978-80-210-7752-2 (brožovaná vazba)

ISBN 978-80-210-7841-3 (online : pdf)

Príspevok jednotlivých autorov:

1. doc. PaedDr. RNDr. Stanislav Katina, Ph.D. – vytvoril koncepciu knihy, navrhol štruktúrované riešenia príkladov a štruktúrované informácie o dátach, vyriešil a naprogramoval príklady a obrázky k nim v \LaTeX a napísal text všetkých kapitol v \LaTeX -u, vytvoril tabuľky funkcií s ich definíciami, vytvoril register, zoznam grafov, tabuliek, matematických symbolov a skratiek;
2. doc. RNDr. Miroslav Králík, Ph.D. – napísal antropologicky a metodicky orientované časti textu, pripravil dáta a štruktúrované informácie o nich, spolupodielal sa na definícii hypotéz v príkladoch a interpretácii výsledkov štatistických testov a vyvodzovaní záverov;
3. Mgr. Adela Hupková – podieľala sa na tvorbe antropologicky a metodicky orientovaných častí textu, ich preklade do slovenčiny a prepise do \LaTeX -u, na príprave dát, štruktúrovaných informácií a grafických podkladov a vytvorení tabuliek funkcií.

Autori by sa radi poďakovali:

- recenzentom prof. RNDr. Gejzovi Wimmerovi, DrSc. a doc. RNDr. Milanovi Turzovi, CSc. za starostlivé prečítanie a korekciiu textu knihy;
- Mgr. Ivete Selingerovej za korekciiu kapitol 2 a 4, Mgr. Kateřine Konečnej a Mgr. Dagmar Lajdovej za korekciiu kapitol 4, 6, 7 a 8;
- Mgr. Tomáši Mořkovskému za všestrannú organizačnú podporu.

Prípravu a vydanie tejto publikácie podporil projekt Formování mezinárodního týmu pro výzkum evoluční antropologie moravských populací (FITEAMP, CZ.1.07/2.3.00/20.0181) z Operačného programu Vzdelávanie pre konkurencieschopnosť, riešený na Ústave antropológie Prírodovedeckej fakulty Masarykovej univerzity.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Obsah

Úvod	xi
1 Vedecké štúdie	1
1.1 Ciele vedeckej štúdie a sledované premenné	3
1.2 Typy vedeckých štúdií	6
1.2.1 Observačné štúdie vo fyzickej a klinickej antropológii	7
1.2.2 Systematický prehľad	13
1.2.3 Štúdie kostrových pozostatkov	14
1.3 Štatistické hľadiská plánovania štúdií	15
1.3.1 Typy výberov	15
1.3.2 Náhodný výber v realite antropologického výskumu	18
1.3.3 Hlavné atribúty dát	18
1.3.4 Metódy zberu dát	18
1.3.5 Zisťovanie presnosti merania	21
1.3.6 Štatistické znaky	23
1.3.7 Triedenie dát	24
1.3.8 Znáhodnenie a zaslepenie	25
1.3.9 Databáza	25
1.3.10 Rozsah náhodného výberu	27
1.3.11 Kontroly a ich hodnotenie	28
1.3.12 Nábor (získavanie) subjektov vo fyzickej a klinickej antropológii	30
1.4 Úloha bioštatistika pri tvorbe vedeckých štúdií	31
2 Model rozdelenia pravdepodobnosti a štatistický model	33
2.1 *Simulačný experiment ako nástroj štúdia teoretických vlastností modelov	56
2.2 *Štatistika	59
2.3 *Funkcia vierohodnosti	62
2.4 *Maximalizácia funkcie vierohodnosti	69
2.5 Kritériá klasifikácie štatistických modelov	74
2.6 Praktické dôsledky odchýlok od normality	75
3 Charakteristiky polohy a variability a štatistická grafika	77
3.1 Charakteristiky polohy	80
3.2 Charakteristiky variability	82
3.3 Detekcia odľahlých pozorovaní	85
3.4 Z-skóre	86
3.5 Príklady na charakteristiky polohy a variability	87
3.6 Štatistická grafika	89
3.6.1 Stĺpcový diagram	89
3.6.2 Spojnicový graf, polygón početnosti a frekvenčná krivka	91
3.6.3 Bodový graf	91
3.6.4 Kruhový diagram	94
3.6.5 Histogram	96
3.6.6 Empirická distribučná funkcia	99
3.6.7 Krabicový diagram	99
3.6.8 Kvantilový diagram	101
3.7 Príklady zo štatistickej grafiky	102
4 Testovanie hypotéz	105
4.1 *Asymptotické vlastnosti odhadov	109
4.2 Interval spoľahlivosti Waldovho typu	113

4.3	Testovanie H_0 oproti H_1	115
4.4	*Tri typy testovacích štatistík	120
4.5	Vierohodnostné intervaly spoľahlivosti	126
5	Testy dobrej zhody	131
5.1	χ^2 test dobrej zhody	131
5.2	Kolmogorov-Smirnovov test dobrej zhody	137
6	Testovanie hypotéz o jednom parametri	143
6.1	Asymptotické testy o strednej hodnote	143
6.2	Asymptotické testy o rozptyle	159
6.3	Asymptotické testy o korelačnom koeficiente	164
6.4	Asymptotické testy o pravdepodobnosti	174
7	Testovanie hypotéz o dvoch parametroch	189
7.1	Asymptotické testy o rozdiel stredných hodnôt	189
7.2	Asymptotické testy o podiele rozptylov	199
7.3	Asymptotické testy o rozdiel korelačných koeficientov	203
7.4	Asymptotické testy o dvoch pravdepodobnostiach	208
8	Testovanie hypotéz o viacerých parametroch	227
8.1	Asymptotické testy o stredných hodnotách	229
8.1.1	Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch	229
8.1.2	Metódy mnohonásobného porovnávania	235
8.1.3	Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch	248
8.2	Asymptotické testy o rozptyloch	256
8.3	Asymptotické testy o korelačných koeficientoch	260
8.4	Asymptotické testy o pravdepodobnostiach	265
9	Antropologické dátové subory	273
9.1	Dátový súbor – jednovýberový test o strednej hodnote	273
9.2	Dátový súbor – párový test o strednej hodnote	273
9.3	Dátový súbor – párový test o strednej hodnote	275
9.4	Dátový súbor – jednovýberový test o rozptyle	275
9.5	Dátový súbor – jednovýberový test o korelačnom koeficiente	276
9.6	Dátový súbor – jednovýberový test o lineárno-uhlovom korelačnom koeficiente	277
9.7	Dátový súbor – jednovýberový test o uhlovom korelačnom koeficiente	277
9.8	Dátový súbor – jednovýberový test o pravdepodobnosti	278
9.9	Dátový súbor – jednovýberový test o pravdepodobnosti	279
9.10	Dátový súbor – dvojjvýberový test o rozdiel stredných hodnôt	279
9.11	Dátový súbor – dvojjvýberový test o rozdiel stredných hodnôt	280
9.12	Dátový súbor – dvojjvýberový test o podiele rozptylov	280
9.13	Dátový súbor – dvojjvýberový test o rozdiel korelačných koeficientov	281
9.14	Dátový súbor – dvojjvýberový test o rozdiel pravdepodobností	282
9.15	Dátový súbor – viacvýberový test o stredných hodnotách, nominálna premenná	283
9.16	Dátový súbor – viacvýberový test o stredných hodnotách, nominálna premenná	283
9.17	Dátový súbor – viacvýberový test o stredných hodnotách, ordinálna premenná	285
9.18	Dátový súbor – viacvýberový test o rozptyloch	285
9.19	Dátový súbor – viacvýberový test o korelačných koeficientoch	286
9.20	Dátový súbor – viacvýberový test o pravdepodobnostiach	287
9.21	Dátový súbor – viacvýberový test o pravdepodobnostiach	287
9.22	Dátový súbor – viacvýberový test o pravdepodobnostiach	288
9.23	Dátový súbor – viacvýberový test o pravdepodobnostiach	290
9.24	Dátový súbor – homogenita vektorov pravdepodobností	290
10	Funkcie	293
	Literatúra	299
	Register	303

Zoznam obrázkov

2.1	Miery normálneho rozdelenia; krivka hustoty s vyfarbeným obsahom pod touto krivkou medzi príslušnými kvantilmi na osi x ; obsah je rovný pravdepodobnosti výskytu subjektov s danou výškou v rozpätí týchto kvantilov	37
2.2	Upravené miery normálneho rozdelenia; krivka hustoty s vyfarbeným obsahom pod touto krivkou medzi príslušnými kvantilmi na osi x ; obsah je rovný pravdepodobnosti výskytu subjektov s danou normovanou výškou v rozpätí týchto kvantilov	38
2.3	Aproximácia binomického rozdelenia normálnym pre $p = 0.515$ a $N = 5, 10$ a 50 ; spojnicový graf superponovaný hustotou (prvý riadok) a distribučnou funkciou (druhý riadok)	41
2.4	Aproximácia binomického rozdelenia normálnym pre $p = 0.1$ a $N = 5, 10$ a 50 ; spojnicový graf superponovaný hustotou (prvý riadok) a distribučnou funkciou (druhý riadok)	42
2.5	Hustoty dvojrozmerného normálneho rozdelenia pri rôznych parametroch (prvý riadok – kontúrový graf, druhý riadok – perspektívny trojrozmerný graf v podobe plochy); čím je ρ odlišnejšie od nuly, tým viac sa kontúry líšia od kruhov (menia sa na elipsy); so zväčšujúcim sa rozdielom medzi σ_1 a σ_2 sa zväčšuje rozdiel rozptýlenia koncentrických kruhov v smere jednotlivých osí (hovoríme, že rozdiel variability premenných X_1 a X_2 sa zväčšuje)	43
2.6	Hustota dvojrozmerného normálneho rozdelenia s parametrom $\hat{\theta}$, ktorý je odhadnutý z dát (vľavo) a superimpozícia kontúr hustoty dvojrozmerného normálneho rozdelenia s parametrom $\hat{\theta}$, ktorý je odhadnutý z dát a dvojrozmerného jadrového odhadu hustoty (vpravo)	44
2.7	Hustoty dvojrozmerného normálneho rozdelenia (prvý riadok $n = 50$; druhý riadok $n = 1000$)	45
2.8	Spoločná hustota dvojrozmerného normálneho rozdelenia (vľavo), hustota zmesi dvoch dvojrozmerných normálnych rozdelení (uprostred) a dvojrozmerný jadrový odhad superponovaný hustotou zmesi dvoch dvojrozmerných normálnych rozdelení (vpravo) – simulačná štúdia	46
2.9	Spoločná hustota dvojrozmerného normálneho rozdelenia (vľavo), hustota zmesi dvoch dvojrozmerných normálnych rozdelení (uprostred) a dvojrozmerný jadrový odhad superponovaný hustotou zmesi dvoch dvojrozmerných normálnych rozdelení (vpravo) – reálne dáta	47
2.10	Hustoty normálneho rozdelenia a zošikmeného normálneho rozdelenia pri rôznych parametroch (prvý riadok); hustoty dvojrozmerného zošikmeného normálneho rozdelenia (druhý riadok vľavo a uprostred) a dvojrozmerného normálneho rozdelenia (druhý riadok vpravo) pri rôznych parametroch	48
2.11	Pravdepodobnostná funkcia a distribučná funkcia $Bin(5, 0.5)$	49
2.12	Histogram vygenerovaných pseudonáhodných čísel superponovaný spojnicovým grafom teoretickej pravdepodobnostnej funkcie X	58
2.13	Histogram vygenerovaných priemerov superponovaný teoretickou krivkou hustoty \bar{X}_n	59
2.14	Histogram vygenerovaných rozdielov priemerov superponovaný teoretickou krivkou hustoty rozdelenia rozdielov výberových aritmetických priemerov	60
2.15	Histogramy vygenerovaných testovacích štatistík v relatívnej škále superponované s teoretickými krivkami hustoty F ; $X \sim N(0, 1)$ (ľavý stĺpec) a $X \sim [(1-p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$ (pravý stĺpec); $n = 15$ (horný riadok), $n = 100$ (dolný riadok)	62
2.16	Porovnanie škálovaného logaritmu funkcie vierohodnosti (plná čiara) s jeho kvadratickou aproximáciou (čiarkovaná čiara) v prvom riadku a porovnanie škálovanvej skóre funkcie a priamky s nulovým interceptom a jednotkovým sklonom v druhom riadku	66
2.17	Profilová funkcia vierohodnosti pre μ (vľavo), σ^2 (uprostred) a funkcia vierohodnosti pre oba parametre (vpravo); $X \sim N(4, 1)$; maximálne vierohodné odhady strednej hodnoty a rozptylu sú označené zvislou čiarkovanou čiarou (vľavo a uprostred) a maximálne vierohodný odhad vektora parametrov je označený \bullet (vpravo)	72
2.18	Funkcia vierohodnosti pre $X \sim Bin(N, p)$ ($p = 0.1, 0.5, 0.9$ a $N = 20$); odhady \hat{p} sú označené zvislou čiarkovanou čiarou	73
2.19	Logaritmus štandardizovanej funkcie vierohodnosti multinomického rozdelenia v parametroch p_1 a p_2 (Európska populácia) s maximom označeným \bullet	74
3.1	Stĺpcové diagramy – početnosti (prvý riadok) pre vlasy (vľavo), pre oči (vpravo); pravdepodobnosti (druhý riadok) pre vlasy (vľavo), pre oči (vpravo)	92
3.2	Základné typy bodov (dolný riadok) a farieb (horný riadok)	93
3.3	Základné typy čiar – zvislo, vodorovne a v uhle 45° (zľava doprava)	94
3.4	Rozptylový graf pre dĺžku a šírku kališných lístkov	94
3.5	Kruhový diagram (dáta oči vs. vlasy)	95
3.6	Kruhový diagram (odtíene sivej)	96
3.7	Histogram so superponovanou krivkou hustoty normálneho rozdelenia (plná čiara) a hustoty vypočítanej z dát (empirická hustota; čiarkovaná čiara); pod histogramom je tzv. „koberec“	97
3.8	Dva histogramy s priloženými bázami (základňami)	98
3.9	Hustota so superponovanou hustotou normálneho rozdelenia v podobe 95% pásu spoľahlivosti	98
3.10	Emirická distribučná funkcia (schodovitá krivka) superponovaná krivkou distribučnej funkcie normálneho rozdelenia (hladká krivka)	100
3.11	Bodový graf s marginálnymi krabicovými diagramami (vľavo) a s histogramami (vpravo)	101
3.12	qq -diagram normovanej spojitej premennej výška 10-ročných dievčat (mm) so superponovanou obálkou normálneho rozdelenia	102
3.13	Základná štvorica grafov pre spojitú premennú výška 10-ročných dievčat (mm) – hustota (vľavo hore), kumulatívna distribučná funkcia (vpravo hore), krabicový diagram (vľavo dole), kvantilový diagram s Atkinsonovou obálkou (vpravo dole)	103
3.14	Základná trojica grafov pre pôrodnú hmotnosť $birth.W$ (dáta <code>two-samples-means-birth.txt</code>) – hustoty (vľavo), kumulatívne distribučné funkcie (uprostred), krabicové diagramy (vpravo)	104

4.1	Grafické znázornenie hustôt normálneho rozdelenia, t -rozdelenia, χ^2 -rozdelenia a F -rozdelenia pri rôznych stupňoch voľnosti	107
4.2	Grafické znázornenie významu pravdepodobnosti pod krivkou rozdelenia medzi dvoma kvantilmi (normálne rozdelenie)	108
4.3	Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou normálneho rozdelenia; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom	109
4.4	Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou t -rozdelenia s $df = 10$; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom	110
4.5	Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou χ^2 -rozdelenia s $df = 10$; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom	111
4.6	Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou F -rozdelenia s $df_1 = 20$ a $df_2 = 20$; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom	112
4.7	MC experiment pre IS (IS, ktoré neobsahujú $\mu = 0$, sú označené hrubou čiarou); vľavo $X \sim N(0, 1)$ a vpravo $X \sim [0.9N(0, 1) + (1 - 0.9)N(0, 4)]$	114
4.8	Silofunkcie asymptotického testu o μ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	125
4.9	Schematický náčrt silofunkcií pre $n = 9$ a $n = 36$	126
4.10	Funkcia vierohodnosti (plnú čiarou) pre p (vľavo) a $g(p)$ vpravo spolu so superponovanými kvadratickými aproximáciami (čiarkovanou čiarou); horizontálna priamka predstavuje hodnotu <i>cut-off</i>	129
5.1	Histogram superponovaný s očakávanými hodnotami SAT skóre	133
5.2	Simulované rozdelenie D_n (vľavo) a histogram superponovaný s očakávanými početnosťami výšok (vpravo)	139
5.3	Simulované hustoty rozdelenia D_n pre jednoduchú a zloženú hypotézu	140
5.4	Pásky spoľahlivosti normálneho rozdelenia – pre hustotu (vľavo), distribučnú funkciu (uprostred) a kvantilovú priamku (vpravo)	141
6.1	Silofunkcie asymptotického testu o μ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	145
6.2	Rozptylový graf $\bar{x}_i, s_i, i = 1, 2, \dots, M, M = 100000$ pre $n = 5$ (vľavo), $n = 50$ (v strede) a $n = 100$ (vpravo)	146
6.3	Distribučná funkcia (vľavo) a hustoty (vpravo) necentrálneho t -rozdelenia pri rôznych parametroch necentrality λ vyjadreného pomocou δ	147
6.4	Hustota centrálného a necentrálneho t -rozdelenia; vľavo – hustota necentrálneho t -rozdelenia je superponovaná histogramom simulácií pre $X \sim N(4, 2.5^2)$ a vpravo – pre $X \sim [pN(4, 2.5^2) + (1 - p)N(4, 4.5^2)]$, kde $p = 0.9$	148
6.5	Empirická (krivka s chybovými úsečkami vo vybraných bodoch) a teoretická (hladká krivka) silofunkcia t -testu; simulácie; vľavo – $X \sim N(500, 100^2)$ a vpravo – $X \sim [pN(500, 100^2) + (1 - p)N(500, 200^2)]$, kde $p = 0.9$	149
6.6	Silofunkcie asymptotického testu o σ^2 pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	161
6.7	Silofunkcie asymptotického testu o ρ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	167
6.8	Silofunkcie asymptotického testu o p pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	176
6.9	Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p ; $N = 30$ (vľavo), 100 (uprostred) a $N = 1000$ (vpravo)	183
6.10	Pravdepodobnosť pokrytia skóre 95% empirického DIS pre p pri rôznych N	184
6.11	Pravdepodobnosť pokrytia vierohodnostného 95% empirického DIS pre p pri rôznych N	184
6.12	Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p pri $N = 30$; spätne transformovaný DIS pre šancu (vľavo), spätne transformovaný DIS pre logaritmus šance (uprostred) a spätne transformovaný DIS pre $\arcsin \sqrt{p}$ (vpravo)	185
6.13	Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p pri $N = 100$; spätne transformovaný DIS pre šancu (vľavo), spätne transformovaný DIS pre logaritmus šance (uprostred) a spätne transformovaný DIS pre $\arcsin \sqrt{p}$ (vpravo)	185
6.14	Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p pri $N = 1000$; spätne transformovaný DIS pre šancu (vľavo), spätne transformovaný DIS pre logaritmus šance (uprostred) a spätne transformovaný DIS pre $\arcsin \sqrt{p}$ (vpravo)	186
7.1	Silofunkcie Waldovho testu o $\mu_1 - \mu_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	190
7.2	Silofunkcie Waldovho testu o $\mu_1 - \mu_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	192
7.3	Hustota centrálného a necentrálneho t -rozdelenia; vľavo – hustota necentrálneho t -rozdelenia je superponovaná histogramom simulácií pre $X_1 \sim N(4, 2.5^2)$, $X_2 \sim N(2, 2.5^2)$ a vpravo – pre $X_1 \sim [pN(4, 2.5^2) + (1 - p)N(4, 4.5^2)]$, $X_2 \sim N(2, 4.5^2)$, kde $p = 0.9$	193
7.4	Nelineárny vzťah rozdielu rizík, pomeru šancí a pomeru rizík (vľavo $OR_{\max} = 0.669$; vpravo $OR_{\max} = 112.235$ a $OR_{\min} = 1.494$)	210
7.5	Nelineárny vzťah rozdielu rizík, pomeru šancí a pomeru rizík (vľavo $OR_{\max} = 0.111$; vpravo $OR_{\max} = 1003.004$ a $OR_{\min} = 9.000$)	211
7.6	Silofunkcie Waldovho testu o $p_1 - p_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	211
7.7	Silofunkcie alternatívneho Waldovho testu o $p_1 - p_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)	212
7.8	Funkcia vierohodnosti a profilová funkcia vierohodnosti binomického rozdelenia pre θ ; $n_1 = 5, n_2 = 1$ (prvý riadok), $n_1 = 6, n_2 = 0$ (druhý riadok)	223
7.9	Funkcia vierohodnosti a profilová funkcia vierohodnosti binomického rozdelenia pre logaritmus pomeru šancí zlomenia sa zuba	224
7.10	Profilová funkcia vierohodnosti Poissonovho rozdelenia pre θ a $\theta_j, j = 1, 2, 3, 4$	225
7.11	Profilová funkcia vierohodnosti pre θ	226
8.1	Silofunkcie ANOVA F -testu pri rôznych J a K – vľavo $J = 3$, uprostred $JK = 12$ a vpravo $JK = 100$	231
8.2	Hustota centrálného a necentrálneho F -rozdelenia superponovaná histogramom simulácií pre $Y_j \sim N(\mu_j, \sigma_\epsilon^2)$	232
8.3	Histogramy vygenerovaných testovacích štatistík za platnosti alternatívnej hypotézy v relatívnej škále superponované s teoretickými krivkami hustoty F_W (vľavo) a U_{LR} (vpravo)	235
8.4	Histogramy vygenerovaných testovacích štatistík (za platnosti nulovej hypotézy) v relatívnej škále superponované s teoretickými krivkami hustoty F_W (vľavo) a U_{LR} (vpravo)	236
8.5	Odhadnuté hustoty vybraných t -štatistík T_{LSD} (pre rozdiel populácií A a B) a maximálnych t -štatistík (T_{HSD}) spolu s korešpondujúcimi teoretickými kritickými hodnotami $t_{n-j}(0.025)$, resp. a $q_{J, n-j}(0.05)$	241

8.6	Kritické hodnoty – Scheffeho $hF_{h,df_e}(\alpha)$, Bonferroniho $F_{1,df_e}(\alpha/h)$, Tukeyho HSD $q_{J,n-J}^2(\alpha)$ a Fisherove LSD $F_{1,df_e}(\alpha)$, $J = 5, 7, 10$, pre rôzne $n < 100$, kde $n - J > 0$ (prvý riadok); upravené hladiny významnosti α_k – Bonferroniho $\alpha_k = \alpha/h$, Holmova $\alpha_k = \alpha/(h - k + 1)$, Benjamini-Hochbergova $\alpha_k = k\alpha/h$, Benjamini-Yekutieliho $\alpha_k = k\alpha/(h \sum_{i=1}^h 1/i)$, $J = 5, 7, 10$, pre vzrastajúce $k = 1, 2, \dots, h$ (druhý riadok)	242
8.7	Rozptytové grafy ANOVA modelov – \mathcal{F}_{H_0} (vľavo) a \mathcal{F}_{H_1} (vpravo)	246
8.8	Waldove simultánne 95% empirické IS Tukeyho typu pre rozdiely stredných hodnôt	247
8.9	Krubicové diagramy pôrodnej hmotnosti pre dievčatá a chlapcov	250
8.10	Krubicové diagramy pôrodnej hmotnosti pre dievčatá a chlapcov podľa počtu predchádzajúcich detí biologickej matky	251
8.11	Krubicové diagramy pôrodnej hmotnosti pre dievčatá a chlapcov podľa vzdelania biologickej matky	251
8.12	Waldove simultánne 95% empirické intervaly spoľahlivosti Tukeyho typu pre rozdiely stredných hodnôt pôrodnej hmotnosti (pohlavie dieťaťa vs počet predchádzajúcich detí biologickej matky) – za predpokladu homogenity rozptylov (vľavo) a nehomogenity rozptylov (vpravo); rozdiely v dĺžke toho istého intervalu spoľahlivosti pri rôznych predpokladoch sa líšia od 0.63 po 14.52 v závislosti od odchýlky hodnôt rozptylov použitých na ich výpočet a od rozdielov stupňov voľnosti df_w (newinsorizované dáta)	252
8.13	Waldove simultánne 95% empirické intervaly spoľahlivosti Tukeyho typu pre rozdiely stredných hodnôt pôrodnej hmotnosti (pohlavie dieťaťa vs vzdelanie biologickej matky) – za predpokladu homogenity rozptylov (vľavo) a nehomogenity rozptylov (vpravo); rozdiely v dĺžke toho istého intervalu spoľahlivosti pri rôznych predpokladoch sa líšia od 2.51 po 54.40 v závislosti od odchýlky hodnôt rozptylov použitých na ich výpočet a od rozdielov stupňov voľnosti df_w (newinsorizované dáta)	253
8.14	Krubicové diagramy pre ženy a mužov – dĺžka hlavy (vľavo hore), šírka dolnej čeľuste (vľavo dole), šírka hlavy (vpravo hore) a šírka tváre (vpravo dole)	254
8.15	Krubicové diagramy pre ženy a mužov podľa sexuálnej orientácie – dĺžka hlavy (vľavo hore), šírka dolnej čeľuste (vľavo dole), šírka hlavy (vpravo hore) a šírka tváre (vpravo dole)	256
8.16	Waldove simultánne 95% empirické intervaly spoľahlivosti Tukeyho typu pre rozdiely stredných hodnôt – dĺžka hlavy (vľavo hore), šírka dolnej čeľuste (vľavo dole), šírka hlavy (vpravo hore) a šírka tváre (vpravo dole); newinsorizované dáta	257
8.17	Histogramy vygenerovaných testovacích štatistík (za platnosti nulovej hypotézy) v relatívnej škále superponované s teoretickými krivkami hustoty U_{LR} (vľavo) a U_B (vpravo)	260
8.18	Histogramy vygenerovaných testovacích štatistík (za platnosti nulovej hypotézy) v relatívnej škále superponované s teoretickými krivkami hustoty U_{LR} (vľavo) a χ_F^2 (vpravo)	263
8.19	Logaritmus štandardizovanej funkcie vierohodnosti s maximom označeným \bullet a vierohodnostnou 95% empirickou elipsou spoľahlivosti pre θ	268
8.20	Stĺpcový diagram relatívnych početností zakončení dlaňových línií (v %) pre každú farbu vlasov	271
9.1	Znázornenie premenných najväčšia dĺžka mozgovne (skull.L) a najväčšia šírka mozgovne (skull.B)	274
9.2	Znázornenie premennej vertikálny priemer v strede dĺžky tela kľúčnej kosti (simd)	274
9.3	Znázornenie premennej dĺžka kosti kľúčnej z ľavej strany (length.L)	275
9.4	Znázornenie premenných najväčšia výška mozgovne (skull.pH) a morfológická výška tváre (face.H)	276
9.5	Znázornenie premenných výška lebky (skull.H), výška lebečnej bázy (base.H), šírka lebečnej bázy (base.B) a uhol, ktorý zvierajú línie prechádzajúce oboma bodmi <i>porion</i> s vrcholom v bode <i>basion</i> (base.A)	278
9.6	Znázornenie premenných uhol v bode <i>nasion</i> (front.A) a uhol tvárového trojuholníka v bode <i>prosthion</i> (prog.A)	279
9.7	Znázornenie premennej výška lebky (skull.H)	281
9.8	Znázornenie premenných dĺžka dolnej končatiny (lowex.L) a dĺžka trupu (tru.L)	282
9.9	Znázornenie premennej výška hornej časti tváre (upface.H)	283
9.10	Znázornenie premenných dĺžka hlavy (head.L), šírka hlavy (head.W), šírka dolnej čeľuste (big.W) a šírka tváre bizyg.W	284
9.11	Znázornenie premennej najväčšia dĺžka kosti kľúčnej z pravej strany (cla.L)	285
9.12	Znázornenie premenných výška nosa (nose.H), šírka nosa (nose.B) a interorbitálna šírka (interorb.B)	286
9.13	Kostný reliéf na vnútornej strane <i>os pubis</i>	288
9.14	Číslovanie pozíc na okraji dlane a príklady vysokého (Hi), stredného (Mi) a nízkeho (Lo) zakončenia troch hlavných dlaňových línií (D, C a B)	289

Zoznam tabuliek

1.1	Štatistiky frekvencie vs. typ štúdie (# znamená počet)	11
2.1	Príklady minimálnych N pre fixované p potrebných na aproximáciu	40
2.2	Kontingenčná tabuľka 2×3 pravdepodobností p_j pre dva socioekonomické statusy, dve politické príslušnosti a dve politické filozofie (multinomické rozdelenie)	50
2.3	Kontingenčná tabuľka 2×3 očakávaných početností Np_j pre dva socioekonomické statusy, dve politické príslušnosti a dve politické filozofie (multinomické rozdelenie)	50
2.4	Kontingenčná tabuľka 2×3 pravdepodobností $p_{j i}$ pre dva socioekonomické statusy, dve politické príslušnosti a dve politické filozofie (súčinové multinomické rozdelenie)	51
2.5	Kontingenčná tabuľka 2×3 očakávaných početností $N_i p_{j i}$ pre dva socioekonomické statusy, dve politické príslušnosti a dve politické filozofie (súčinové multinomické rozdelenie)	51
2.6	Kontingenčná tabuľka 3×3 pravdepodobností p_j pre tri farby vlasov a tri farby očí (multinomické rozdelenie)	52
2.7	Pozorované a očakávané početnosti m_n (zaokrúhlené na nula desatinných miest) Pruských armádných jednotiek, v ktorých nastalo n úmrtí zapríčinených kopnutím koňom	53
2.8	Pozorované početnosti rodín m_n s n chlapcami	55
2.9	Očakávané početnosti rodín m_n (zaokrúhlené na nula desatinných miest) s n chlapcami (binomické rozdelenie)	55
2.10	Pozorované početnosti robotníkov m_n s n úrazmi v továrni	56
2.11	Očakávané početnosti robotníkov m_n (zaokrúhlené na nula desatinných miest) s n úrazmi v továrni (Poissonovo rozdelenie)	56
2.12	Simulované a teoretické relatívne početnosti úspechov	57
2.13	Teoretické hodnoty stredných hodnôt a rozptylov S^2 a F a ich odhady zo simulačnej štúdie pri $n = 15$ a $n = 100$	61
2.14	Očakávané početnosti robotníkov m_n (zaokrúhlené na nula desatinných miest) s n úrazmi v továrni (negatívne binomické rozdelenie)	74
3.1	Zoradné realizácie x_i a ich poradia r_i pre výšky 10-ročných dievčat	81
3.2	Rozsah, aritmetický priemer a smerodajná odchýlka pre surové, urezané a winsorizované dáta (výšky 10-ročných dievčat)	88
3.3	Vybrané charakteristiky polohy a variability pre surové dáta (výšky 10-ročných dievčat)	89
3.4	Vybrané charakteristiky polohy a variability pre najväčšiu dĺžku lebky	89
3.5	Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov	90
3.6	Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi pravdepodobnosťami (multinomické rozdelenie)	90
3.7	Kontingenčná tabuľka 2×3 početností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi početnosťami (multinomické rozdelenie)	91
3.8	Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi stĺpcovými početnosťami (súčinové multinomické rozdelenie; po stĺpcoch)	91
3.9	Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi riadkovými početnosťami (súčinové multinomické rozdelenie; po riadkoch)	91
5.1	Očakávané pravdepodobnosti a početnosti a pozorované početnosti pre SAT skóre	132
5.2	Pozorované početnosti m_n päťsekundových intervalov v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom, v ktorých sa plod ove n-krát pohol	135
5.3	Očakávané početnosti m_n päťsekundových intervalov v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom (zaokrúhlené na nula desatinných miest), v ktorých sa plod ove n-krát pohol (Poissonovo rozdelenie)	135
5.4	Očakávané početnosti m_n päťsekundových intervalov v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom (zaokrúhlené na nula desatinných miest), v ktorých sa plod ove n-krát pohol (ZIP rozdelenie)	136
6.1	Minimálne rozsahy n pri vybraných rozdieloch ρ a ρ_0 , kde $\rho_0 = 0$	167
6.2	Minimálne rozsahy n pri vybraných rozdieloch ρ a ρ_0 spolu s rozdielom $z_R - \xi_0$, ktorý je funkciou ρ a ρ_0	168
6.3	Minimálne rozsahy N pre rôzne p v súvislosti s Haldovou podmienkou	175
6.4	Minimálne rozsahy N pre rôzne rozdiely p a p_0 (kde $p_0 = 0$) v porovnaní s minimálnym rozsahom vypočítaným pomocou Haldovej podmienky (tučne sú zvýraznené tie N , ktoré spĺňajú obe kritériá)	182
6.5	Minimálne rozsahy N pre rozdiel $p - p_0 = 0.1$ pri rôznych p a p_0 v porovnaní s minimálnym rozsahom vypočítaným pomocou Haldovej podmienky (tučne sú zvýraznené tie N , ktoré spĺňajú obe kritériá)	182
7.1	Minimálne rozsahy n pre rozdiel $\rho_1 - \rho_2 = 0.2$ pri rôznych ρ a ρ_0 spolu s rozdielom $\xi_1 - \xi_2$, ktorý je funkciou ρ_1 a ρ_2	205
7.2	Početnosti subjektov s rozšírenými a lokalizovanými metastázami	223
7.3	Odhad relatívneho rizika úmrtia a 95% IS relatívneho rizika úmrtia celkovo a pre každú vekovú skupinu	225
7.4	Početnosti subjektov s infarktom myokardu a mozgovou mŕtvicou v skupine A a B	226
8.1	Experimentálna chyba α_e ako funkcia α_e a h	239
8.2	Koncentrácia stroncia Sr (mg/ml) v piatich vodných celkoch	245
8.3	Výsledky Tukey HSD metódy - rozdiely aritmetických priemerov $\bar{y}_i - \bar{y}_j$, dolná a horná hranica Waldových simultánnych 95% empirických IS Tukeyho typu pre $\mu_i - \mu_j$ (DH a HH), adjustované p-hodnoty \tilde{p}_k	247
8.4	Adjustované p-hodnoty pre Tukeyho HSD (THSD) metódu, Bonferroniho (B) metódu, Holm-Bonferroniho metódu (HB step-down), Hochberg-Bonferroniho metódu (HB step-up), Benjamini-Hochbergovu (BH) metódu a Benjamini-Yekutieliho (BY) metódu	248

8.5	Pozorované početnosti a pravdepodobnosti a očakávané početnosti a pravdepodobnosti (vypočítané pomocou funkcie vierohodnosti) pre Prahu	268
10.1	Prehľad základných funkcií – charakteristiky polohy a variability a matematické funkcie	293
10.2	Prehľad funkcií súvisiacich s dátovým manažmentom a funkcia library()	294
10.3	Prehľad štatistických a numericko-matematických funkcií	295
10.4	Prehľad funkcií kresliacich rôzne druhy grafov a funkcií s grafmi súvisiacich	296
10.5	Prehľad funkcií súvisiacich s grafmi – popis obrázka a jeho parametre	296
10.6	Prehľad funkcií súvisiacich s rozdeleniami pravdepodobnosti	297

Úvod

Aplikácia štatistických metód a štatisticky orientovaný spôsob uvažovania nebol v biologickej antropológii zaužívaný od jej začiatkov v európskom novoveku, a ani v súčasnosti nepatrí k optimálne rozvinutým oblastiam antropológie. Celý rad štatistických metód pritom vznikol v súvislosti s potrebami vedných odborov zaoberajúcich sa človekom (napr. lineárna regresná analýza vznikla kvôli odhadovaniu výšky postavy človeka na základe dĺžky kostí jeho skeletu, Pearson (1899)). Jedným z dôvodov je po storočia pretrvávajúci typologický prístup k štúdiu človeka, v dôsledku čoho sa na dlhý čas zakonzervoval rasový koncept, ktorý brzdil akékoľvek štúdium ľudskej rozmanitosti a prispôsobivosti. Antropologické štúdie devätnásteho storočia, napísané často na mnoho desiatkach až stovkách strán, do najmenšieho detailu popisovali niekoľko ľudí či niekoľko ľudských kostí, a bez akýchkoľvek údajov o spôsobe vzniku vzorky vyvodzovali ďalekosiahle závery napr. o „rasových“ rozdieloch (cf. Broca, 1862). Aj niektorí zakladatelia a priekopníci biologickej antropológie v storočí dvadsiatom sa využitiu štatistiky bránili. Dokonca i znamenitý Aleš Hrdlička (1869–1943), americký antropológ českého pôvodu, zakladateľ a dlhodobý editor dnes celosvetovo uznávaného odborného časopisu *American Journal of Physical Anthropology*, štatistike neprial a nepodporoval použitie pokročilých štatistických metód v článkoch publikovaných v tomto časopise (Ashley Montagu, 1944). Situácia sa začala meniť v polovici 20. storočia, kedy sa biologická antropológia začala orientovať ekologickým smerom a skúmať ľudské populácie a variabilitu ľudských vlastností v nich i medzi nimi ako výsledok dlhého procesu prispôsobovania sa rôznym podmienkam prostredia (Mielke a kol., 2011, str. 3–22). Populačné vzorky, spôsob ich vzniku a ich vlastnosti (populačné mikroevoľučné procesy) sa stali pre interpretáciu výsledkov a vyvodzovanie záverov zásadné, rovnako tak ako sa štatistika stala dôležitým nástrojom zabezpečujúcim platnosť (štatistickú validitu) antropologických záverov. Už prvá česko-slovenská učebnica antropológie má kapitolu zoznamujúcu s podstatou základov štatistického uvažovania (Suchý, 1967), nasledovaná vznikom niekoľkých ďalších prác o štatistike a bioštatistike, vhodnej pre antropológov, biológov a lekárov (napr. Zvára, 1999, 2001; Komenda, 2000). Aplikácia štatistických metód je dnes súčasťou takmer každej odbornej práce v biologickej antropológii, pričom pokroky v rozvoji štatistických metód umožňujú výber vhodnej metódy prispôbenej skúmaným javom a komplexné usporiadanie štatistických porovnaní. Výučba základných štatistických metód patrí medzi štandardné súčasti štúdia biologickej antropológie. Napomáha adeptom naučiť sa pristupovať k riešeným problémom koncepčne od samotného začiatku, t.j. počiatočného nápadu a návrhu výskumu až po rozhodovanie o závažnosti nimi zistených výsledkov. Ako v prípade každého nástroja aj v prípade štatistických metód platí, že pri správnom použití dobre splňajú svoj účel, ale pri nesprávnom použití môžu výsledky výskumu v neznámej miere strácať svoju platnosť.

Dnešný antropologický výskum sa bez uplatnenia štatistického uvažovania nezaobíde. I keď sa väčšina biológov, lekárov ani antropológov štatistikmi nikdy nestanú (až na výnimočné personálne únie), výsledky výskumov i možnosti ich publikácie na správnom usporiadaní a štatistickom spracovaní dajú silno závisia. Kľúčovým pre obojstranne úspešnú spoluprácu preto je na strane týchto odborov porozumieť základom štatistických postupov, vedieť sa vyjadrovať aspoň základnou štatistickou terminológiou a vedieť štatistikovi vysvetliť svoj výskumný zámer; na strane štatistika potom pochopiť podstatu zamerania jednotlivých odborov, charakter ich metodológie a typické problémy, s ktorými sa po štatistickej stránke stretávajú – a vytvoriť si vzťah obojstranného porozumenia a prospešnosti. Jedným z cieľov tejto knihy je podporiť kladný prístup mladých ľudí k využívaniu štatistických metód v antropológii a ďalších odboroch a umožniť ich aplikáciu v prostredí programu \mathbb{R} , univerzálneho výpočtového prostredia, voľne dostupného všetkým (R Development Core Team, 2013).

Táto kniha nie je ani „kuchárskou knihou“ (pretože matematická štatistika nie je knihou receptov alebo návodov), nie je ani „teoretickou matematickou štatistikou“ (pretože teória je vysvetlená prostredníctvom príkladov pochádzajúcich z reality praxe biologickej antropológie) a nie je ani „učebnicou prostredia \mathbb{R} “ (pretože program \mathbb{R} je v knihe použitý len ako nástroj, prostredníctvom ktorého sú riešené reálne situácie). Čím teda kniha je? **Kniha je unikátnou kombináciou sily teoretického základu matematickej štatistiky implementovaného v prostredí \mathbb{R} s cieľom pochopiť a riešiť praktické situácie z biologickej antropológie (ako aj biológie a medicíny).** Prečo

práve \mathbb{R} ? Pretože \mathbb{R} naozaj stojí za to. Nie je to len „užívateľsky neprispôsobivý“ komerčný klikací softvér slúžiaci na riešenie vybraných problémov z aplikácií s obmedzeným množstvom použitelných štatistických metód (pokiaľ sa nejaká metóda v takomto softvéri nenachádza, je nutné ju hľadať inde). Je to voľne šíriteľné komplexné prostredie slúžiace na štatistické výpočty, prostredie schopné prispôbiť sa požiadavkám užívateľa. Je to interaktívne prostredie s priateľlivou statickou, ako aj animačnou grafikou. Je to prostredie, v ktorom je možné riešiť nekonečné množstvo praktických, ako aj teoretických štatistických problémov. \mathbb{R} je „všetko v jednom“ a naozaj stojí za to!

Kniha je napísaná na základe dlhoročných skúseností prvého autora z prednášania bioštatistických predmetov na štyroch univerzitách (Univerzita Komenského, University of Vienna, University of Glasgow a Masarykova univerzita) pre študentov antropológie, medicíny, aplikovanej matematiky a štatistiky. Je jeho víziou komplexného prístupu k matematickej štatistike pozostávajúceho z dvoch trojpilierových systémov

1. (a) matematicko-štatistická teória, (b) implementácia v \mathbb{R} a (c) aplikácia na reálne situácie a
2. (a) plánovanie bio-medicínskych štúdií, (b) databáza a dátový manažment a (c) interpretácie.

Je členená do deviatich kapitol. Prvá kapitola Vedecké štúdie obsahuje informácie o plánovaní bio-medicínskych štúdií, ktoré by mal vedieť prakticky používať každý vedec pracujúci s reálnymi dátami. Zahŕňa témy ako typy vedeckých štúdií, teória a prax náhodného výberu, presnosť merania, znáhodnenie a zaslepenie, pravidlá tvorby bio-medicínskych databáz („Achilovej päty“ výskumu), plánovanie rozsahu náhodného výberu („piliera“ plánovania) a pod. Druhá kapitola podáva prehľad filozofie pojmov „model rozdelenia pravdepodobnosti“ a „štatistický model“, z ktorých sú postavené „pevné základy“ výskumu na reálnych dátach. Nachádza sa v nej prehľad vybraných, najčastejšie sa vyskytujúcich modelov ako model binomického rozdelenia, Poissonovho rozdelenia, multinomického a súčinného multinomického rozdelenia, negatívne-binomického rozdelenia, model normálneho rozdelenia a pod. Parametre týchto modelov sú podkladom „štatistického výkladového slovníka“, ktorý slúži na interpretácie výsledkov. Tretia kapitola Charakteristiky polohy a variability a štatistická grafika obsahuje metódy základnej číselnej a grafickej exploratívnej analýzy. Charakteristiky polohy a variability zjednodušene charakterizujú dáta. Štatistická grafika je „obrazom v ráme“, prostredníctvom ktorého sú dáta a výsledky štatistických analýz prezentované. Štvrtá kapitola Testovanie hypotéz komplexne zahŕňa najdôležitejší „pojmový štatistický aparát“, bez znalosti ktorého nie je možné robiť žiadnu štatistickú analýzu, t.j. ide o „pilier“ štatistických analýz a ich interpretácií. Ďalšie štyri kapitoly sú uceleným prehľadom najčastejšie používaných štatistických metód. Ide o systematický prehľad jednovýberových, dvojevýberových a viacvýberových praktických situácií. Tieto kapitoly sú základom štatistickej inferencie, prostredníctvom ktorej sú zovšeobecnené a interpretované výsledky analýz. Teoretický úvod vo väčšine prípadov obsahuje (1) teoretické predpoklady, (2) matematickú definíciu hypotéz, (3) testovaciu štatistiku (Waldovu testovaciu štatistiku, testovaciu štatistiku pomerom vierohodnosti alebo skóre testovaciu štatistiku), (4) jej rozdelenie za platnosti nulovej a alternatívnej hypotézy, (5) definíciu kritického oboru a silofunkcie, (6) definíciu p-hodnoty, (7) definíciu empirických intervalov spoľahlivosti, (8) algoritmus výpočtu minimálneho rozsahu súboru a (9) odvodenie vybraných typov testovacích štatistík. Po teoretickom úvode nasledujú riešené didaktické príklady na simulovaných alebo reálnych dátach (vysvetľujúce vlastnosti testov alebo demonštrujúce ich použitie) nasledované **riešenými reálnymi príkladmi. Ich riešenia sú štruktúrované do špecifických odsekov špeciálne vyvinutých pre túto knihu** – (1) slovná a matematická formulácia hypotéz, (2) testovacia štatistika, (3) zamietacia oblasť, (4) empirický dvojstranný interval spoľahlivosti, (5) štatistický záver, (6) slovný záver a (7) antropologický slovný záver. **Podobne sú v štruktúrovaných odsekoch prezentované aj informácie o dátach** – (1) hodnotený súbor, (2) súbor dát, (3) popis premenných, (4) biologické súvislosti a (5) ciele. Zadané príklady vhodné pre antropológov (biológov alebo lekárov) sú podfarbené sivou farbou. Matematicky náročnejšie kapitoly sú označené hviezdíčkou. Definície, vety a dôležitá teória sú vľavo zvýraznené hrubou vertikálnou čiarou. Riešenia príkladov v \mathbb{R} sú zvýraznené iným typom písma, jednotlivé riadky kódu sú očíslované a poznámky odlíšené sivou farbou. Kniha spolu obsahuje 273 príkladov (približne 90 % riešených), 1633 riadkov \mathbb{R} -kódu, 107 obrázkov, 48 tabuliek a 24 antropologických dátových súborov. Súčasťou knihy je aj tabuľkový prehľad použitých a naprogramovaných funkcií a ich stručné definície.

1 Vedecké štúdie

V procese poznania má teória nezastupiteľné miesto a stojí vždy na počiatku. Reprezentuje tradičný pohľad, ktorý v danej chvíli vysvetľuje väčšinu javov a ich súvislostí. Teória, ktorú sa spravidla naučíme, predstavuje sféru javov možných a overených, v jej rámci sa pohybujeme pri formulovaní pracovnej hypotézy. Posun v poznaní však umožňuje až novinka (inovácia), ktorá do jestvujúcej teórie (tradície) nezapadá. Veda je v tomto pohľade nikdy nekončiacie posúvanie hranice medzi tradíciou (teóriou, „sedliackym rozumom“, sférou vecí možných a uznávaných) a informáciou (novinkou). Vedecká metóda má zaistiť, aby sa posúvanie tejto hranice dalo v reálnom živote/svete uskutočniť, a aby nesmerovalo nežiaducim smerom vplyvom šumu (náhody, nesystematických javov). Teóriu/tradíciu potrebujeme poznať preto, aby sme dokázali v nových empirických dátach spoznať chyby, metódu potrebujeme na to, aby sme dokázali odlíšiť novinky od chýb.

Veda prináša systematizované poznanie, predstavuje aplikáciu štandardných metód na štandardné (a neštandardné) problémy. Zmyslom vedeckej metódy je predovšetkým zaistiť, aby vlastný postup získavania dát a ich interpretácie nevnašal do výsledkov skutočnosti, ktoré v reálnom svete neexistujú, a aby naše výsledky mali atribúty vedecky podložených výsledkov. Na rozdiel od iných (viac či menej legitímnych) spôsobov ľudského poznania (subjektívne myslenie, tušenie, viera) sa veda vyznačuje tým, že jej metódy a poznatky sú interpersonálne vymeniteľné (naučiteľné) a opakovateľné. Základným nárokom na vedecký výsledok je podmienka, aby rovnakým postupom mohol ktokoľvek a kedykoľvek v budúcnosti dosiahnuť rovnaké výsledky (čo je ideálna situácia).

Základnými vlastnosťami každej vedeckej štúdie by mala byť teoretická zakotvenosť, inovatívnosť, interpersonálna vymeniteľnosť a opakovateľnosť. Každá vedecká štúdia by mala byť pred realizáciou jasne a zrozumiteľne opísaná. Jej opis musí obsahovať dostatočné detaily v podobe tzv. **plánu (dizajnu) vedeckej štúdie (protokolu vedeckej štúdie)** s rozsahom 5 až 25 strán. Takýto plán musí zahŕňať jeho skrátenú, prehľadnú a kompaktnú verziu v podobe **anotácie**¹ v rozsahu 200–400 slov alebo **téz**, z ktorých možno získať rýchly prehľad o štúdiu v netechnickom jazyku zrozumiteľnom aj mimo vedeckého odboru, do ktorého štúdia patrí (Hackshaw, 2011). Plán a anotáciu možno usporiadať do nasledovných odstavcov, s každým v rozsahu jednej až troch viet, obsahujúcich len kľúčové fakty (pre každý typ štúdie je potrebné vybrať vhodnú podmnožinu odstavcov):

1. **Biologické súvislosti/Pozadie štúdie a jej význam** – informácie o cieľoch, význame a dôležitosti štúdie a o poznatkoch z danej problematiky.
2. **Dizajn štúdie** – informácie o zvolenom type štúdie (pozri kapitolu 1.2 Typy vedeckých štúdií), o počte sledovaných subjektov, v tejto časti sa často vyskytuje aj zoznam použitých štatistických metód (môže však byť uvedený aj samostatne; pozri ďalej).
3. **Subjekty/skúmané osoby/účastníci štúdie** – informácie o skúmaných subjektoch (zdroj subjektov – aké subjekty, odkiaľ a ako budú vybrané) a ich počte (počet prípadov a kontrol spolu s opisom párovania) a o základných vyšetreniach alebo vykonaných zákrokoch (v antropológii napr. meranie živého človeka, meranie kostí z kostrových sérií, morfometrická analýza obrazu (fotografie, 2D snímky, 3D modely)).
4. **Ciele** – často nazývané aj **Účel/Účely**, príp. **Biologicky formulované hypotézy** – informácie o tom, akú vedeckú otázku/otázky bude štúdia riešiť; či budú primárne alebo sekundárne.
5. **Premenné** – zoznam sledovaných premenných v zmysluplných skupinách, ich počet a definície
 - **Závislé premenné**² – primárne a sekundárne – presne korešpondujúce s cieľom, ich počet a typ, rozdelenie do zmysluplných skupín.

¹ Doslovný preklad anglického termínu abstract nie je presný, pretože pod abstraktom chápeme stručné zhrnutie už hotového textu (napr. článku), ale pod anotáciou rozumieme stručné zhrnutie plánovaného projektu/výskumu.

² Často štatisticky modelujeme (napr. lineárnym regresným modelom) kauzálny vzťah nezávislých a závislých premenných, kde sa nezávislé premenné nazývajú aj prediktory, pretože na základe nich odhadujeme hodnoty závislej premennej vnútri rozsahu hodnôt prediktorov alebo predpovedáme (predikujeme) hodnoty závislej premennej mimo rozsahu prediktorov.

- **Nezávislé premenné/Prediktory** – označenie typu meraných premenných, stanovenie metódy/metód a frekvencie meraní.
6. **Klinické vyšetrenia subjektov/skúmaných osôb** – pokiaľ ide o klinickú štúdiu (pozri ďalej).
 7. **Zákroky** – údaje o tom, kedy a aký typ randomizácie (pozri ďalej) subjektov do skupín bol použitý.
 8. **Trvanie** a prípadne ďalšie časové aspekty štúdie.
 9. **Opis štatistickej analýzy** – štatistický model/modely, model/modely rozdelenia pravdepodobnosti, matematicky formulované hypotézy³, výpočet minimálneho rozsahu súboru a pod. (nebýva súčasťou téz, ale vlastného plánu štúdie).

Definícia 1 (subjekt vs. výskumník) *Subjekt (skúmaný) je osoba/človek, štatistická jednotka, ktorá sa zúčastní výskumu (v experimente je i cieľom intervencie) a je zdrojom hodnotených údajov/dát o sledovaných premenných, ktoré sa získavajú (napr. meraním alebo vyšetrením) a štatisticky spracovávajú výskumníkom (skúmajúcim). Subjektom sa niekedy hovorí aj participant; subjektom vyplňajúcim dotazník aj respondent.*

Príklad 1 (závislé a nezávislé premenné) *Lorencová a Beneš (1976) uskutočnili prierezovú antropologickú štúdiu (pozri kapitolu 1.2 Typy vedeckých štúdií) zameranú na zistenie faktorov ovplyvňujúcich u mužov (adolescentov a dospelých) zloženie tela v priebehu života. Nameranými primárnymi závislými premennými boli hrúbky troch kožných rias (tricepsovej, subkapulárnej, suprailiákálnej) merané kalibrom typu Harpenden, z ktorých boli následne podľa rovnice $y = 1,87 + 0,398x$ (Pařízková, 1973) vypočítané sekundárne závislé premenné – percentuálny obsah tuku v tele a percentuálne zastúpenie netukového tkaniva ako doplnok do 100 % (x – súčet hrúbok troch kožných rias v mm, y – % tuku). Autori sledovali ovplyvnenie percenta tuku nezávislými premennými, medzi ktoré zaradili vek (resp. vekové kategórie od 16 do 64 rokov), frekvenciu príjmu stravy za deň (2 a menej, 3, 4 a viac), zamestnanie z hľadiska fyzickej námahy (uční, študenti, nemanuálne pracujúci, ľahko manuálne pracujúci a ťažko fyzicky pracujúci) a pravidelnú športovú aktivitu (pravidelne športujúci, nepravidelne športujúci, nešportujúci). Z výsledkov štúdie vyplýva, že percentuálny obsah tuku v tele sa s vekom zvyšuje a v rozmedzí 4. až 6. decénia je relatívne stály. Ďalej zistili negatívnu závislosť percenta tuku na frekvencii jedla a telesnej záťaže, t.j. muži s frekventovanejším príjmom stravy (väčším počtom menších dávok) a vyšším kalorickým výdajom (ťažko fyzicky pracujúci a aktívne športujúci) mali nižší percentuálny obsah telesného tuku.*

Veľmi účelným grafickým znázornením abstraktu a téz je **sieťový diagram**, prehľadne ukazujúci hlavné odstavce štúdie, ako aj:

- hlavné (dve až tri) kritériá výberu subjektov,
- základné vyšetrenia alebo zákroky na subjektoch na začiatku štúdie; v prípade randomizácie subjektov je potrebné uviesť, kedy a aká randomizácia sa vykonala,
- čo sa udeje so subjektmi počas štúdie (protokol sledovania).

Typická sekvencia štúdií je od **opisnej** (deskriptívnej), cez **analytickú** (opis príčinnno-následného vzťahu), až po (prevažne v medicíne) **klinickú štúdiu** sledujúcu efekt nejakého zákroku (intervencie).

Príklad 2 (sekvencia vedeckých štúdií) *Opisná štúdia: Aká je priemerná týždenná porcia rýb v strave ľudí s anamnézou koronárnej choroby srdca? Analytická štúdia: Aká je asociácia medzi konzumáciou rýb a rizikom opakovaného infarktu myokardu u ľudí s anamnézou koronárnej choroby srdca? Klinická štúdia: Redukuje liečba tabletami rybieho oleja mortalitu ľudí s anamnézou koronárnej choroby srdca?*

³Formulujeme nulovú hypotézu voči alternatívnej, kde sa často snažíme nulovú hypotézu vyvrátiť (princíp falzifikácie); formulácia je striktné previazaná s biomedicínskymi cieľmi; viac pozri v kapitole 4 Testovanie hypotéz.

Príklad 3 (biologická formulácia hypotézy) *Hypotéza: 50 až 69-ročná žena s anamnézou koronárnej choroby srdca, ktorá užíva tablety s rybím olejom, má nižšie riziko výskytu opakovaného infarktu myokardu oproti tým ženám rovnakého veku, ktoré tieto tablety neužívajú.*

Okrem anotácie (téz) a protokolu štúdie musí každá štúdia obsahovať aj tzv. **operačný manuál**, čo je zhrnutie špecifických inštrukcií, dotazníkov a iných častí vytvorených na zaistenie uniformného a štandardného prístupu a postupu v priebehu celej štúdie s dobrou kontrolou jej kvality.

Plán vedeckej štúdie vychádza z jednej či viacerých pracovných hypotéz, ktorých východiskom sú aktuálne poznatky o skúmanej téme a jej širokom ukotvení v rámci daného odboru, resp. vedeckej paradigmy, t.j. teórie. Každá hypotéza preto vychádza z teórie prijímanej určitou časťou vedeckej komunity a zameriava sa na rozvinutie/naplnenie teórie v oblastiach dosiaľ neznámych a dosiaľ nezodpovedaných otázok. Hypotéza by mala byť navrhnutá tak, aby bolo v podmienkach reálneho výskumu možné urobiť platný pokus o jej vyvrátenie. Žiadnu hypotézu nemožno s definitívnou platnosťou potvrdiť (verifikovať) ani akokoľvek vysokým počtom pozitívnych dôkazov, keďže niekedy v budúcnosti môže nastať situácia, keď sa hypotéza nepotvrdí. Naproti tomu s definitívnou istotou môžeme zistiť, že hypotéza neplatí. Novinku a posun v poznatkoch preto predstavujú predovšetkým situácie, v ktorých sa pracovnú hypotézu podarilo vyvrátiť. Hypotézy by teda mali byť navrhnuté tak, aby sa ich prípadným vyvrátením dosiahol postup v sledovanej otázke.

Definícia 2 (metóda) *(Antropometrická) metóda je plánovitý postup, ktorý vedie k vytýčenému cieľu a má okrem iného zaistiť validitu vedeckej štúdie; tento pojem sa používa vo všeobecnejšom zmysle.*

Definícia 3 (validita vedeckej štúdie) *Validita vedeckej štúdie označuje platnosť, správnosť a hodnovernosť vedeckej štúdie, vrátane jej výsledkov a záverov.*

Validitu štúdie možno rozdeliť na niekoľko úrovní (oblastí/typov). **Konstruktívna validita** odkazuje na to, či použitým postupom skutočne sledujeme (meriame) vlastnosť, ktorú merať chceme. **Interná validita** zabezpečuje, že zaznamenaný rozdiel je skutočne spôsobený sledovaným faktorom. Inými slovami, že zaznamenaná súvislosť je skutočne spôsobená nami predpokladaným kauzálnym vzťahom. **Externá validita** sa týka šírky platnosti výsledkov, t.j. či sú výsledky platné nielen pre použitú vzorku, ale aj pre inú vzorku na inom mieste a v inom čase atď. **Validita štatistických záverov** zaisťuje, že zistený (väčšinou číselný) rozdiel je skutočným systematickým rozdielom a nielen náhodne spôsobenou výchyľkou. Použitá metóda by mala zaistiť validitu výskumu na všetkých štyroch úrovniach. Zabezpečiť to je nevyhnutnou súčasťou správne navrhnutej a uskutočnenej štúdie.

Definícia 4 (metodika) *Metodika predstavuje konkrétny návod, algoritmus realizácie použitej metódy.*

Príkladom metodiky je napr. metodika metrického odhadu pohlavia jedinca podľa jeho panvovej kosti.

Definícia 5 (technika) *Technika predstavuje konštrukciu a použitie nástrojov pri výskume.*

1.1 Ciele vedeckej štúdie a sledované premenné

Ciele, účel/účely a hypotézy by mali byť formulované a napísané jasne a zrozumiteľne v netechnickom jazyku. Príkladmi cieľov v klinickej a fyzickej antropológii sú:

- hodnotenie rizikových faktorov, príčin choroby alebo smrti,
- hodnotenie charakteristík, postojov, skúseností alebo správania sa skúmanej skupiny osôb,
- hodnotenie metód prevencie, detegovania alebo liečenia choroby, príp. prevencie predčasnej smrti,
- konanie laboratórnych experimentov na biologických objektoch, zvieratách a pod. s cieľom preskúmať efekty stimulov alebo expozícií (dávok) nejakých látok/liečiv, identifikácie asociácií ako súčasť výskumu liekov a pod.,

- hľadanie vzťahov medzi biologickými premennými, ako napr. hodnotenie genetických a iných biomarkerov asociovaných s chorobou alebo predčasnou smrťou a pod.,
- hodnotenie vplyvu regionálnych, environmentálnych a socio-ekonomických faktorov na telesnú stavbu človeka súčasných alebo minulých populácií,
- hodnotenie vplyvu civilizačných trendov (miera pohybovej aktivity, prevládajúce typy pohybov, množstvo a zloženie potravy) na telesné zloženie, metabolizmus a zdravotný stav človeka,
- antropometrické charakterizovanie súčasných populácií a tvorba referenčných údajov (noriem) a ich aplikácia v ergonómii,
- hľadanie vzťahov medzi biologickými (veľkostnými a tvarovými) a socio-kultúrnymi premennými, napr. sledovanie fyziologických rastových zmien u detí a dospievajúcich, ako aj včasné odhalenie rastových porúch,
- vývin metód aplikovateľných v kriminalistickej a forenznej praxi pri identifikácii jedinca.

Každý cieľ by mal byť opísaný jednou stručnou vetou nezameniteľne s opisom sledovaných závislých premenných, t.j. premenných slúžiacich na opis cieľov. Do štúdie je potrebné zahrnúť realistické a primárne dôležité ciele priamo naviazané na závislé premenné, ktoré by nemali byť príliš komplexné a mali by byť realizovateľné v zmysluplnom časovom horizonte.

Príklad 4 (cieľ vs. závislá premenná) *Príklady cieľov a priamo naviazaných závislých premenných (v podobe „cieľ – závislá premenná“) v klinickej a fyzickej antropológii:*

- zistenie vplyvu statínovej terapie na ľudí bez anamnézy srdcovej choroby – hladina cholesterolu v sére;
- zistenie vplyvu statínovej terapie na ľudí s anamnézou srdcovej choroby – percentuálne zastúpenie ľudí s druhým infarktom myokardu;
- zhodnotenie efektívnosti novej terapie astmy v porovnaní so štandardnou terapiou – percentuálne zastúpenie pacientov, ktorí trpia silnými astmatickými záchvatmi;
- zhodnotenie efektívnosti testu A v porovnaní s testom B v prípade identifikácie ženy čakajúcej dieťa s Downovým syndrómom – percentuálne zastúpenie falošne pozitívnych a falošne negatívnych výsledkov;
- zistenie vzťahu tlaku krvi a veku – systolický/diastolický tlak a vek každého sledovaného subjektu;
- hodnotenie efektu chemoterapie pri liečení nádoru pľúc – čas prežívania pacientov od randomizácie po smrť z rôznych príčin alebo po dátum, kedy bol pacient ešte nažive (prípadne do cenzurujúceho dátumu, t.j. dátumu, kedy bola štúdia ukončená);
- hodnotenie efektu bezpečnej dávky nového lieku na králikoch pred testovaním na ľuďoch – nepriaznivé udalosti (akákoľvek nepriaznivá zmena zdravotného stavu alebo škodlivý účinok zistený napr. krvnými testami);
- zistenie rozdielov medzi ľuďmi trpiacimi schizofréniou, bipolárnou poruchou alebo velokardi- ofaciálnym syndrómom a zdravými ľuďmi – charakteristiky tvaru ľudskej tváre;
- hodnotenie miery pohlavného dimorfizmu vo výške postavy – výška postavy mužov a žien;
- vekové zmeny v množstve a rozložení telesného tuku v oblasti trupu – hodnota WHR;
- zistenie vplyvu laterality na vznik medzistranových rozdielov na hornej končatine – rozmery hornej končatiny.

Rozlišuje sa hlavný cieľ/ciele a vedľajší cieľ/ciele. **Hlavné ciele** a na ne naviazané závislé premenné sa môžu použiť po skončení štúdie ako indikátory zmeny (rutinnej) klinickej praxe, zdravotníckej

politiky, prípadne ako indikátory zvýšenia stavu vedomostí o danej chorobe alebo problematike a pod. **Vedľajšie ciele** často obsahujú doplnkové informácie.

Príklad 5 (hlavný cieľ a vedľajšie ciele) *Hlavný cieľ: hodnotenie efektu nového lieku pri liečení nádoru pľúc vo vzťahu k celkovému prežívaniu. Vedľajšie ciele: (1) hodnotenie efektu nového lieku na zmenšovanie nádoru, (2) sledovanie, či nový liek ovplyvňuje opakovaný výskyt nádoru, (3) zistenie bezpečnosti (toxického profilu) novej liečby, (4) zistenie, či nová liečba pozitívne ovplyvňuje kvalitu života pacienta.*

Výstižne formulované ciele v podobe **vedeckých otázok** možno správne formulovať len vďaka kvalitnému systematickému prehľadu (pozri kapitolu 1.2.2 Systematický prehľad). Vedecká otázka musí mať päť základných **FINER** (*Feasible, Interesting, Novel, Ethical, Relevant*) atribútov, t.j. musí byť:

1. *reálna* – v zmysle dostatočného počtu subjektov, dostatočných odborných znalostí, finančnej prístupnosti a časovej prijateľnosti, a musí poskytnúť odpoveď;
2. *zaujímavá* – mala by v istom zmysle fascinovať vedcov alebo vzbudzovať ich záujem;
3. *nová* – mala by buď potvrdzovať správnosť predošlých poznatkov a rozširovať ich o nové zistenia, alebo dokazovať ich nesprávnosť;
4. *etická* – prístupná k skúmaniu odpovedí po schválení etickou komisiou inštitúcie;
5. *relevantná* – v zmysle vedeckých znalostí pre teóriu a smerovanie výskumu, ako aj aplikáciu poznatkov v praxi (napr. v klinickej praxi, v sociálnej a zdravotnej politike a pod.).

Príklad 6 (ciele v podobe vedeckých otázok) *Mali by ľudia jesť viac rýb? Ako často jedia ľudia istého regiónu ryby? Znižuje jedenie rýb riziko kardiovaskulárnych chorôb? Spôsobuje zvýšená konzumácia rýb u starších ľudí riziko otravy ortuťou? Majú doplnky stravy v podobe rybieho oleja v tabletách rovnaký efekt na kardiovaskulárne choroby ako vlastné ryby? Ktoré typy doplnkov stravy v podobe rybích olejov nespôsobujú, že ľudský pach sa podobá rybaciemu?*

Správne identifikované ciele a na ne naviazané závislé premenné pomáhajú pri rôznych rozhodnutiach týkajúcich sa dát – napr. ako získať potrebné dáta, ako ich štatisticky analyzovať, ako interpretovať výsledky a nakoniec, ako získané výsledky publikovať.

Sledované premenné musia prejsť

- **internou validizáciou (kontrolou kvality)**, t.j. *kontrolou kvality databázy, kontrolou validity merania* a následným *výpočtom reliability merania*, ktorého súčasťou je výpočet
 - **intraindividuálnej chyby** (rozdiel medzi dvoma (alebo viacerými) opakovanými meraniami rovnakého výskumníka na tej istej vzorke),
 - **interindividuálnej chyby** (rozdiel medzi dvoma (alebo viacerými) meraniami dvoch (alebo viacerých) výskumníkov na tej istej vzorke);
- **externou validizáciou**, ktorá predstavuje napr. zlepšenie plánu štúdie, zväčšenie rozsahu náhodného výberu a použitie stratégií zlepšenia **presnosti** aj **správnosti a výstižnosti merania**. Patria sem:
 - stratégie zlepšenia presnosti: (1) štandardizácia meracích metód v operačnom manuáli, (2) školenie výskumníka, (3) nastavenie prístroja alebo zvýšenie jednoznačnosti dotazníka, (4) automatizácia meracieho prístroja alebo vyplnenie dotazníka samotnými subjektmi (respondentmi), (5) opakovanie meraní a následný výpočet priemernej hodnoty merania;
 - stratégie zlepšenia správnosti a výstižnosti merania (navyše k bodom (1) až (4) v stratégiách zlepšenia presnosti): (1) redukcia systematickej chyby napr. kalibráciou prístroja, (2) porovnanie meraní so „zlatým štandardom“, napr. výpočtom senzitivity a špecificity pre dichotomické merania alebo výpočtom koeficientu kappa pre kategorické premenné s viac ako dvojpoložkovou škálou, (3) zaslepenie príslušnosti subjektu do nejakej skupiny (z hľadiska subjektu aj z hľadiska výskumníka).

Definícia 6 (presnosť merania) *Presnosť merania je stupeň, do ktorého má premenná pri viacnásobnom meraní približne rovnakú hodnotu. Presnosť sa najlepšie hodnotí porovnaním opakovaných meraní. Zvyšovaním presnosti merania sa zvyšuje sila štúdie. Presnosť merania najviac ohrozuje náhodná chyba či už na strane výskumníka, alebo subjektu, ale aj chyba meracieho prístroja.*

Definícia 7 (správnosť a výstižnosť merania) *Správnosť a výstižnosť merania je stupeň, do akého premenná reprezentuje to, čo reprezentovať má. Správnosť a výstižnosť merania sa najlepšie hodnotí porovnaním so „zlatým štandardom“. Zvyšovaním správnosti a výstižnosti merania sa zvyšuje validita záverov štúdie. Správnosť a výstižnosť merania najviac ohrozuje systematická chyba či už na strane výskumníka, alebo subjektu, ale tiež meracieho prístroja.*

1.2 Typy vedeckých štúdií

Rozlišujeme dva hlavné typy vedeckých štúdií – experimentálne a observačné. Na zodpovedanie cieľov musí byť použitá vhodnejšia z nich. Oba typy štúdií môžu byť zahrnuté v systematickom prehľade.

Experimentálna vedecká štúdia sú štúdie, v ktorých sú niektoré alebo všetky subjekty experimentálne podrobené zmeneným a kontrolovaným podmienkam prostredia (dávke žiarenia a pod.) alebo liečbe, s ktorými by normálne neprišli do styku. Tu rozlišujeme:

- klinické pokusy na ľuďoch,
- laboratórne experimenty.

Observačné vedecké štúdie sú štúdie, v ktorých sú študované subjekty sledované v ich prirodzených podmienkach bez zámeru do subjektov akokoľvek zasahovať. Rozlišujú sa:

- kvalitatívne štúdie,
- patientsky audit,
- prípadové štúdie,
- prierezové štúdie,
- (retrospektívne) štúdie prípadov a kontrol,
- kohortové (retrospektívne/prospektívne) štúdie, v biologickej antropológii nazývané aj longitudinálne štúdie,
- sekvenčné alebo semilongitudinálne štúdie.

Špeciálnym typom štúdií v antropológii sú **štúdie kostrových pozostatkov** – kostrových sérií, ojedinelých kostrových nálezov, historických osobností, múmií, atď.

Príklad 7 (štyri typy štúdií) *Príklady štyroch základných plánov štúdií skúmajúcich, či príjem rýb v strave redukuje riziko vypuknutia srdcovocievnej choroby.*

Klinická (randomizovaná zaslepená) štúdia: Dve skupiny sú vytvorené náhodným (randomizovaným, znáhodneným) a zaslepeným spôsobom. Výskumník náhodne priradí subjekty do skupiny, ktorá prijíma v strave rybí olej a do skupiny, ktorá prijíma placebo, potom sleduje obe skupiny niekoľko rokov z hľadiska výskytu srdcovocievnych chorôb.

Prierezová štúdia: Subjekty sú hodnotené v jednom časovom bode. Výskumník zaznamená subjektom udávaný príjem rýb v strave v minulosti a v súčasnosti a odpovede dáva do vzťahu s prepuknutím srdcovocievnych chorôb a so súčasným výskytom vápnika v krvi.

Štúdia prípadov a kontrol: Vybraní jedinci sú rozdelení do dvoch skupín na základe výskytu ochorenia (závislá premenná). Výskumník hodnotí skupinu pacientov so srdcovocievnyimi chorobami (prípady) a porovnáva ju so skupinou bez srdcovocievnych chorôb (kontroly) pýtajúc sa na minulý príjem rýb v strave.

Kohortová štúdia: Subjekty sú sledované v čase. Výskumník zaznamenáva príjem rýb v strave na začiatku štúdie a následne príjem rýb opakovane zaznamenáva počas niekoľkých návštev zisťujúc, či sa u jedincov konzumujúcich viac rýb vyskytovalo menej srdcovo-cievnych chorôb.

Systematický prehľad (zahŕňajúci **meta-analýzu**) je štúdia, ktorej cieľom je identifikovať všetky publikované a nepublikované štúdie v príslušnej oblasti, ako aj kombinovať a interpretovať ich výsledky. Tento typ štúdie sa najčastejšie používa pri klinických pokusoch, kohortových štúdiách a štúdiách prípadov a kontrol.

Špeciálnym typom štúdie je tzv. **translačná štúdia**, ktorá predstavuje premostenie medzi laboratórnym výskumom a klinickou štúdiou (ozn. ako **T1**), alebo klinickou štúdiou a praxou (ozn. ako **T2**).

Väčšinu štúdií realizovaných v antropológii predstavujú štúdie observačné. Experimentálny výskum ovplyvňujúci biologické procesy u zdravých ľudí podlieha schváleniu etickej komise a je takmer celkom obmedzený na oblasť klinických štúdií (hlavne to platí pre invazívne vyšetrenia s narušením integrity tela, užívaním testovaných liečiv atď.). Laboratórne experimenty na ľuďoch, dobrovoľníkoch sú však možné v psychológii, behaviorálnych a kognitívnych vedách, pokiaľ nepredstavujú pre dobrovoľníkov zdravotné alebo iné riziká. Možné sú aj napr. tafonomické alebo biomechanické experimenty s kostnými a zubnými tkanivami.

1.2.1 Observačné štúdie vo fyzickej a klinickej antropológii

Observačná štúdia je taká štúdia, v ktorej sa študované subjekty sledujú v ich prirodzených podmienkach a dáta sa získavajú z nemocničných alebo ambulantných záznamov, regionálnych alebo národných registrov (napr. register pacientov s cystickou fibrózou, register operácií bedrového a kolenného kĺbu a pod.), z dotazníkov alebo interview s ľuďmi, z databáz RTG snímok alebo CT skenov. Pri zbere dát je dôležité dbať na presnosť a komplexnosť záznamov, pričom treba rozlišovať, či informácie pochádzajú zo záznamov vyplňaných samotným pacientom alebo vyšetrujúcim lekárom, či pochádzajú z lekárskeho záznamu alebo z priamej diagnózy klinickým expertom, či boli merania vykonané študentom v zácviaku alebo skúseným antropológom.

Kvalitatívne štúdie majú zvyčajne málo subjektov (menej ako 50) a sú založené na pozorovaní alebo interview s kladením otázok otvoreného typu. Môžu slúžiť na vývin dizajnu ďalšej štúdie, vývin meracích prostriedkov v podobe dotazníka alebo na zistenie názoru na zdravotnú starostlivosť, príj. liečbu.

Audit pacientov predstavuje extrakciu údajov z minulosti z už existujúcich záznamov pacientov v nemocniciach, slúži na zistenie zámkrov, rizikových faktorov choroby alebo predčasnej smrti. Tu treba mať na zreteli výberovú odchýlku.

Prípadové štúdie, nazývané aj *prípadové správy* sú popisné či iné štúdie, v ktorých je vzorka obmedzená na jeden alebo niekoľko zaujímavých alebo niečím významných prípadov nejakého javu. Dôvodom môže byť ich neexistencia (súčasny výskyt) vo väčšom počte (napr. veľmi vzácna choroba) alebo ťažké štúdium vo väčšom počte (eticke obmedzenie, finančné nároky, ap.). Príkladom môže byť *paleopatologická štúdia jedného skeletu s výskytom početných prejavov nejakej choroby na rôznych kostiach* (napr. syfilis). Tiež však môže ísť o *zámernú výskumnú stratégiu*, kedy na rozdiel od relatívne povrchného štúdia jedného alebo niekoľkých znakov u veľkého počtu prípadov (čo je bežná populačná štúdia, niekedy označovaná ako *cross-case study* a predstavujúca väčšinu štúdií citovaných a popísaných v tejto knihe) študujeme na jednom alebo niekoľkých prípadoch veľké množstvo znakov a súvislostí s cieľom pochopenia komplexity ich vzťahov a ich vnútornej organizácie. Vlastná štúdia nespočíva v sledovaní štatistického rozdielu medzi skupinami alebo súvislostí medzi premennými, ale v detailnom, mnohostrannom popise študovaných prípadov a (bio)logickom vysvetlení povahy javu vo všetkých rozlíšených rovinách/uhloch pohľadu. Existujú tiež metódy, ktorými možno kombinovať výsledky viacerých prípadových štúdií. V širšom slova zmysle možno za prípadovú štúdiu považovať

súčasť alebo prípravu bežnej populačnej štúdie. Napríklad v longitudinálnej štúdií rastu najskôr vytvoríme rastové krivky pre každé dieťa (t.j. tolko jednotlivých prípadových štúdií, koľko máme longitudinálne zaznamenaných detí) a potom štatisticky hodnotíme závislosti parametrov rastových kriviek na nejakom faktore v populačnej štúdií. Pre rozdelenie typov prípadových štúdií a ich dizajn pozri napr. Gerring (2007). Špeciálnym prípadom prípadovej štúdie je aj štúdia porovnania prípadu so starostlivo zvolenou *referenčnou populáciou* (Šefčáková a Katina, 2008; Šefčáková a kol., 2011).

Prierezové štúdie, niekedy nazývané aj *prevalenčné*, sa používajú v prípadoch prieskumu, monitorovania alebo dohľadu. Svoje pomenovanie dostali na základe toho, že vybrané subjekty predstavujú prierez populáciou alebo jej časťou na danom mieste a čase v kontexte skúmaného javu. Používajú sa napr. na zistenie vzťahu rizikových faktorov a chorôb. Údaje možno získavať z lekárskeho vyšetrenia. Často sa využíva validovaný dotazník alebo dotazník špecificky vytvorený pre danú štúdiu (vývoj tohto dotazníka musí byť presne dokumentovaný a dotazník musí byť validovaný). Základnou úlohou je nájsť rozdiely v *prevalencii* medzi exponovanou a kontrolnou (referenčnou) skupinou. Takáto štúdia informuje o prevalencii v určitom čase. Stanovenie expozícií a meranie osobných charakteristík alebo biologických markerov môže byť *prospektívne* na základe budúcich výskumov alebo *retrospektívne* na základe už existujúcich záznamov. V týchto štúdiách ide o *reprezentatívny výber*, čo umožňuje odhadovať pravdepodobnosť výskytu choroby alebo vystavenie sa expozícií v celej populácii a následne testovať isté hypotézy. Overuje sa napr., či pravdepodobnosť výskytu choroby závisí od expozície. V praxi sú časté náhodné výbery veľkého rozsahu a predmetom záujmu je vzťah vybraných faktorov s expozíciou alebo chorobou.

Prevalenčné štúdie často slúžia na porovnanie prevalence choroby na rôznych miestach alebo u rôznych populačných skupín vzhľadom na expozíciu. Tieto štúdie môžu skúmať napr. rozdiely v prevalencii respiračných problémov v rôznych skupinách populácie (u ľudí s rôznou expozíciou), môžu sledovať chronické stavy, napr. artritídu, diabetes, hypertenziu, peptický vred, srdcovocievne choroby a mozgové príhody, alebo tiež študovať hygienu práce pri expozícii chemikáliám, prachu a plynom, príp. koncentrácie rôznych látok na pracoviskách (napr. ortute) a pod. Prevalenčné štúdie môžeme využiť pri overovaní prvých pracovných hypotéz ako východisko pre kohortové štúdie. Nie sú vhodné na sledovanie akútneho účinku nových chemikálií a iných škodlivín, ktoré vyžaduje aj kohortovú štúdiu.

V biologickej antropológii predstavujú jeden z najčastejších typov výskumu živého človeka prierezové štúdie, ktoré sa uplatňujú pri zisťovaní výskytu či miery prejavu akéhokoľvek biologického znaku/javu v ľudských populáciách. Uskutočňujú sa u detí aj dospelých. V prípade ľudí rôzneho veku sa získavajú rozdiely medzi vekovými kategóriami, z ktorých možno vytvárať *nepravé rastové krivky* (nemožno ich zamieňať za *pravé rastové krivky* vytvorené na základe longitudinálnych dát). Ak sa na základe prierezovej štúdie hodnotia vekové rozdiely (detí alebo dospelých), vnútorná validita štúdie môže byť ohrozená tým, že vekové skupiny sa môžu líšiť v mnohých iných vlastnostiach nesúvisiacich s vekom, ktoré vyplývajú z rozdielov medzi generáciami. Tento jav sa označuje ako *efekt kohorty*.

Príklad 8 (efekt kohorty; znižovanie výšky postavy s vekom) *V prierezovej štúdií zaznamenaný rozdiel vo výške postavy medzi dvadsaťročnými a osemdesiatročnými ľuďmi bol spôsobený efektom kohorty v populácii, ktorá prekonala sekulárnu zmenu vo výške postavy. Pred šesťdesiatimi rokmi ľudia dosahovali pri ukončení rastu postavy do výšky nižšieho veku (Cardoso, 2008) než dnešní dvadsaťroční ľudia a túto výšku postavy si potom niesli životom ako kohorta. To však neznamená, že v priebehu starnutia nedochádza k menším degeneratívnym zmenám kostí a kĺbov a úbytku výšky, väčšia časť rozdielov je však daná rozdielmi medzi generáciami (Eveleth a Tanner, 1990, s. 208–223).*

Priemerná výška postavy v danej kohorte sa v priebehu starnutia môže meniť pod vplyvom selekcie, ktorá nie je neutrálna voči výške postavy. V každej vekovej kategórii totiž mortalita klesá s výškou postavy. Vyššieho veku sa teda dožíva väčší podiel jedincov s vyššou než s nižšou postavou (Waalder, 1984).

Príklad 9 (efekt kohorty; vekové rozdiely v inteligencii (IQ)) *V minulosti viedol efekt kohorty k nadhodnoteným predstavám o znižovaní inteligencie v priebehu starnutia (Schaie, 2000).*

Prierezová štúdiá použitá na porovnanie vekových skupín neumožňujú zachytenie vnútornej štruktúry vekových zmien. Nedovoľuje napríklad odpovedať na otázku, či majú ľudia vo veku dvoch rokov s telesnou výškou na 10. percentile aj v desiatom roku stále výšku odpovedajúcu 10. percentilu populácie.

Štúdie prípadov a kontrol sa zvyčajne používajú na zistenie rizikových faktorov choroby alebo predčasnej smrti. Sledujú sa subjekty, napr. pacienti a k nim prislúchajúce kontroly, retrospektívne alebo prospektívne.

Do **retrospektívnych štúdií prípadov a kontrol** sa vyberajú pacienti (chorí) a k nim zdraví jedinci. Pozerajú sa späť do minulosti v určitom časovom intervale a porovnávajú sa napr. početnosti neexponovaných a exponovaných pacientov pomocou premenných charakterizujúcich napr. životný štýl, zvyky alebo takých premenných, ako biochemické alebo genetické markery. Cieľom je nájsť premenné (rizikové faktory), ktoré pomôžu vysvetliť, prečo prípady dostali chorobu a kontroly nie. Ďalej tiež zistiť, či expozícia súvisí s chorobou. Rozsahy skupín chorých a zdravých jedincov nemusia odrážať ich rozdelenie v populácii. Keďže tradičným cieľom týchto štúdií je zistiť prítomnosť alebo neprítomnosť choroby, prípady sú zvyčajne chorí. Avšak prípadmi môžu byť aj pacienti s nejakým druhom postihnutia a kontroly pacienti bez tohoto postihnutia.

Príklad 10 (retrospektívna štúdiá prípadov a kontrol) *Vyberajú sa deti postihnuté a nepostihnuté kongenitálnymi malformáciami. Sledujeme, či matky mali alebo nemali rubeolu počas tehotenstva (Hackshaw, 2009).*

Príklad 11 (retrospektívna štúdiá prípadov a kontrol) *Vzťah fajčenia a pľúcnych nádorov. Výskum sa realizoval v 20 nemocniciach v Londýne na 709 subjektoch rovnakého pohlavia s diagnostikovaným pľúcny nádorom, ktoré boli zoskupené v 5-ročných vekových intervaloch, a im vekovo odpovedajúcich 709 subjektoch toho istého pohlavia bez nádorového ochorenia. Fajčiar sa definoval ako osoba, ktorá vyfajčila v ostatnom roku aspoň jednu cigaretu denne. Ide o retrospektívny dizajn, v ktorom nepoznáme prevalenciu pľúcnych nádorov v populácii.*

Zriedkavé sú **prospektívne štúdie prípadov a kontrol**, kde sa prípady a kontroly sledujú v budúcnosti.

Príklad 12 (prospektívne štúdie prípadov a kontrol) *Štúdia chrípky ako dôvodu akútneho infarktu myokardu (AIM; MacIntyre a kol., 2013), kde prípadmi boli hospitalizovaní pacienti s AIM a kontrolami ambulantní pacienti bez AIM v Sydney (Austrália) v časovom období rokov 2008 až 2010.*

Okrem klasických štúdií prípadov a kontrol existujú aj tzv. **vnorené štúdie prípadov a kontrol**, kde sa prípady a spárované kontroly vyberajú z kohortovej štúdie (pozri nižšie). Tieto štúdie sa špeciálne vyskytujú pri registroch chorôb, kedy sú prípady reprezentatívnou vzorkou populácie a reprezentatívne kontroly sa k nim získavajú z tej istej populácie.

Príklad 13 (vnorené štúdie prípadov a kontrol) *Štúdia úlohy infekcie dolných dýchacích ciest u pacientov liečených antibiotikami, ktorí znovu navštívili lekára v priebehu štyroch týždňov po poslednej návšteve, na ktorej im boli predpísané antibiotiká (Macfarlane a kol., 1997). Prípadmi boli pacienti, ktorí znovu navštívili lekára s rovnakými symptómami. Kontrolami boli pacienti, ktorí lekára znovu v priebehu štyroch týždňov už nenavštívili.*

Kohortové štúdie sledujú subjekty nejakej kohorty⁴, retrospektívne alebo prospektívne.

⁴Slovo *kohorta* pochádza z latinského *cohors* (útvár bojovníkov s počtom 1/10 rímskej légie, ktorí boli súčasne nasadení do boja), ale dnes sa používa na opísanie určitej skupiny ľudí, ktorú sledujeme v danom časovom intervale.

Do **retrospektívnej kohortovej štúdie** sa vyberajú subjekty, ktorých základné merania (ako aj sledovanie) prebehli v minulosti, teda už existujú, a my ich vyhľadávame v lekárskych alebo archívnych záznamoch, regionálnych alebo národných databázach.

Do **prospektívnej kohortovej štúdie** (nazývanej aj *longitudinálna* v antropológii alebo *incidenčná* v medicíne) sa vyberajú subjekty, ktorých základné merania prebehnú v budúcnosti. Subjekty sa potom sledujú istý čas *longitudinálne* (niekoľko rokov) a početnosti tých, u ktorých sa vyvinie skúmaná choroba sa porovnávajú medzi neexponovanými a exponovanými nejakému faktoru, pričom možno zisťovať *incidenciu* choroby, príp. *remisiu* (dočasné vymiznutie prejavov choroby) alebo *relaps* (opakovaný výskyt prejavov choroby). V rastovej antropológii (auxológii človeka) sa longitudinálne štúdie využívajú predovšetkým na zisťovanie vývinových a rastových zmien u detí a dospelujúcich (Bogin, 1999).

Príklad 14 (longitudinálne štúdie v ČR) *V Brne sa realizovali dve rozsiahle longitudinálne štúdie. Prvou z nich bola Brněnská růstová studie, ktorú viedla docentka Marie Bouchalová (Bouchalová, 1987). Druhú reprezentuje zapojenie do Evropské dlouhodobé studie těhotenství a dětství (ELSPAC), ktorej českú časť vedie docent Lubomír Kukla (Kukla, 2008).*

V longitudinálnych štúdiách sa sledujú zmeny v priebehu času na tej istej vzorke. Každá skúmaná osoba sa sleduje minimálne dvakrát za sebou s určitým časovým odstupom (hovoríme o *párovom dizajne*). Longitudinálna štúdia umožňuje sledovať skutočné zmeny a vytvárať pravé rastové krivky, vrátane *individuálnych rastových kriviek*. Umožňuje tiež sledovať vnútornú štruktúru časových (tu vekových) zmien. Jej nevýhodou je časová náročnosť, znižovanie vzorky (po čase skúmané osoby strácajú záujem pokračovať v štúdiu) a *riziko metodologickej nekonzistencie* (zmena metód, prístrojov, výskumníkov, spoločenských cieľov alebo dokonca etického rozmeru študovaného problému). Ohrozenie vnútornej validity štúdie spočíva vo vplyve histórie a celospoločenských zmien, ktoré ovplyvňujú celú populáciu. V longitudinálnej štúdiu však túto zmenu zaznamenáme ako zmenu s vekom osôb sledovanej vekovej kohorty.

Príklad 15 (vplyv histórie a celospoločenských zmien v longitudinálnej štúdiu) *V longitudinálnej štúdiu sa v nedávnej histórii západnej civilizácie zaznamenalo zníženie počtu fajčiarov cigariet medzi 30. až 50. rokom života. Toto zníženie však nemusí byť len dôsledkom zákonitých systematických zmien v prístupe ľudí ku svojmu zdraviu v priebehu dospelosti a starnutia (stále zodpovednejšie, resp. opatrnejšie chovanie), ale môže byť aj dôsledkom celospoločenských zmien prebiehajúcich synchronne so starnutím ľudí sledovanej kohorty (stále väčší dôraz spoločnosti na zdravý životný štýl, resp. politický tlak na obmedzovanie fajčenia, ekonomické zmeny relatívne zvyšujúce cenu a znižujúce dostupnosť tabakových výrobkov a pod.). Bez prierezovej kontroly týchto faktorov nie je možné rozhodnúť, ktorý z nich má na sledovaný jav podstatnejší vplyv. Vzhľadom na to, že z prierezových demografických štúdiách vyplýva (Sovínová a kol., 2012), že v mladších vekových kategóriách bolo percentuálne zastúpenie fajčiarov v roku 2011 takmer rovnaké ako v roku 1999 a zníženie bolo tak v roku 1999 ako aj v roku 2011 jasne zreteľné až vo vyššej vekovej kategórii (55–64 rokov), pravdepodobnejšie vysvetlenie pre uvedené obdobie sú skutočne individuálne zmeny súvisiace s vekom (zdravotné komplikácie alebo finančné problémy vo vyššom veku). Vo väčšom časovom rozsahu (napr. medzi 50. rokmi 20. storočia a začiatkom 21. storočia) však väčší vplyv môžu mať spoločenské zmeny postoja k fajčeniu.*

Porovnanie štúdií prípadov a kontrol a kohortových štúdií. Vo všeobecnosti sa považujú kohortové štúdie za reliabilnejšie než štúdie prípadov a kontrol, pretože „*spomienková*“ (napr. ľudia so sledovanou chorobou si na zvyky v minulosti spomínajú lepšie než ľudia bez tejto choroby) a *selekčná výchyľka* ich ovplyvňujú v menšej miere. Kohortové štúdie však zvyčajne trvajú niekoľko rokov, čo spôsobuje, že sú finančne často náročné. Štúdie prípadov a kontrol sú vhodnejšie, ak je študovaná choroba zriedkavá alebo trvanie výskumu z nejakého dôvodu časovo obmedzené, pretože v zmysluplnom časovom horizonte umožňujú získať väčší počet subjektov. Kohortové štúdie sa využívajú v prípadoch častejšie sa vyskytujúcich chorôb (s výskytom nad 10 % prípadov), kým štúdie prípadov a kontrol sa využívajú pri štúdiu príčin vzácnejšie sa vyskytujúcich chorôb (s výskytom pod 10 %). Na minimalizáciu rôznych druhov výchyľiek (napr. „*spomienkovej*“, selektnej, informačnej výchyľky merania

alebo výchyľky spôsobenej chýbajúcimi pozorovaniami) sa hodia rôzne typy štúdií, takže je potrebné zahrnúť otázku výchyľky do plánu štúdie.

Výber medzi kohortovou štúdiou a štúdiou prípadov a kontrol závisí napr. na zložitosti získania subjektov (napr. zriedkavo sa vyskytujúce choroby a pod.), ovplyvniteľnosti výsledkov výchyľkou a mäťúcimi premennými, finančnom zabezpečení a trvaní štúdie.

Kohortová štúdia a štúdia prípadov a kontrol sa líšia aj použitým **efektom sledovaného rizika**. Pri kohortovej štúdii je to zvyčajne relatívne riziko a pri štúdii prípadov a kontrol pomer šancí.

Definícia 8 (mäťúce premenné) *Mäťúce premenné definujeme ako cudzie premenné, ktorých prítomnosť ovplyvňuje študované premené, takže výsledky nereflektujú aktuálny vzťah medzi závislou a nezávislou premennou.*

Mäťúce premenné možno povoliť pri dizajne štúdií prípadov a kontrol, kde sú prípady párované s kontrolami, ale nie pri kohortových štúdiách, lebo by nežiaduco ovplyvnili štatistické modely počas štatistických analýz. Plán štúdie musí obsahovať zdôvodnenie voľby prípadných mäťúcich premenných a možnosť kvantifikácie ich vplyvu nejakou štandardnou, presnou a komplexnou cestou (napr. uvedenie etnicity, presné zaznamenanie množstva skonzumovaného alkoholu).

Napokon je potrebné zdôrazniť, že incidenciu alebo riziko výskytu ochorenia možno zistiť z kohortových štúdií, ale nie zo štúdií prípadov a kontrol.

Definícia 9 (štatistiky frekvencie) *Frekvencia (počet, početnosť) v užšom slova zmysle vyjadruje počet nejakých udalostí (prípadov), kým v širšom slova zmysle vyjadruje početnosť výskytu nejakého znaku (pozri kapitolu 1.3.7 Triedenie dát). Incidencia vyjadruje počet nových prípadov s daným znakom v populácii za jednotku času. Prevalencia označuje celkový výskyt (počet) žijúcich jedincov s daným znakom v populácii teraz alebo kedykoľvek v minulosti. Abundancia vyjadruje početnosť prípadov (napr. v ekológii počet jedincov daného živočíšneho druhu na danej lokalite).*

Tabuľka 1.1: Štatistiky frekvencie vs. typ štúdie (# znamená počet)

typ štúdie	štatistika	definícia
kohortová	incidencia	$\frac{\# \text{subjektov, ktorí dostali chorobu}}{\# \text{subjektov v riziku} \times \text{čas v riziku}}$
	kumulatívna incidencia	$\frac{\# \text{subjektov, ktorí dostali chorobu}}{\# \text{subjektov v riziku}}$
prierezová	prevalencia	$\frac{\# \text{subjektov, ktorí majú chorobu}}{\# \text{subjektov v riziku}}$
	kumulatívna prevalencia	$\frac{\# \text{subjektov, ktorí kedykoľvek nadobudli chorobu}}{\# \text{subjektov v riziku}}$

Všetky štyri štatistiky frekvencie sa používajú v absolútnej škále (počet, početnosť) alebo v relatívnej škále (škálované počtom subjektov v súbore). Je potrebné si uvedomiť, že hodnoty incidence sú ovplyvnené časovými jednotkami. Definícia štatistik frekvencie závisí aj na type štúdie (pozri tabuľku 1.1). **Sekvenčné alebo semilongitudinálne štúdie** predstavujú kombináciu prierezovej a longitudinálnej štúdie, ktorá kombinuje výhody a súčasne obmedzuje ohrozenie vnútornej validity výskumu oboch prístupov. Prebieha kratší čas než štúdia longitudinálna a zatiaľ čo prierezová zložka umožňuje kontrolu vplyvu histórie, longitudinálna zložka umožňuje kontrolu efektu kohorty.

Plán observačnej štúdie. Najdôležitejšími prvkami observačnej štúdie, ktoré musia byť zahrnuté v jej pláne, sú:

- v prípade študovaných subjektov (skúmaných osôb, účastníkov výskumu)
 - **výberové schéma**, t.j. špecifikácia miesta, odkiaľ budú subjekty pochádzať, v štúdii prípadov a kontrol špeciálne kontroly (z populácie, pacientov nemocnice alebo z príbuzných prípadov);
 - **selekčné kritériá, kritériá vhodnosti** alebo **zoznam prijímacích a vylučovacích kritérií** – prijímacie kritériá musia byť presné a podrobné (presná špecifikácia populácie relevantnej na riešenie vedeckej otázky a presná špecifikácia vhodnosti štúdie, napr. *demografické charakteristiky* ako pohlavie a vek, *klinické charakteristiky* ako dobré všeobecné zdravie a stály sexuálny partner, *časové charakteristiky* ako časový interval zberu dát a pod.), vylučovacie kritériá musia byť úsporné (špecifikácia subjektov, ktoré nebudú študované pre vysoké riziko straty zo sledovania, pre nemožnosť zabezpečiť kvalitné dáta, napr. v dôsledku jazykovej bariéry, pre vysoké riziko škodlivých/vedľajších/nepriaznivých účinkov, napr. v dôsledku prekonaného infarktu myokardu alebo mozgovej príhody);

- **typ náhodného výberu**, t.j. selekcia z výberovej schémy;
- jasná **definícia prípadov a kontrol** (v štúdií prípadov a kontrol);
- **párovacie kritéria a faktory**, t.j. ako budú kontroly párované s prípadmi (v štúdií prípadov a kontrol);
- v prípade náboru subjektov a ich sledovania
 - **časový interval** použitý na identifikáciu subjektov;
 - **dĺžka náboru a sledovania v budúcnosti** (v kohortových štúdiách);
 - **dĺžka sledovania do minulosti** t.j. ako hlboko do minulosti budú pacienti sledovaní v súvislosti s detailami ich životného štýlu alebo zvykov (v štúdií prípadov a kontrol);
- v prípade zberu dát a vyšetrení
 - **details zberu dát**, t.j. interview, typ dotazníkov (samovyplňovacie alebo vyplňované niekým iným), dáta z patientskych záznamov, dáta z regionálnych alebo národných databáz a pod.;
 - **details vyšetrení**, t.j. typ vyšetrenia, napr. klinické vyšetrenie, snímkovanie (RTG, CT sken, MRI sken, 2D fotografia tváre, 3D laserová snímka, 3D stereofotogrametrická snímka, snímka z elektrónového mikroskopu a pod.), krvný test, odber moču, slín a pod.; kto vykoná vyšetrenia, frekvencia vyšetrení;
 - **spôsob skladovania biologického materiálu** (krv, moč, sliny) v rámci danej štúdie alebo z hľadiska jeho ďalšieho využitia a analýz v budúcich štúdiách;
 - **spôsob merania mäťúcich premenných/faktorov**;
 - **spôsob minimalizácie výchyľiek** rôzneho typu, napr. „spomienkovej“, selekčnej, informačnej výchyľky, výchyľky merania alebo výchyľky spôsobenej chýbajúcimi pozorovaniami;
 - **spôsob určenia diagnózy**.

Párovacie kritériá v štúdií prípadov a kontrol. Častým nedostatkom protokolu je nedostatočný opis párovania prípadov a kontrol. Pojem párovanie sa navyše často používa veľmi nepresne. Mal by indikovať pojem **spárovaná dvojica**, čo však nemusí byť zámerom výskumníka alebo plánovaného štatistického prístupu. Návrh, v ktorom sú subjekty párované na základe pohlavia, etnicity, veku alebo BMI, je nepresný (v spojitosti s realitou) a v praxi nerealizovateľný. Výskumník by mal zabezpečiť, aby sledované skupiny boli **vyvážené** v závislosti od sledovaných charakteristík, t.j. ide o **frekvenčné párovanie**. Pre spojité premenné (ako napr. vek) je potrebné špecifikovať rozsah, ktorý charakterizuje toto párovanie spolu s priemerom a smerodajnou odchýlkou. Vyhnúť sa treba párovaniu pomocou mäťúcich premenných, ktorých vzťah ku závislej premennej nie je dostatočne preskúmaný.

Definícia 10 (párovanie do dvojíc) *Párovanie do dvojíc je výber kontroly pre každý prípad tak, aby obe mali rovnakú hodnotu mäťúcej premennej. Ak je medzi skupinami štatisticky významný rozdiel v premenných, ktoré charakterizujú párovanie, je potrebné ich vplyv odpočítať pomocou vhodného štatistického modelu. Toto je jednoznačne úlohou bioštatistika.*

Príklad 16 (štatistické hľadisko párovania do dvojíc) *Majme párovanie do dvojíc pomocou premenných pohlavie a vek. Keďže párovanie prípadov bolo vykonané v rámci rodiny, kde kontroly boli rodinní príslušníci rôzneho veku a pohlavia (rodičia, súrodenci a pod.), je potrebné použiť štatistický model odstraňujúci negatívny efekt párovania, ktorý vplyv veku a pohlavia eliminuje.*

Definícia 11 (frekvenčné párovanie) *Frekvenčné párovanie je taký výber kontrol ku prípadom, v ktorom sú mäťúce premenné v oboch skupinách zo štatistického hľadiska identické.*

Definícia 12 (štatistické hľadisko frekvenčného párovania) *Zo štatistického hľadiska nesmie byť štatisticky významný rozdiel medzi tými premennými, ktoré charakterizujú frekvenčné párovanie.*

Výberová schéma musí byť jednoznačne definovaná a musí zahŕňať tzv. *kritériá vhodnosti*, hlavne v podobe vekových ohraničení (napr. zahrnutie starších ľudí do štúdie a zdôvodnenie rozhodnutia).

Príklad 17 (kritériá vhodnosti) *Ak je cieľom štúdie hľadanie vzťahu (asociácie) medzi fajčením a nádorom pľúc, potom prijímacími kritériami sú napr. vek 18–80 rokov, nefajčiari a fajčiari schopní doručiť informovaný súhlas a vylučovacími kritériami sú napr. súdoba liečenia alebo jedinci s anamnézou nádoru, vystavení nejakým látkam alebo situáciám, ktoré sú známe svojou asociáciou s vysokým rizikom vzniku nádoru.*

Príklad 18 (výberová schéma – prierezová štúdia) *Štúdia a ciele: prierezová štúdia odhadu prevalencie konzumácie alkoholu a fajčenia medzi študentmi antropológie. Výberová schéma: register všetkých študentov antropológie univerzity. Typ výberu: všetci študenti v registri.*

Príklad 19 (výberová schéma – štúdia prípadov a kontrol) *Štúdia a ciele: štúdia prípadov a kontrol na hodnotenie asociácie medzi vrodenými poruchami a fajčením počas tehotenstva. Výberová schéma: prípady – deti s vrodenou poruchou vybrané z národného registra vrodených porúch, kontroly – deti bez vrodenej poruchy vybrané z registra pôrodov vo vybranom geografickom regióne. Typ výberu: prípady – všetky deti s vrodenou poruchou z národného registra narodené medzi rokmi 2000 a 2010, kontroly – náhodný výber detí bez vrodenej poruchy narodené medzi rokmi 2000 a 2010 so spárovaným vekom matky a rokom narodenia dieťaťa.*

Príklad 20 (výberová schéma – kohortová štúdia) *Štúdia a ciele: kohortová štúdia hodnotenia asociácie medzi cvičením a rizikom vzniku srdcovocievnej choroby. Výberová schéma: všetci pacienti starší ako 40 rokov registrovaní na klinike v príslušnom geografickom regióne. Typ výberu: náhodný výber 5000 pacientov.*

1.2.2 Systematický prehľad

Úvod každej štúdie v podstate predstavuje krátky (cielený) systematický prehľad témy, ktorá súvisí so študovanou problematikou. Tento prehľad akumuluje vedomosti v sledovanej oblasti na základe už publikovaných a nepublikovaných výsledkov, ktorých závery sa syntetizujú (kombinujú) do všeobecnejšej podoby. Efekty každej štúdie sa kvantitatívne kombinujú pomocou štatistických metód, ktoré súborne nazývame **meta-analýza**. Základom takejto štúdie je identifikácia publikovanej a nepublikovanej literatúry v sledovanej tematike. Kumulácia vedomostí môže mať tieto dôsledky:

- **Potvrdenie doterajšej praxe** získaním presnejšieho odhadu efektu alebo rizikového faktora a následne častejšie používanie v praxi a pod. Keďže kombinovaná analýza má vyšší rozsah výberu, sila použitého testu v rámci nejakého štatistického modelu bude vyššia. Pomôže to aj vyhnúť sa neistote prípadného falošného výsledku v individuálnej analýze.
- **Zmena doterajších praktík**, čo v praxi vedie napr. k zmene typu liečby, k zmene názoru na nejakú vedeckú problematiku, k identifikácii nového rizikového faktora vedúceho k vzniku ochorenia alebo k predčasnej smrti (na základe observačných štúdií), ďalej k zmene doterajšej štandardnej klinickej praxe, alebo môže viesť k vývinu novej zdravotnej politiky a pod.

Problémom systematického prehľadu pri observačných štúdiách môže byť kombinácia individuálnych výchyliek a mätúcich premenných štúdií zahrnutých do meta-analýzy. To môže viesť ku falošným záverom alebo asociáciám, ktoré sa zdajú byť presnejšie (napr. získaním užšieho intervalu spoľahlivosti). V klinických pokusoch možno tieto výchylky účinne kontrolovať.

Existujú dva typy meta-analýzy

1. **meta-analýza na základe sumárnych výsledkov** získaných z výsledkov publikovaných a nepublikovaných individuálnych štúdií;
2. **meta-analýza na základe originálnych (pôvodných) dát** získaných od autorov individuálnych štúdií; v medicínskom výskume sa nazýva aj *meta-analýza dát od individuálnych pacientov*.

Meta-analýza sa v súčasnosti uplatňuje predovšetkým v psychológii, sociológii a v biomedicínskom výskume. Vzhľadom na komparatívnu a syntetickú povahu antropológie je meta-analýza žiaducou metódou aj v tomto odbore. Napriek tomu sa však meta-analýza v antropológii doteraz príliš neuplatnila (príklady meta-analytických štúdií v antropológii možno nájsť v práci Russella Bernarda 2006, s. 107–108) a na svoj väčší rozvoj ešte len čaká.

Príklad 21 (dôležitosť meta-analýzy) *Dôležitosť meta-analýzy pri formulovaní hypotéz v antropológii demonštruje výsledok štúdie Whitea (White, 1980, cit. Russell Bernard, 2006, s. 108), v ktorej na základe stovky publikovaných štúdií autor zistil, že sociálny status zodpovedá iba za 6.3 % celkového rozptylu v školskom prospechu študentov. Autor tiež zistil, že pôvodné korelácie naprieč štúdiami kolísali od hodnoty -0.14 po hodnotu $+0.97$. Tento rozsah kolísania demonštruje nutnosť kontroly ďalších faktorov, ktoré môžu prospech ovplyvňovať.*

1.2.3 Štúdie kostrových pozostatkov

Zvláštnym typom súborov/vzoriek v antropológii sú súbory kostrových pozostatkov, tzv. kostrové série. Podľa charakteru výberu a kontextových informácií ich možno rozdeliť na niekoľko skupín. Ich spoločnou vlastnosťou je fakt, že obsahujú kosti zomretých ľudí⁵. Vzorky pozostávajúce z nájdených kostrových pozostatkov sa značne odlišujú od vzoriek vytvorených na základe definovaného výberu ľudí zo živej populácie. Tieto súbory totiž nevznikajú štandardnými postupmi výberu vzorky z populácie, ale pod vplyvom rôznych, väčšinou nekontrolovaných (často nekontrolovateľných) faktorov.

Prvým typom sú **dokumentované antropológické zbierky**⁶, ktoré obsahujú relatívne kompletne skelety a údaje o hlavných biologických znakoch jedincov (dožitý vek, pohlavie, a i.). Tieto zbierky majú veľký význam pri tvorbe antropológických metód odhadujúcich telesné znaky zo skeletov z archeologických nálezov. Jednotlivé dokumentované zbierky sa však líšia spôsobom výberu vzorky a rozsahom kontextových dát. Jednu podskupinu predstavujú **anatomické zbierky** vytvorené na základe kostí jedincov z anatomických pitiev, druhou sú **forenzné zbierky** (väčšinou menšieho rozsahu), treťou sú **zbierky z exhumácií pochovaných tiel** a štvrtou sú zväčša nedostupné **zbierky kostrových pozostatkov dokumentovaných obetí vojnových konfliktov**. Novo vznikajú aj **zámerne vytvárané „pohrebiská“**⁷, zložené z hrobov dobrovoľníkov, ktorí ešte za života odkázali svoje telo po smrti vede. Rozdiely v selekcii vzoriek sa premietajú do parametrov súborov. Kým anatomické zbierky bývajú zo sociálneho či zdravotného hľadiska *selektívne, neselektívne* exhumácie dokumentovaných hrobov z rozsiahlejších bežných civilných cintorínov predstavujú pravdepodobne najprirodzenejšie kostrové súbory (hoci aj tieto môžu byť selektívne zo sociálneho hľadiska).

Druhým typom sú **kostrové súbory z archeologických výskumov**, na základe ktorých kostrová antropológia (humánna osteológia, bioarcheológia, historická antropológia) študuje život minulých populácií. Získanie týchto súborov je dnes väčšinou viazané na záchranné archeologické výskumy obmedzeného rozsahu. Preto sa v nich výrazne prejavuje *neúplnosť dát* v miere danej stavom zachovalosti a kompletnosti kostí/skeletov (závisiacej na geologických a pôdnych podmienkach danej lokality, na rozdieloch v odolnosti skeletu rôznych jedincov – deti vs. dospelí, ženy vs. muži – voči tafonomickému vplyvom, na pohrebnom ríte, na exkavačnej a rekonštrukčnej metodike a i.), rozsahom pohrebisk, pomerom rozsahu výskumu a rozsahu pohrebiska (možnosť lokálnych nehomogéností v zložení hrobov na pohrebiskách) a dostupných kontextových údajov a ich (ne)úplnosti (napr. rozdiely v pohrebnom ríte a hrovej výbave, znalosť väzby na sídlisko atď.). Extrémnym prípadom sú **súbory kremácií**, v ktorých sú kosti poškodené žiarom (príp. aj rozbité zámerne v súvislosti s pohrebným rítom) a extrémne fragmentárne. V prípade takýchto sérií nemožno určiť ani základné biologické kategórie.

Okrem obmedzenej reprezentatívnosti a celistvosti dát získaných z kostrových súborov sa s výskumom minulých populácií spájajú ďalšie okolnosti, ktoré sa označujú ako **osteologický paradox** (Wood a kol., 1992). Tento jav možno sledovať v troch problémových oblastiach, ktoré sprevádzajú archeologické kostrové súbory:

1. **demografická nestabilita** – výskyt a proporcie výskytu skeletov na pohrebiskách závisia od demografických zmien v danej populácii, napr. vyšší výskyt detských skeletov môže znamenať väčšiu

⁵Výnimkou sú série založené na záznamoch z neinvazívnych zobrazovacích metód. Tam však ide o nenáhodnosť a selektivnosť iného druhu – pacientov.

⁶Pozri napr. <http://skeletal.highfantastical.com>.

⁷Jantzova zbierka v Tennessee (WM Bass Donated Skeletal Collection): <http://fac.utk.edu/collection.html>.

detskú mortalitu v demograficky stabilnej populácii alebo napr. nižšiu detskú mortalitu a vyššiu natalitu v demograficky rastúcej populácii;

2. **selektívna mortalita** – k dispozícii sú iba skelety ľudí, ktorí zomreli, nikdy ale nemáme prístup k ľuďom, ktorí boli v danej vekovej kategórii rizikom ohrození, ale prežili; rôzne vekové kategórie v archeologických kostrových súboroch sú potom zložené z pozostatkov ľudí odlišných biologických vlastností;
3. **stratená heterogenita rizík** – v nájdených kostrových súboroch sa vyskytuje zmes ľudí líšiacich sa nielen príčinou smrti, ale aj citlivosťou na rizikové faktory (napr. choroby, úrazy a pod.); bez poznania príčin smrti je ťažké vytvoriť relevantné biologické kategórie vzájomne si podobných jedincov a následne študovať napríklad rozdiely v pôsobení genetických a sociálnych faktorov atď.

Celkovo sú archeologické súbory v rôznej miere **nereprezentatívne**, zaťažené mnohými neznámymi tendenciami, takže nemusia spĺňať nároky štatistických metód na charakter vstupných dát (napr. náhodné vzorkovanie, normalita rozdelenia). Uvedené okolnosti výrazne limitujú možnosti štatistických porovnávaní a testov a predovšetkým interpretácií, ktoré z nich vyplývajú. Pri hodnotení archeologických kostrových súborov preto treba – podľa možnosti – do použitého modelu zakomponovať predstavu o demografických procesoch v danej populácii, ako aj o environmentálnych, socio-ekonomických, socio-kultúrnych a zdravotných podmienkach. To kladie ešte väčšie nároky na spoluprácu antropológa a štatistika od samého počiatku príprav výskumu.

1.3 Štatistické hľadiská plánovania štúdií

Zo štatistického hľadiska sa treba pri plánovaní pokusov zamerať na typ výberu, rozsah náhodného výberu, na metódy zberu dát a spôsoby merania, na hlavné atribúty dát a ich triedenie. Každému z týchto okruhov bude venovaná pozornosť v nasledovných kapitolách.

1.3.1 Typy výberov

Štatistický (základný) súbor je konečná množina prvkov (napr. osôb, jedincov, subjektov), na ktorých sledujeme určité znaky, veličiny, vlastnosti a pod. Ak uskutočnime nejaký výber zo štatistického súboru, hovoríme o **výberovom súbore**, ktorý reprezentuje štatistický súbor výberom určitého počtu štatistických jednotiek. **Štatistické jednotky** tvoria napr. subjekty, respondenti dotazníka, pričom po uskutočnení výberu hovoríme o **výberových jednotkách**. Na základe výberových jednotiek vo výberovom súbore si vytvárame predstavu o štatistických jednotkách v základnom súbore. Kvalita tejto predstavy v podobe nejakého štatistického modelu alebo modelu rozdelenia pravdepodobnosti striktné závisí od správnosti zvoleného typu výberu.

Príklad 22 (náhodný výber vs. zovšeobecnenie na populáciu) Často nemôžeme z rôznych príčin sledovať celú populáciu. Nemôžeme napr. do výskumu zaradiť všetky tehotné ženy alebo všetky osoby žijúce v skúmanej geografickej oblasti. Ak je našim cieľom napr. zisťovať vzťah prírastku hmotnosti ženy počas tehotenstva a hmotnosti novorodenca, môžeme údaje zistiť len od určitej vzorky (výberu) tehotných žien. Získané výsledky sa následne zovšeobecňujú na všetky tehotné ženy. Kvalita zovšeobecnenia pritom priamo závisí od kvality výberu.

Definícia 13 (zovšeobecnenia záverov štúdie) Na základe *aktuálnych/použitých subjektov v aktuálnom/realizovanom výbere* formulujeme závery štúdie pre použité subjekty [zistenia v štúdiu], potom zovšeobecníme závery na *zamýšľanú populáciu* napr. na populáciu dospelých vo veľkých slovenských mestách (*inferencia na základe internej validity*) [pravdivosť štúdie], potom na *dosiahnuteľnú populáciu* napr. na populáciu dospelých vo všetkých slovenských mestách (*inferencia na základe externej validity*), a nakoniec na *cieľovú populáciu* – napr. dospelých vo všetkých slovenských mestách a dedinách [všeobecná pravdivosť]. Menej spoľahlivým záverom by bolo napr. zovšeobecnenie na dospelých a deti, na ľudí v iných krajinách a pod. (Hulley a kol., 2007).

Interná validita je vlastnosť vedeckej štúdie, ktorá reflektuje mieru/rozsah zaručenosti kauzálnych záverov vedeckej štúdie. Externá validita je validita zovšeobecenej (kauzálnej) štatistickej inferencie (vedeckej štúdie) alebo miera zovšeobecnenia na iné (všeobecnejšie, v istom zmysle hierarchicky nadradené) situácie.

Medzi základné typy výberov patria (1) náhodný výber, (2) selektívny výber, (3) zámerný výber, (4) výber typu snehovej gule a (5) výber typu vhodnosti (komfortu) a príležitosti. Prvému typu výberu hovoríme aj **pravdepodobnostný výber**, ostatné patria do skupiny **nepravdepodobnostných výberov**.

Náhodný výber je výber, v ktorom vyberanie štatistických jednotiek z populácie prebieha celkom náhodne a nezávisle na našom úsudku (Bland, 2009). Rozlišujeme nasledovné typy náhodných výberov:

1. **Jednoduchý náhodný výber** je priamy výber štatistických jednotiek, pričom každá má rovnakú pravdepodobnosť, že bude vybraná (napr. *generovanie pseudo-náhodných čísel* alebo *žrebovanie*, pričom je výhodné, keď sú štatistické jednotky očíslované a je možné použiť matematickú teóriu náhodných čísel).
2. **Mechanický (systematický) výber** je založený na určitom (dopredu stanovenom) usporiadaní prvkov populácie a spočíva vo výbere tých prvkov (subjektov), ktoré sú vzájomne vzdialené o zvolený výberový krok. Prvý prvok (subjekt) vyberieme *jednoduchým náhodným výberom*. Pri tomto výbere musíme dať pozor, aby usporiadanie prvkov (subjektov) nesúviselo so sledovaným znakom.
3. **Oblastný (stratifikovaný) výber**. Základný súbor je rozdelený na oblasti podľa určitého hľadiska. Oblasti sú vytvorené tak, aby boli *vnútorne homogénne* (v sledovaných znakoch sa vnútri oblasti príliš neodlišujú) a *medzi sebou heterogénne* (v sledovaných znakoch sa môžu, ale nemusia odlišovať). V jednotlivých oblastiach sa uskutoční *jednoduchý náhodný výber* alebo *mechanický výber*. Percento vybraných jednotiek môže byť buď vo všetkých oblastiach rovnaké, alebo medzi oblasťami odlišné (napr. z ekonomických dôvodov musíme vybrať menší počet jednotiek, výber jednotiek je náročný; navyše percento vybraných jednotiek môže reprezentovať prirodzené rozdelenie sledovanej premennej v populácii). Konečný výberový súbor vytvoríme spojením všetkých oblastí.
4. **Skupinový výber**. Pokiaľ je štatistický (základný) súbor pomerne rozsiahly (stotisíce alebo milióny osôb), dá sa jednoduchý náhodný výber uskutočniť veľmi ťažko; najprv sa náhodne vyberú *skupiny (agregáty) jednotiek* (nie jednotlivé jednotky), ktoré tvoria buď prirodzené alebo umelé agregáty. Je žiaduce, aby boli jednotlivé agregáty, pokiaľ je to možné, rovnako veľké a vnútri každej skupiny *heterogénne*. Variabilita medzi skupinami musí byť čo najmenšia, t.j. blízka *homogénnej* (opačne než pri oblastnom výbere). Pri tomto výbere rozlišujeme dve možnosti.
 - *Výber všetkých jednotiek v agregáte.*
 - *Dvojstupňový a viacstupňový výber.* Je založený na hierarchickom opise prvkov základného súboru, ku ktorým sa dostávame postupne cez vyššie výberové jednotky. Každá výberová jednotka je skupinou výberových jednotiek nižšieho rádu, kde rozlišujeme *jednotky prvého stupňa (primárne jednotky)*, potom *jednotky druhého stupňa (sekundárne jednotky)* atď., až nakoniec máme *základné jednotky* štatistického súboru. Postupné výbery prebiehajú často *jednoduchým náhodným výberom*, ale použiť sa môže aj *mechanický* alebo *oblastný výber*.

Príklad 23 (kartotéka pacientov) Z abecedne usporiadanej kartotéky (databázy) pacientov u praktického lekára vyberáme s krokom 10 a prvú kartu vyžrebujeme (napr. deviatu kartu), takže výber bude tvorený pacientmi, ktorých karty boli uložené v poradí 9, 19, 29, 39, 49 atď.

Príklad 24 (zamestnanie pacientov) Zisťujeme zamestnanie pacientov vedených v stomatologickej ambulancii. Pacienti prichádzajú do ambulancie v určitom časovom slede, ktorému zodpovedá usporiadanie ich zdravotných záznamov. Výber s krokom rovným dennému počtu pacientov (za predpokladu, že do ambulancie príde každý deň rovnaký počet pacientov) vedie k značne selektívnemu výberu tých pacientov, ktorí prichádzajú v určitú časť dňa, čo môže súvisieť s typom ich zamestnania.

Príklad 25 (oblasti) *Ak robíme výber obyvateľov Slovenskej alebo Českej republiky, oblasťami sú územné celky, vekové skupiny alebo socioekonomický status.*

Príklad 26 (hierarchia) *Vyššie výberové jednotky → prvky základného súboru = mestá – bloky – domy – domácnosti, okresy – podniky – dielne – zamestnanci.*

Príklad 27 (agregát) *Agregát môže byť malý – rodina, škola, podnik, zdravotný obvod, ale i väčší – obec, okres.*

Selektívny výber je výber, v ktorom vybraná vzorka nepokrýva požadovanú cieľovú vzorku, čo dáva skreslený obraz o študovanej populácii.

Príklad 28 *Vzorka 15 až 16-ročných chlapcov, prvotligových basketbalistov, z ktorej by sme chcelirobiť inferenciu o výške chlapcov tohto veku v celej slovenskej populácii.*

Zámerný výber je výber, v ktorom o výbere jednotky rozhodujú okrem náhody častokrát nekontrolovateľné činitele (subjektívny názor vyberajúceho, ochota, resp. neochota odpovedať na kladené otázky a pod.). Všeobecne sa tvrdí, že tento typ výberu sa opiera o „expertné“ stanovisko a rôzne „odhady“ ako získať reprezentatívny výber. Takto získané výberové súbory sú často ovplyvnené subjektívnym pohľadom „experta“, ale aj ďalšími faktormi ovplyvňujúcimi tvorbu výberu a presnosť zovšeobecňujúcich záverov sa skôr opiera o „expertný“ pohľad než o metodológiu.

Výber typu snehovej gule predstavuje typ nenáhodného výberu subjektov, v ktorom práve hodnotené subjekty odporučia alebo privedú ďalšie subjekty z radov svojich známych (Russell Bernard, 2006, s. 192–194). Tento (rovnako ako aj iné typy nenáhodného výberu subjektov) je predmetom kritiky, jeho výsledkom je však vzorka zložená z ľudí tvoriacich prirodzenú sieť sociálne prepojených osôb. To má význam pri vytváraní vzorky u skrytých populácií. Ide o osoby riedko rozmiestnené na veľkom území, osoby sociálne stigmatizované (napr. osoby HIV pozitívne) alebo osoby zámerne sa skrývajúce (napr. narkomani, zločinci a pod.). Interpretácia výsledkov musí vždy vychádzať z charakteru vzorky, ktorý je daný typom vzorkovania (výberu).

Výber typu vhodnosti (komfortu) a príležitosti predstavuje typ nenáhodného výberu subjektov, v ktorom vyberáme subjekty ochotné a ľahšie dostupné (Walker a Almond, 2010). Najčastejšie sa tento typ výberu používa v pilotných štúdiách a v prieskumoch verejnej mienky. Tento výber je selektívny, preto je veľmi dôležité zozbierať aj demografické dáta, ktoré môžu poukazovať na výberové výchyľky.

Príklad 29 (dobrovoľníci vo výbere) *Dobrovoľníkov by sme nemali považovať za prvky náhodného výberu. Ak by meranie prebiehalo napr. kolektívne počas telocviku, ako dobrovoľníci by sa mohli prihlásiť iba ľudia, ktorí nemajú problém so svojou telesnou hmotnosťou. Vo vzorke by tak chýbali jedinci obézní alebo anorektickí, ktorí sa meraniu vyhli z obavy pred sociálnou kritikou vyplývajúcou zo zistených hodnôt. Pri zachovaní dobrovoľnosti i s meraním v intimitate mimo zrak ostatných je potrebné s týmto počítať. Výskum preto musí obsahovať presnú definíciu prijímacích a vylučovacích kritérií.*

Pri realizácii uvedených štatistických výberov dochádza k dvom druhom chýb.

1. **Chyby reprezentatívnosti** sú rozdiely v hodnotách charakteristík základného a výberového súboru, ktoré sú zapríčinené tým, že sa skúma iba časť základného súboru. Ak bol výberový súbor vytvorený korektne, tak rozdiely v charakteristikách základného a výberového súboru predstavujú *náhodné chyby*.
2. **Chyby registrácie** sú rozdiely medzi presnými hodnotami znaku u vybraných jednotiek a zaregistrovanými hodnotami⁸.

⁸Chyba merania nie je chybou registrácie (pozri kapitolu 1.3.3 Hlavné atribúty dát).

1.3.2 Náhodný výber v realite antropologického výskumu

Ideálny náhodný výber, zodpovedajúci vyššie uvedenej definícii, je v reálnych podmienkach antropologického výskumu (ľubovoľného zamerania či materiálu) skôr výnimkou než normou. Zriedka totiž máme k dispozícii všetkých jedincov danej populácie (tj. celú populáciu), z ktorej náhodne vyberáme študovanú vzorku (pozri kapitolu 1.3.1 Typy výberov). V štúdiách živého človeka väčšinou ide o **štúdie na dobrovoľníkoch**. Závisí od charakteru skúmaného javu a použitej metodiky, do akej miery bude dobrovoľná účasť v štúdiu meniť charakter výberu oproti náhodnému. Nenáhodnosť môžeme obmedziť z hľadiska geografického pôvodu – napr. v geograficky stratifikovanom výbere, kde ide o výber dobrovoľníkov proporcionálny ku množstvu jedincov potrebných charakteristík v danej geografickej oblasti. Dáta štatisticky analyzujeme tak, akoby o náhodný výber šlo. Zovšeobecnenia na celú populáciu sú však problematické.

Výnimkou môžu byť v antropológii iba **štúdie kompletných dát** (databáza tohto typu má charakter **registra**), t.j. štúdie celej populácie určitej geografickej oblasti, kedy nemáme k dispozícii vzorku, ale všetky prípady daného charakteru (napr. všetkých novorodencov v danej spádovej oblasti za dané obdobie).

V **kostrových súboroch** (pozri kapitolu 1.2.3 Štúdie kostrových pozostatkov, komentár k osteologickému paradoxu) nemožno väčšinou náhodný výber zaručiť, a to ani v prípade dokumentovaných kostrových súborov. Pri kostrových súboroch z pohrebiska dáta štatisticky analyzujeme tak, akoby o náhodný výber šlo. Pritom predpokladáme, že množstvo rôznych náhodných a vzájomne nesúvisiacich a často protichodných faktorov (aj keď samostatne nenáhodných) v rôznych obdobiach a na rôznych hierarchických úrovniach spôsobí, že výsledná vzorka sa blíži náhodnému výberu z populácie. Nemusí tomu tak však byť, lebo synergické pôsobenie niekoľkých významnejších faktorov môže spôsobiť systematický posun aj napriek ich náhodnosti. Napr. mladé dospelé ženy s maskulinnejšími kostami panvy môžu hypoteticky byť v kostrovej sérii zomrelých dospelých žien nadhodnotenú už v čase úmrtia (z dôvodu problémov pri pôrode), tafonomické procesy potom môžu túto nerovnováhu ešte zosilniť (skelety väčších, maskulinnejších žien se lepšie zachovávajú). Výsledkom môže byť nižší sexuálny dimorfizmus v danej sérii oproti realnej situácii v danej populácii za života.

1.3.3 Hlavné atribúty dát

Štatistické spracovanie dát vyžaduje získanie kvalitných dát, a to už v terénnej fáze výskumu. Kvalitné dáta spájajú nasledovné atribúty:

1. **Objektivita.** Pod objektivitou informácií rozumieme vlastnosť pravdivo odrážať alebo zachytávať skúmané javy resp. ich znaky. Postup skúmania je objektívny vtedy, keď získané fakty podávajú verný obraz o skúmanom jave. Objektivitu zabezpečí taký postup, ktorý hodnoty znaku určí jednoznačne, takže výsledky nie sú závislé od osoby vyhodnocovateľa.
2. **Reliabilita (spoľahlivosť).** Výskumná metóda je reliabilná vtedy, keď zisťuje (meria) tak, že pri opätovnom použití tejto metódy na rovnakých dátach (aj pri zisťovaní rôznymi výskumníkmi) za inak rovnakých podmienok dostaneme v podstate tie isté výsledky.
3. **Validita (platnosť).** Je zabezpečená vtedy, keď otázky v dotazníku alebo miery na lebke a pod. zisťujú a merajú tie vlastnosti, ktoré skutočne chceme zisťovať.
4. **Reprezentatívnosť.** Pri niektorých typoch štúdií je potrebné zabezpečiť, aby dáta tvorili reprezentatívnu vzorku, teda vzorku, ktorá odráža skutočné rozdelenie znaku v populácii, napr. vekové, podľa pohlavia alebo sociálneho statusu a pod. Reprezentatívnosť môže znamenať aj rovnomerné zastúpenie alebo komplexnosť v zastúpení nejakých skupín z populácie. Interpretácia tohto pojmu závisí aj od typu štúdie.

1.3.4 Metódy zberu dát

Medzi metódy zberu dát patria (1) observačné metódy, (2) rozhovor/dotazník a (3) dokumentácia.

Observačné metódy predstavujú priame pozorovanie, antropologické merania, klinické, biochemické alebo mikrobiologické vyšetrenia a pod. Spôsoby merania lineárnych, oblúkových, obvodových

a uhlových rozmerov v *klasickej (tradičnej) morfometrii* sú previazané s chybami merania. Na meranie sa používajú tieto nástroje (Katina a kol., 2011; Hrdlička, 1920, 1939/1952; Martin, 1914/1928; Martin a Saller, 1957–1966; Knussmann, 1988; Fetter, 1967; Preedy, 2012):

- *pomocné nástroje* – kraniofor (na nastavenie a upevnenie lebky orientovanej vo frankfurtskej horizontále), kovové ihlice (na nastavenie príslušných priamok na lebke),
- *meracie nástroje* – dotykové meradlo (kefalometer, na meranie lineárnych rozmerov, napr. M1 = dĺžka lebky), posuvné meradlo (na meranie lineárnych rozmerov, napr. M52 = výška očnice), koordinátové (hlbkové) meradlo (na meranie projekčných mier a hĺbok na lebke, napr. M20 = nadušná bregmatická výška), uhlomer (na meranie uhlov, napr. M73 = uhol profilu nosa), mandibulometer (na meranie rozmerov sánky, napr. M68 = dĺžka sánky), pásové meradlo (na meranie oblúkových a obvodových mier, napr. M27 = mediálny parietálny oblúk alebo M23 = horizontálny obvod lebky cez glabellu); antropometer (na meranie výšky postavy a telesných proporcií), dynamometer (na meranie sily stisku), bioimpedančná váha (na stanovenie hmotnosti a telesného zloženia), kaliper na meranie kožných rias (na stanovenie obsahu telesného tuku).

Príklad 30 (príklady skupín meraní) Merania môžeme zaradiť do nasledovných skupín

Lekárska anamnéza: údaje o diagnóze, liečení, operáciách, symptómoch.

Psychosociálne faktory: rodinná anamnéza, depresia.

Antropometrické premenné: dĺžkové, šírkové, obvodové, objemové miery, uhly, indexy.

Biochemické markery/premenné: cholesterol v sére, fibrinogén v plazme.

Genetické/molekulárne testy: jednoduchý nukleotidový polymorfizmus, typ ľudského leukocytového antigénu.

Obrazový materiál: hustota kosti, vápnik v krvi.

Elektromechanický materiál: arytmia, kongenitálna srdcová choroba a pod.

Rozhovor a dotazník zhromažďujú údaje pomocou zámerné kladených otázok. Získané údaje môžu byť skreslené nepochopením otázok, ich nejednoznačnosťou, zlou formuláciou, zlým záznamom odpovedí a pri rozhovore aj vplyvom sociálnej interakcie. Medzi najpoužívanejšie techniky patrí **metóda štandardizovaného rozhovoru pomocou dotazníka** realizovaná školenými anketármi, koordinátormi. Pri tvorbe dotazníka je potrebné vytvoriť na meranie zisťovaných javov vhodné škály reprezentované predpísanými odpoveďami v otázkach. Základné typy škál sú (1) *nominálna (neusporiadaná)*, (2) *ordinálna (usporiadaná)* a (3) *kvantitatívna (numerická)*. Škála znaku musí byť zvolená tak, aby dobre rozdeľovala znak do kategórií. Nemá napr. zmysel zaradiť do dotazníka takú otázku, na ktorú je možná jediná odpoveď. Otázky v dotazníku delíme na *zatvorené* (je možné vybrať si jednu z predvoleného konečného počtu odpovedí) a *otvorené* (odpoveď je potrebné napísať slovné a rozsah slov nie je ohraničený). Špecifickú skupinu tvoria *otázky s viacerými možnosťami odpovede*, ktoré však nie sú štatistickým znakom v zmysle definície – *štatistický znak je jednoznačná transformácia* ($R \Rightarrow O$, kde R označuje množinu respondentov a O označuje množinu odpovedí na danú otázku). Pri ich spracovaní treba využiť špecifické techniky, takže vhodnejšie je vyhnúť sa v dotazníku tomuto typu otázok. Z definície štatistického znaku, ako jednoznačnej transformácie, dostávame **základné štatistické požiadavky**, ktoré je potrebné rešpektovať *pri konštrukcii škál otázok* dotazníka:

- *jednoznačnosť* – zaručuje disjunktný rozklad množiny objektov, t.j. jeden objekt nemôže mať priradenú viac než jednu hodnotu daného znaku;
- *úplnosť* – zaručuje zahrnutie všetkých možných hodnôt, t.j. škála znaku (otázky) musí byť konštruovaná tak, aby zahŕňala všetky možnosti;
- *nezávislosť* – pri všetkých podmienkach musí platiť rovnaká škála (ráno a večer, v Prahe, ako aj v Bratislave) v rámci daného výskumu.

Všetky tri body platia nielen pre škály otázok dotazníka, ale aj všeobecne pre akýkoľvek spôsob získavania dát, t.j. nie je možné mať dve alternatívne namerané hodnoty pre jeden objekt, nesmie sa stať, že nejaký objekt nebude možné zmerať a za všetkých podmienok je potrebné na rovnakom objekte namerať to isté (t.j. akákoľvek metóda získavania dát musí byť *vyčerpávajúca, exkluzívna a nezávislá*).

Príklad 31 (úplná vs. neúplná škála) *Majme znak „vzdelanie“ s kategóriami – základné, stredoškolské bez maturity, stredoškolské s maturitou a vysokoškolské. Ak by sme v dotazníku vynechali čo i len jeden variant, nemáme úplnú škálu.*

Formálna úprava dotazníka musí byť prehľadná, aby sa minimalizovali chyby pri kódovaní, ako aj pri ich zázname do PC. Okrem takejto úpravy musí dotazník obsahovať *identifikačné znaky*, ktoré sú pomocou pri kontrolách, t.j. číslo dotazníka či číslo koordinátora. Okrem meritorých znakov (otázok) musí dotazník obsahovať patričné demografické znaky podľa skúmanej témy, napr.

- *kraj*
 - Slovenská republika: Bratislavský kraj, Trnavský kraj, Trenčiansky kraj, Nitriansky kraj, Žilinský kraj, Banskobystrický kraj, Prešovský kraj, Košický kraj;
 - Česká republika: Stredočeský kraj, Jihočeský kraj, Plzeňský kraj, Karlovarský kraj, Ústecký kraj, Liberecký kraj, Královéhradecký kraj, Pardubický kraj, Vysočina, Jihomoravský kraj, Olomoucký kraj, Moravskoslezský kraj, Zlínský kraj, Hlavní město Praha;
- *veľkostná skupina obce* – zaužívaná kategorizácia: do 1999 obyvateľov (1), 2000–9999 (2), 10000–49999 (3), 50000–99999 (4), nad 100000 (5);
- *okresy* – vhodne kódované číslami (1, 2, ..., k) alebo jednoduchými skratkami ich názvov; podľa potreby možno kategorizáciu usporiadať podľa rozlohy okresu alebo počtu obyvateľov.

Ďalšie demografické ukazovatele možno prípadne doplniť podľa potreby.

V prípade, že kategórie znaku majú malú početnosť, zlučujú sa podľa logiky problému. V dotazníku sa môžu vyskytnúť otázky, na ktoré neodpovedajú všetci respondenti. Takýmto prípadom sa treba striktne vyhýbať, lebo spracovanie takýchto otázok vnáša do štatistickej analýzy určité problémy, ktorým možno predchádzať úplným vyplnením dotazníka⁹. Vhodné je v jednotlivých otázkach zachytávať jedno hľadisko, pretože pri kombinácii viacerých hľadísk sa musia tieto kombinácie variantov znakov „násobiť“.

Príklad 32 (úplná škála) *Ovplyvnila alebo neovplyvnila prebiehajúca verejná diskusia o vstupe štátu XX do inštitúcie YY Váš postoj k ZZ?*

- 1) *ovplyvnila, nechcel som sa ho zúčastniť, ale zúčastním sa ho;*
- 2) *ovplyvnila, chcel som sa ho zúčastniť, ale nezúčastním sa ho;*
- 3) *neovplyvnila, chcel som sa ho zúčastniť a zúčastním sa ho;*
- 4) *neovplyvnila, nechcel som sa ho zúčastniť a nezúčastním sa ho;*
- 5) *neviem posúdiť.*

Príklad 33 (úplná škála) *Očakávate zmenu v YY?*

- 1) *určite áno;*
- 2) *asi áno;*
- 3) *neviem;*
- 4) *asi nie;*
- 5) *určite nie.*

Príklad 34 (úplná škála) *Podporujete vstup XX do YY?*

- 1) *vstup som podporoval/a a podporujem ho aj naďalej;*
- 2) *vstup som podporoval/a, ale teraz ho nepodporujem;*
- 3) *vstup som nepodporoval/a, ale teraz ho podporujem;*
- 4) *vstup som nepodporoval/a a naďalej ho nepodporujem.*

⁹Neúplne vyplnený dotazník predstavuje z hľadiska reprezentatívnosti dát rovnakú situáciu ako úplné odmietnutie účasti jedinca v štúdiu (t.j. jedinca sa nestane dobrovoľníkom).

Niekedy môže byť výhodné dva alebo viac znakov kombinovať do jedného bez straty informácie, napr. dve otázky do jednej.

Príklad 35 (kombinácia znakov) Znak XA nadobúda hodnoty 0 (v úrade nemajú PC) a 1 (v úrade majú PC), znak XB (vek PC) je X rokov; je možné kombinovať do jednej otázky XX , kde kód 0 znamená, že PC nemajú a ostatné odpovede sú už len nominálne, teda vek PC. Takto sa redukuje počet otázok (premenných) a eliminujú sa chýbajúce dáta.

V kvantitatívnom výskume je potrebné vyhýbať sa všetkým typom **otvorených otázok**, ako *otvoreným* otázkam so stručnou odpoveďou, tak aj *otvoreným* otázkam so širokou odpoveďou. Najvýhodnejšími typmi otázok z pohľadu ďalšieho matematicko-štatistického spracovania sú *otázky dichotomické (binárne)*, *otázky prirad'ovacie* (či už prirad'ujeme do usporiadanej alebo neusporiadanej kategorizácie) a *otázky s numerickou odpoveďou*. Všetky takéto vhodné otázky môžeme zahrnúť pod jeden pojem **uzavreté otázky**. Treba ich formulovať *stručne, jasne, zrozumiteľne, úplne a jednoznačne*. Navrhovať treba *navzájom nezávislé otázky* (porovnaj s príkladom 35), čo znamená, že odpoveď na nasledujúcu otázku by nemala závisieť od odpovede na predchádzajúcu otázku.

Dokumentácia je jednoduchý a často jediný spôsob ako získať informácie z minulosti. V lekárskom výskume (alebo aj v klinickej antropológii) rozoznávame tri typy dokumentácie, a to

1. **pôvodná zdravotnícka dokumentácia** (ako je záznam o zdraví a chorobe („karta“), hlásenie o narodení dieťaťa alebo list o prehládke mŕtveho);
2. **údaje rutinnej zdravotníckej štatistiky a rutinných štatistík iných odvetví**, napr. demografie, poisťovníctva, ekonomiky, geografie a meteorológie (*údaje o zdravotnom stave obyvateľstva* – o celkovej chorobnosti, chorobnosti sporej s pracovnou neschopnosťou, príčinách úmrtia a príčinách invalidity, ako aj *o zdravotníckych službách* – o sieti zdravotníckych zariadení, pracovníkoch v zdravotníctve, zdravotníckych školách o lekárskech a farmaceutických fakultách);
3. **historická dokumentácia**, napr. cirkevné matriky; uplatňuje sa v biologickej antropológii a príbuzných odboroch (napr. behaviorálne-ekologické štúdie v rámci teórie životnej histórie); umožňujú sledovať zaznamenané udalosti z celého života ľudí aj v niekoľkých po sebe idúcich generáciách.

1.3.5 Zisťovanie presnosti merania

Na zistenie spoľahlivosti nameraných dát je vhodné, a v odborných prácach dnes už nevyhnutné, číselne charakterizovať **presnosť merania** (napr. Goto a Mascie-Taylor, 2007). Výsledky merania sú vždy ovplyvnené kombináciou systematických a náhodných chýb merania. **Systematické chyby** spôsobené meraním môžeme rozdeliť na tieto skupiny (Katina a kol., 2011):

1. **chyby spôsobené externými/environmentálnymi faktormi** – denná doba, intenzita svetla, vlhkosť prostredia a oblečenie;
2. **chyby prístroja** – presnosť merania prístroja;
3. **chyby merania** – chyby z odlišnej aplikácie techniky merania (rôzne pochopenie definície meranej miery), intraindividuálna a interindividuálna chyba (iné držanie prístroja, iný tlak aplikovaný pri meraní, iná orientácia lebky pri meraní a pod.);
4. **kalibrácie meracieho prístroja** (často sa používa aj anglický pojem *zero error*), napr. MicroScribe G2, kde je potrebné opakovane kalibrovať prístroj na tri fixne stanovené landmarky pri otočení tej istej lebky a pod.

Zmiešaním chýb (1) až (4) vzniká tzv. **kombinovaná systematická chyba**, ktorú nie je možné objektívne hodnotiť. Problematické tiež je, keď sa kombinujú miery (na výpočet indexov, ako aj v štatistických výpočtoch) merané inými meracími prístrojmi s rôznou presnosťou merania (zvyčajne od zlomku milimetra do troch milimetrov). Pri meraniach všeobecne môžeme hovoriť aj o **náhodnej**

chybe¹⁰ (šume), ktorá je dôsledkom nesprávneho náhodného výberu. Pri antropologických meraniach na historických populáciách však ide o špecifický problém, lebo pri výskume kostrových sérií sa merajú všetky nájdené lebky. Keďže tento druh výberu nie je možné ovplyvniť, nedá sa hovoriť o náhodnom výbere v pravom slova zmysle. Výber je potom ovplyvnený len dostatočnou zachovanosťou lebiek a veľkosťou kostrovej série, ktorá nemusí dostatočne reprezentovať populáciu žijúcu v danom čase a priestore.

Obidva typy chýb, systematické ako aj náhodné, sa vo výsledkoch kombinujú. Pokiaľ meranie nie je dostatočne presné, náhodný šum výrazne ovplyvňuje možnosť zachytenia štatisticky významného rozdielu. Autor tak čitateľovi dáva vedieť, že napríklad medzi populáciami nie je v strednej hodnote sledovaného znaku rozdiel, aj keď v skutočnosti medzi nimi rozdiel je. Čitateľ je tak uvedený do omylu, pretože nie je možné odlíšiť túto situáciu od situácie skutočnej zhody medzi dvoma strednými hodnotami, v dôsledku čoho svoj ďalší výskum orientuje nesprávnym smerom. Presnejšia štúdia rozdiel nájde, čím vznikne rozpor medzi oboma výsledkami, pričom nie je možné zistiť, či ide o skutočný rozdiel medzi dvoma štúdiami (v jednej sa dve skupiny nelíšia a v druhej sa líšia) alebo ide len o dôsledok odlišnej presnosti merania a miery šumu v častiach oboch štúdií. Je preto v záujme samotného autora nielen uvádzať v publikáciách údaje o presnosti merania (ako intraindividuálnu, tak aj interindividuálnu chybu; pozri kapitolu 1.1 Ciele vedeckej štúdie a sledované premenné), ale predovšetkým mať jasnú predstavu o tom, čo a ako presne meria. Len tak sa môže rozhodnúť, či vôbec meranie použije na analýzu a ako bude výsledky interpretovať.

Na vyjadrenie presnosti merania sa najčastejšie používajú absolútne a relatívne ukazovatele vzťahu medzi rozptylom nameraných hodnôt znaku a rozptylom spôsobeným rozdielom medzi dvoma opakovanými meraniami (Ulijaszek a Lourie, 1994). Najvhodnejšie je dvakrát zmerať všetky prípady danej vzorky, v niektorých špeciálnych metódach aj viackrát (napr. pri hodnotení fluktuatívnej asymetrie sa používa opakované meranie priamo ako faktor vstupujúci do analýzy rozptylu a porovnáva sa jeho vplyv s efektom fluktuatívnej asymetrie). V mnohých prípadoch však z praktických, finančných či etických príčin chybu merania opakovaním merania všetkých prípadov stanoviť nemožno. Vtedy je potrebné stanoviť chybu merania aspoň na časti vzorky. Rôzni autori odporúčajú rôznu minimálnu veľkosť vzorky na stanovenie chyby merania, napr. 50 prípadov (Mueller a Martorell, 1988), pokiaľ sa štúdia nezaobera porovnávaním viacerých skupín, u ktorých sa presnosť merania môže líšiť (napr. ťarchavé a neťarchavé ženy), v takom prípade je potrebné stanoviť chybu merania v každej skupine zvlášť.

Jedným z absolútnych ukazovateľov je **technická chyba merania**

$$\text{TEM} = \sqrt{\frac{\sum_{i=1}^n x_{d,i}^2}{2n}},$$

kde $x_{d,i} = x_{i1} - x_{i2}$ je rozdiel medzi meraniami. TEM vyjadruje priemernú chybu merania, ktorá pripadá na jedno meranie. Pokiaľ sa hodnota TEM rovná napríklad 1.118 mm, znamená to, že pri každom meraní na jedno meranie tohto znaku pripadá priemerne chyba 1.118 mm. Jednotkou TEM sú pôvodné jednotky, v ktorých bola premenná meraná. Rôzne TEM hodnoty možno porovnávať iba v rámci tejto premennej, t.j. nemožno porovnávať číselné hodnoty TEM u výšky postavy a sily stisku ruky.

Ďalším ukazovateľom je **relatívna technická chyba merania**

$$\text{TEM}_{\text{rel}} = \frac{\text{TEM}}{\bar{x}} \times 100,$$

kde \bar{x} je celková priemerná hodnota. TEM_{rel} predstavuje percentuálne vyjadrený podiel TEM k priemernej hodnote danej premennej. Pokiaľ je hodnota TEM_{rel} napr. 2.42 %, pripadá na každé meranie chyba predstavujúca 2.42 % z priemernej hodnoty. Tento ukazovateľ teda nezávisí len na samotnej presnosti merania, ale tiež na priemernej hodnote. Tou môže byť populačný priemer tabelový (publikovaný), priemer vypočítaný z hodnôt nameraných v danom výskume alebo priemerná hodnota z takto testovaných opakovaných meraní. Na rozdiel od TEM, porovnávanie TEM_{rel} medzi rôznymi veličinami je zmysluplné. Vyššie hodnoty TEM_{rel} majú v antropológii spravidla rozmery merané na živom človeku a na mäkkých tkanivách a menšie rozmery merané na skelete, čo je dané komplikovanejšou špecifikáciou veličín a štandardizáciou podmienok merania u živého človeka (mäkké tkanivá, cirkadiálne rytmy, psy-

¹⁰Za náhodné chyby považujeme aj **chyby registrácie** – chyby z odčítania hodnôt z meracieho prístroja, chyby zo zápisu hodnôt do protokolu, chyby z prenosu hodnôt z protokolu do PC.

chický stav, atď.). Keďže je tu chyba vzťahnutá k strednej hodnote, u znakov meraných s rovnakým TEM (dané napr. obdobnou definíciou veľičiny a rovnakou presnosťou meradla), ale s rôznou strednou hodnotou (môže to byť napr. dĺžka kosti stehennej a druhej kosti záprstnej, obe merané na osteometrickej doske), bude relatívna chyba veľičiny s menšou priemernou hodnotou napriek rovnakej TEM väčšia.

Tretím ukazovateľom je **koeficient reliability**

$$CR = \left(1 - \frac{TEM^2}{s^2}\right) \times 100,$$

kde s je celková smerodajná odchýlka. CR vyjadruje podiel druhej mocniny TEM k celkovému rozptylu (druhej mocniny smerodajnej odchýlky) hodnôt sledovanej vzorky, odčítaný od hodnoty jedna. Ide teda opäť o ukazovateľ relatívny, ktorý udáva, aký podiel rozptylu v dátach *nie je* tvorený chybou merania. Nadobúda hodnoty od 0 (absolútne nereliabilné meranie) do 1 (absolútne reliabilné meranie). Aj keď nie je stanovený žiadny limit určujúci, akú najnižšiu hodnotu by mal CR dosiahnuť, aby sme mohli namerané údaje použiť, Uliaszek a Kerr (1999) uvádzajú, že v antropometrii by mal dosahovať hodnoty minimálne 0.95 a viac. Zo spôsobu výpočtu je zrejmé, že CR závisí na hodnote smerodajnej odchýlky. Ak vypočítame CR pre zlúčený súbor mužov a žien dohromady a pre mužov a ženy samostatne, nižšia hodnotu CR (a teda nižšia reliabilita merania) bude pravdepodobne v zlúčenom súbore, kde bude smerodajná odchýlka výrazne vyššia.

Vzhľadom na umocnenie a odmocnenie rozdielov, TEM (ani ďalšie nasledujúce dva z neho vypočítané ukazovatele – TEM_{rel} a CR) nijak nezohľadňuje zmysel rozdielu (záporný či kladný) medzi prvým a druhým meraním a nie je teda ukazovateľom systematickej zmeny merania medzi prvým a druhým meraním. Na otestovanie systematickej zmeny, pozri kapitolu 6.1 Asymptotické testy o strednej hodnote. Vzhľadom na mnohé druhy príčin, v dôsledku ktorých systematická chyba medzi prvým a druhým meraním často vzniká, okrem jej testovania by sme sa systematickej chybe mali snažiť predchádzať metodickými opatreniami. Systematický posun nenastane, ak znáhodníme poradie prvého a druhého merania, t.j. nemerame najskôr všetky prípady prvýkrát a potom druhýkrát, ale v rámci jedného merania zaradíme každý prípad dvakrát v náhodnom poradí. S možným výskytom systematickej chyby merania medzi oddeleným prvým a druhým meraním súvisí aj nevyhnutnosť znáhodnenia (randomizácie) poradia merania prípadov z porovnávaných skupín (pozri kapitolu 1.3.8 Znáhodnenie a zaslepenie). Ak napríklad študujeme sexuálny dimorfizmus a porovnáваме stredné hodnoty u mužov a u žien, nie je správne zmerať najskôr mužov a potom ženy (alebo dokonca skupiny rozdeliť medzi rôznych výskumníkov), pretože môže vznikáť systematická chyba merania (v dôsledku zmeny podmienok prostredia, zmeny v chápaní rozmeru na mužskom a ženskom tele v čase, rovnako tak aj odlišnosti medzi dvoma osobami v chápaní definície rozmeru a praktických skúsenostiach, napr. v tlaku vyvíjanom na meradlo pri meraní mäkkých tkanív ľudského tela). Systematická chyba sa potom neošetrená stáva súčasťou študovaného sexuálneho dimorfizmu. V ideálnom prípade preto treba poradie mužov a žien randomizovať a meranie uskutočňovať jedným výskumníkom. Keďže v rozsiahlejších štúdiách to väčšinou nie je možné, pri väčšom počte merajúcich osôb je nutné ešte pred začiatkom merania testovať interindividuálnu chybu u všetkých výskumníkov na rovnakej testovacej vzorke.

Nevhodné na testovanie presnosti merania je použitie korelačného koeficientu (Halligan, 2002) alebo regresného modelu. Hodnoty opakovaných meraní totiž môžu veľmi silno korelovať aj v prípade nereliabilného merania zaťaženého systematickou chybou merania. Ak by sme napríklad pri druhom meraní u všetkých prípadov namerali presne dvakrát väčšiu hodnotu než pri meraní prvom, meranie by bolo veľmi nereliabilné a s veľkým systematickým rozdielom medzi prvým a druhým meraním, korelačný koeficient by však bol napriek tomu rovný jednej.

1.3.6 Štatistické znaky

Na štatistických jednotkách skúmame **štatistické znaky (premenné)**, ktoré sa delia do nasledovných kategórií (hovoríme aj o **škále merania**):

1. kvantitatívne (metrické, kardinálne)

- **spojité** (merané na nekonečný počet desatinných miest), **diskrétne** (merané na konečný počet desatinných miest; často sa im hovorí aj diskretizované spojité znaky, lebo znak nemôžeme zmerať s absolútnou presnosťou; napr. dĺžkové miery lebky) a **intervalové** (jav, ktorý

nevieme presne pozorovať, napr. termíny a vekové kategórie v rokoch používané pri odhade veku podľa kostry¹¹ (Szilvássy, 1988): infans I (0, 7), infans II (7, 14), juvenis (14, 20), adultus I (20, 30), adultus II (30, 40), maturus I (40, 50), maturus II (50, 60), senilis (60, vek_{max}) [vysoká informačná hodnota];

- **frekvencie/početnosti výskytu nejakej udalosti** [vysoká informačná hodnota], kde ide napr. o počet vyfajčených cigariet za deň a pod.;

2. kvalitatívne

- **nominálne znaky (neusporiadaná kategorizácia)** – ide o príslušnosť sledovaného objektu k určitej triede objektov, napr. vyučovacie predmety; naboženstvá ako katolíci, protestanti, židia, moslimovia; typ sídla – dom, apartmán; pohlavie¹² – žena, muž; krvný typ – A, B, AB a 0 [nízka informačná hodnota, ak ide o intervalovú premennú vytvorenú z nejakej spojitej premennej; inak vysoká informačná hodnota];
- **ordinálne znaky (usporiadaná kategorizácia)** – ide o znak, ktorého hodnoty môžeme prirodzene usporiadať, napr. stupnica známok – 0, 1, . . . , 5; sociálna skupina – nízka, stredná, horná; politická filozofia – liberálna, stredná, konzervatívna; stupeň bolesti (podľa WHO) – 0 (žiadna), 1 (mierna bolesť), 2 (vnímaná a obťažujúca), 3 (silná a stresujúca), 4 (veľmi silná a neznesiteľná), 5 (zničujúca) [stredne vysoká informačná hodnota];
- **alternatívne znaky (binárne)** – typ nie/áno, kedy môže ísť o neusporiadanú kategorizáciu, napr. pohlavie – 0 (žena), 1 (muž) alebo usporiadanú kategorizáciu – 0 (nemá znak), 1 (má znak) [nízka až stredne vysoká informačná hodnota].

Frekvencie/početnosti hovoria o **absolútnej škále znaku**, kým pravdepodobnosti a percentá o **relatívnej škále znaku**. Pri zaznamenávaní detailov o sledovaných premenných je potrebné zaznamenať nielen *typ premennej* (škálu merania), ale aj jej *presné pomenovanie a skratku v databáze, jednotky, stručný popis a možný rozsah hodnôt*.

Realizácie štatistických znakov (dáta) môžu mať rôznu formu – **skalár**, **vektor**, **matica**, **pole** alebo **dátová tabuľka** (kombinuje číselné a textové údaje), z ktorých možno získať napr. **incidenčnú maticu** (matica neprítomnosti a prítomnosti – nuly a jednotky), **abundančnú maticu** (matica abundancií; v každej bunke sa vyskytuje počet) alebo **tabuľky početností** atď.

1.3.7 Triedenie dát

Triedenie dát slúži na rozdelenie výberových jednotiek do skupín (tried) podľa dopredu určených triediacich znakov. Podľa počtu triediacich znakov rozlišujeme

- **jednostupňové triedenie** – len jeden triediaci znak, napr. triedenie novorodencov podľa pohlavia;
- **viacstupňové (kombinačné) triedenie** – dva a viac triediacich znakov, napr. triedenie zomretých osôb podľa veku, pohlavia a zamestnania.

S typom triedenia súvisí aj následne použitý štatistický model, v ktorom možno triedenie použiť pre závislé, ako aj nezávislé premenné.

Triedy sú pri triedení určené podľa kvantitatívnych znakov pomocou *triednych intervalov*, ktoré musia pokryť všetky hodnoty sledovaného kvantitatívneho znaku a vzájomne sa nesmú prekrývať (musia byť disjunktné). *Hranice triednych intervalov* sú dané číselne a ich rozdiel predstavuje *dĺžku triedneho intervalu*. *Stred triedneho intervalu* je aritmetický priemer hraníc triedneho intervalu. Rovnako dlhé triedne intervaly sa nazývajú *ekvidištantné*. *Počet triednych intervalov* je najčastejšie od 5 do 20 (niekedy aj menší, podľa potreby), je určený s ohľadom na rozsah súboru a jeho rozpätie (viac pozri v kapitole 3 Charakteristiky polohy a variability a štatistická grafika).

¹¹V súčasnosti sa v kostrovej antropológii pochybuje o správnosti zaraďovania jedincov do vekových kategórií v dospelosti v desaťročných intervaloch. Možnosťami reálneho a validného hodnotenia veku dospelých jedincov na kostre sa zaoberali Buk a kol. (2012) a Brůžek (2008).

¹²Pohlavie všeobecne chápeme ako nominálny znak (kódovanie: 0 – žena, 1 – muž); ako ordinálny znak vystupuje len vtedy, keď sledujeme riziko choroby súvisiace s pohlavím, kde nulou označujeme menej rizikové pohlavie.

Príklad 36 (triedenie veku) Pri sledovaní pacientov po operácii bedra a kolena ich môžeme rozdeliť do nasledovných vekových kategórií (tried): (1) $(x_{\min}, 55)$ rokov, (2) $(55, 65)$ rokov, (3) $(65, 75)$ rokov a nakoniec (4) $(75, x_{\max})$ rokov.

1.3.8 Znáhodnenie a zaslepenie

Znáhodnenie sa používa hlavne pri meraní/zázname dát. Štatistické jednotky (subjekty) sa náhodne poprehadzujú pomocou ich identifikačných čísel tak, aby napr. meranie nebolo ovplyvnené usporiadaním náhodného výberu (poradiť subjektov). Znáhodnenie alebo **znáhodnená alokácia**, t.j. náhodné pridelovanie subjektov do skupín, je fundamentálnym princípom klinických štúdií. Cieľom znáhodnenej alokácie je redukcia výchyľky, ktorá sa vyskytuje pri nenáhodnom priradovaní subjektov do skupín. V podstate ide o aplikáciu princípov náhodného výberu (najčastejšie stratifikovaného výberu), pričom detaily implementácie majú byť uvedené v protokole v sekcii Štatistické metódy. Pokiaľ je súčasťou znáhodňovania aj **stratifikácia**¹³, je potrebné popísať **prognostické premenné/faktory** a počet hladín/úrovní pre každú z nich (napr. pohlavie, závažnosť ochorenia a pod.). Znáhodnená alokácia prebieha v každej **stratifikačnej skupine** (kombinácii hladín všetkých faktorov). Je potrebné dodržiavať pravidlo použitia malého počtu faktorov a hladín, pretože počet stratifikačných skupín rýchlo stúpa.

Príklad 37 (znáhodnená alokácia; permutačný blokový princíp) Majme dve skupiny *A* a *B* (vo všeobecnosti môžeme mať *k* skupín), do ktorých chceme náhodne alokovať subjekty. **Alokačný pomer** (podiel rozsahov týchto dvoch skupín) je 1 : 1. Alokácia do týchto dvoch skupín prebieha pomocou $(m \times k)$ -rozmerných blokov (*m* je nejaké prirodzené číslo; keďže máme 2 skupiny, $k = 2$). Nech $m = 2$. Potom je blok zložený zo štyroch elementov (dva pre každú skupinu). Možné usporiadania (permutácie) elementov v blokoch sú nasledovné – AABB, BBAA, ABBA, BAAB, ABAB a BABA. Ich poradie je určené náhodným usporiadaním čísel 1 až 6. Celkový počet písmen *A* a *B* zodpovedá rozsahu náhodného výberu.

Príklad 38 (stratifikovaná znáhodnená alokácia) Chceme náhodne alokovať subjekty do dvoch skupín v pomere 1 : 1. Majme premenné pohlavie (hladiny – žena a muž) a závažnosť ochorenia (hladiny – 1 a 2). Budeme mať potom štyri stratifikačné skupiny (obe závažnosti ochorenia pre ženy ako aj pre mužov) a v každej z nich vykonáme znáhodnenú alokáciu z predchádzajúceho príkladu.

Zaslepenie/maskovanie sa používa na redukciu výchyľky, ktorá by mohla vzniknúť v prípade, že má výskumník informácie o zaradení subjektov do skupín (typ vyšetrenia, typ choroby, prípad alebo kontrola a pod.), pretože tieto informácie môžu ovplyvniť jeho rozhodovanie. Špeciálnym prípadom zaslepenia je **dvojité zaslepenie**, ktoré sa v klinických pokusoch používa v prípadoch, keď ani výskumník, ani subjekt nepoznajú zaradenie subjektu do príslušnej skupiny. V protokole sa takáto situácia opíše nasledovne: „Ide o dvojito zaslepenú znáhodnenú štúdiu, ktorá zisťuje efekt lieku XY a placebo (alebo lieku XZ) na incidenciu infarktu myokardu bez a s následkom smrti (celková mortalita) u *n* pacientov po prvom infarkte myokardu.“ Je potrebné špecifikovať, čo sa bude znáhodňovať a kroky, ktoré budú vykonané na zabezpečenie znáhodnenia v praxi. Je tiež dôležité zdôrazniť, že ani ďalšie osoby, ako napr. rádiológ, patológ a laboratórny personál, nemajú prístup k zatriedeniu subjektov do skupín. Rovnako tak pri antropologickom meraní, či už klasickom alebo virtuálnom, je potrebné zabezpečiť, aby ani výskumník nemal prístup k zatriedeniu subjektov do skupín. Optimálne je preto použiť identifikačné čísla subjektov v náhodnom poradí.

1.3.9 Databáza

Celistvosť a kvalita štatistickej analýzy závisí od kvality dát. Každá štúdia musí vychádzať z vysoko kvalitných dát, ale kroky k dosiahnutiu tohto cieľa sú často prehliadané. V angličtine sa používa slovné spojenie „*garbage in – garbage out*“, v slovenčine sa štatistika definuje ako „*presná práca s nepresnými číslami*“. V protokole je potrebné uviesť, akým spôsobom budú dáta zozbierané, akým spôsobom bude

¹³Z latinského *stratum* (singulár) a *strata* (plurál); strátum v štatistike sa prekladá ako vrstva alebo hladina.

zaslepená identifikácia subjektov, akým spôsobom sa budú dáta uchovávať a chrániť. Práca s dátami v elektronickej podobe sa nazýva **dátový manažment**. V prípade veľkých databáz je potrebné kontaktovať informatika špecializujúceho sa na databázy, t.j. **databázového programátora**, ktorý je schopný programovať v jazyku SQL a **bioštatistika**, ktorý je schopný programovať v jazyku \mathbb{R} . Bioštatistika je potrebné kontaktovať v každom prípade, pretože sa musí podieľať na **databázovom projekte**, ktorý zahŕňa plánovanie, definíciu a realizáciu databázy, vytváranie dátových formulárov, spôsob zadávania dát, monitorovanie a revíziu databázy. Dobre organizovaná databáza zabezpečí nielen dobré uchovanie dát, ale uľahčí aj hľadanie subjektov, kontrolu kvality, vlastnú štatistickú analýzu a prezentáciu výsledkov.

Pri tvorbe formulárov treba mať na zreteli kto, kedy a kde bude formuláre vyplňať, kedy budú dáta dostupné a či bude formulár súčasťou databázy. Je vhodné vytvoriť **zoznam všetkých potrebných formulárov**, v ktorom budú uvedené názvy súborov a miesto ich uloženia (Peacock a Peacock, 2011). V každom prípade je dôležité mať

- **zoznam premenných, ich typ, dátum a jednotky merania**; v analýze tvaru aj **zoznam mier, landmarkov a kriviek**; všetko s definíciami premenných, vysvetlením skratiek (forma skratiek musí byť konzistentná s pravidlami vytvárania názvov stĺpcov v použítom štatistickom programe, napr. \mathbb{R}), číselným formátom hodnôt (počet desiatinných miest, počet cifier, forma dátumu, napr. *dd/mm/yyyy*), s očakávaným rozsahom a očakávanou hodnotou, definíciou kódovania v tzv. vyhľadávacích tabuľkách, s uvedením spôsobu identifikácie chýbajúcich a neposkytnutých dát (v databáze sa nesmú nechávať prázdne bunky, optimálne je definovať tieto hodnoty tak, aby nemohli byť zamenené s reálnymi hodnotami, napr. 999 alebo -9 a pod.), s definíciou pravidiel validácie, spôsobu získania dát (virtuálne z obrazu, fyzickým meraním, akým vyšetrením, akým prístrojom), spôsobom merania, použitím dát (popisná alebo štatistická analýza); sumárne tomu hovoríme **dátový slovník**;
- **záznam o identifikácii subjektov**, ktorý je potrebný na anonymnú identifikáciu subjektov; **kontaktné informácie o subjekte**;
- **výstupný záznam o subjekte** – kedy subjekt opustil štúdiu, status ukončenia a dôvod.

Kontrola kvality databázy zahŕňa kontrolu

- **opakovaného zahrnutia toho istého subjektu** (napr. aj pomocou rodných čísel),
- **rozsahu danej premennej** (čistenie dát, t.j. zhodnotenie a korekcia; napr. pomocou kontroly posunu desatinnej čiarky ako systematickej chyby, zobrazením dát, kontrolou cez stratifikované premenné, hlavne cez kľúčové (primárne) premenné a pod.), v angličtine sa používa pojem *out-of-range measurements*, v štatistike sa špecifickejšej skupine týchto realizácií hovorí **odľahlé pozorovania**, ktoré sa môžu (ale nemusia) vyskytovať v povolenom rozsahu danej premennej,
- **kvality obrazového materiálu** (napr. kontrola rekonštrukcie 3D obrazu, kontrola dodržania svetelných podmienok, pri osobách aj prítomnosti mejkapu, náušnic, vlasov alebo chlupov brániacich vytvoreniu obrazu a pod.),
- **dátový audit** – kontrola splnenia vylučovacích kritérií, t.j. či sa v súbore nachádzajú len tie subjekty, ktoré sa v súbore nachádzať majú v zmysle vylučovacích kritérií.

Bezpečnosť databázy sa často hodnotí pomocou tzv. **bezpečnostnej trojice**:

1. **Dôvernosť** – ochrana dát pred neautorizovaným vniknutím do databázy – v prípade papierovej podoby databázy sa používa uzamknutá skrinka, v prípade elektronickej podoby databázy ide o enkryptovaný súbor v PC, v inej pracovnej stanici, v laptope alebo na inom mobilnom zariadení, ako je tablet, USB-kľúč alebo externý HDD; ochrana tohto súboru heslom (neodporúča sa nechať pracovnú stanicu neuzamknutú, ani používať všeobecné heslá); databázu je potrebné uchovávať bez možnosti identifikovať subjekty, čo je legislatívne ošetrené napr. v Privacy Rule v dokumente HIPPA (Health Insurance Portability and Accountability Act), ktorý hovorí o ochrane dôverných informácií; v neposlednom rade je potrebné zabezpečiť pravidelné zálohovanie na serveri, protivírusovú ochranu a *firewalls* (najčastejšie prostredníctvom IT tímu inštitúcie).

2. **Úplnosť** – zabezpečenie správnosti údajov zabránením nevhodnej zámene dát, či už náhodnej, alebo cielenej (napr. povolením len čítania dokumentu), ďalej limitovanou aktualizáciou, plným prístupom pre príslušných členov riešiteľského kolektívu.
3. **Dostupnosť** – zabezpečenie dostupnosti autorizovaným používateľom (členovia riešiteľského kolektívu, špecificky napr. pre koordinátora projektu, bioštatistika, databázového programátora a pod.).

Uzamknutie databázy. Priebežné čistenie databázy je potrebné vykonávať pravidelne, konečné čistenie na konci štúdie, keď sa predpokladá, že všetky potrebné údaje o subjektoch sú už skompletizované. V tomto období sa vykoná tzv. **zmrazenie**, čo je časové obdobie kontroly a čistenia, kedy bioštatistik môže odhaliť problémy napr. v podobe odľahlých pozorovaní počas **predbežnej štatistickej analýzy**. Po skončení tohto obdobia sa vytvorí **finálna kópia databázy určená na štatistické účely**, do ktorej môže zasahovať len bioštatistik. Po ukončení analýz sa vykoná tzv. **trvalé zmrazenie** databázy, po ktorom nie je možná žiadna ďalšia zmena ani v rámci autorizovaného prístupu.

1.3.10 Rozsah náhodného výberu

Veľmi dôležitou súčasťou plánovania výskumu je určenie **minimálneho rozsahu náhodného výberu**, ktorý môže ovplyvniť nielen trvanie výskumu a jeho finančnú náročnosť, ale v neposlednom rade aj vlastné štatistické analýzy. Výpočet rozsahu náhodného výberu by mal prebiehať v spolupráci so štatistikom, keďže treba vopred zvážiť, aký štatistický model sa použije v následných analýzach. Rovnako treba zohľadniť oprávnenosť použitia tohto modelu, ako aj dostatočnú reliabilitu získaných odpovedí na sledované otázky. Na výpočet sú potrebné tieto informácie (Hackshaw, 2009):

1. Správny **štatistický model** konzultovaný so štatistikom. Spolu s typom premenných a ich jednotkami musí byť jasne a zrozumiteľne opísaný.
2. **Veľkosť efektu** je číslo získané z istého štatistického modelu, ktoré charakterizuje sledovanú premennú v súvislosti s testovanou hypotézou, kde efektom je napr. rozdiel priemerov, podiel rozptylov, rozdiel pravdepodobností, pomer šancí, relatívne riziko, Pearsonov korelačný koeficient, regresný parameter a pod. Približnú (predpokladanú) veľkosť efektu zistíme z predchádzajúcich štúdií v rámci tvorby systematického prehľadu z literatúry, pilotnej štúdie alebo zo skúsenosti lekára/antropológa, pričom predstavuje *minimálny (realistický) klinicky/antropologicky dôležitý efekt*. Čím je efekt väčší, tým menší rozsah výberu potrebujeme. Rozsah výberu však v súvislosti so štatistickým modelom nemožno podceňovať, pretože menší rozsah nielenže nemusí dostatočne reprezentovať sledovanú populáciu, ale ani získaný výsledok testovania určitej hypotézy nemusí byť štatisticky signifikantný.
3. **Hladina významnosti** je číslo, ktoré zjednodušene predstavuje maximálnu pravdepodobnosť nájdenia štatisticky signifikantného efektu, ktorý ale reálne neexistuje. V zjednodušenom chápaní vyjadruje maximálnu pravdepodobnosť chybného úsudku.
4. **Sila testu** je číslo, ktoré predstavuje pravdepodobnosť nájdenia štatisticky signifikantnej veľkosti efektu (rovnej alebo väčšej ako nejaké dopredu zvolené číslo), ak signifikantný efekt v realite skutočne existuje.

Príklad 39 (štúdia prípadov a kontrol) *Cieľom štúdie je hľadanie sily asociácie medzi fajčením matiek a vrodenými poruchami novorodencov, kde prípady sú matky s dieťaťom s vrodenou poruchou a kontroly matky s dieťaťom bez vrodenej poruchy. Očakávame približne 25 % fajčiarok medzi kontrolami, kde predpokladáme nájdenie pomeru šancí (príslušný efekt) približne 1.75. Pri 80% sile a 5% hladine významnosti pri dvojitýžerovom Studentovom t-teste s obojstrannou alternatívnou hypotézou za prepokladu alokačného pomeru 3 : 1 (t.j. troch kontrol na jeden prípad), bude minimálny rozsah náhodného výberu 170 prípadov a 510 kontrol.*

Niekedy sa môže stať, že už vypočítaný **základný minimálny rozsah náhodného výberu** treba z nejakého dôvodu zvýšiť. K tejto situácii dochádza napr. v týchto prípadoch:

- máme niekoľko závislých premenných alebo mnohonásobné porovnávanie, čím sa automaticky mení nielen hladina významnosti, ale aj štatistický model (napr. zo Studentovho *t*-testu na ANOVA model s fixnými efektmi, z jednoduchého lineárneho regresného modelu na mnohorozmerný lineárny regresný model a pod.);
- nemôžeme predpokladať, že pomer počtu zahrnutých do štúdie k počtu vyšetrených bude číslo rovné jednej (t.j. že všetci vyšetrení budú zahrnutí do štúdie), že nejaké subjekty budú pokračovať v štúdiu a stratíme o nich ďalšie informácie (napr. v kohortovej štúdiu a pod.); preto musíme plánovať štúdiu na základe rozsahu, ktorý hovorí o dostupnej populácii v rozsahu väčšom ako je minimálny a bezprostredne potrebný.

1.3.11 Kontroly a ich hodnotenie

Úspešný nábor či získavanie subjektov je vo fyzickej a klinickej antropológii kľúčom k úspechu každej vedeckej štúdie. Efektívny nábor vyžaduje zabezpečenie potrebnej infraštruktúry, chodu a dokumentácie s cieľom optimalizovať kontroly a ich hodnotenie. Pod **infraštruktúrou** rozumieme miesto, kde sa bude nábor/získavanie konať, a to buď v laboratóriu, alebo v pracovni výskumníka, alebo mimo týchto priestorov. Je potrebné odhadnúť veľkosť výskumného priestoru, identifikovať ho a zariadiť podľa potrieb štúdie. Vybrané miesto musí byť bezpečné z hľadiska uchovávaní a ochrany dôverných informácií či už v písomnej, alebo v elektronickej podobe v enkryptovaných dátových súboroch (napr. informovaný súhlas subjektov, dáta, dotazníky, 2D alebo 3D obraz a pod.). Rovnako musí byť pripravený aj priestor na uchovávanie biologického materiálu. Miestnosť musí obsahovať priestor, v ktorom prebehne interview a vyšetrenia subjektov, ale aj priestor pre výskumníkov, ktorí vyšetrenia vykonávajú.

Propagácia výskumu sa môže konať rôznym spôsobom, napr. pomocou letákov posielaných písomnou alebo elektronickou formou, pomocou internetových stránok či periodickej tlače. Akákoľvek použitá metóda musí byť vopred schválená inštitucionálnou etickou komisiou. Spôsob a miesto propagácie ovplyvňuje výber vzorky a tým aj výsledky štúdie, preto by mali byť zahrnuté v pláne vedeckej štúdie. Najefektívnejšie je hromadné posielanie písomnej alebo elektronickej pošty, po čom zvyčajne nasleduje telefonický rozhovor. V mnohých prípadoch je nevyhnutná úzka spolupráca so zdravotníckymi zariadeniami alebo príslušnými organizáciami.

Alokačný čas potrebný na vykonanie interview, vypísanie informovaného súhlasu, zistenie zdravotného stavu (v minulosti a súčasnosti), vyplnenie dotazníka, vykonanie vyšetrení, meraní alebo odobratia krvi na krvné testy a pod. je potrebné dopredu odhadnúť ešte pred návštevou prvého subjektu a pred zistením jeho spôsobilosti zúčastniť sa štúdie. Tiež je potrebné odhadnúť **počet návštev** na skompletizovanie vyšetrení (celkovo, ale aj denne alebo týždenne). Pokiaľ chceme subjekt zaradiť do štúdie, treba ho najskôr vyšetriť alebo zhodnotiť, a preto je potrebné odhadnúť **pomer vyšetrených ku zahrnutým** do štúdie, čo je efektívna miera úspešnosti náboru. Najefektívnejšie je ponúknuť subjektom flexibilný čas návštevy/návštev na zlepšenie zápisu, oboznámiť ich, najlepšie písomnou formou, s dôležitými informáciami (ako napr. poloha, čas, čo očakávame počas vyšetrenia a hodnotenia, dĺžka návštevy a pod.). Vyžaduje sa tiež dodržanie HIPPA, ako aj princípov etickej komisie inštitúcie.

Cieľom vyšetrení je začať proces zistenia spôsobilosti subjektov zúčastniť sa štúdie, zoznámenie sa s potenciálnymi subjektmi, získanie informovaného súhlasu a zhromaždenie dát potrebných na vlastný zápis (zaradenie) subjektov do štúdie. Vyšetrenie a hodnotenie subjektov môžeme rozdeliť do desiatich krokov (Hulley a kol., 2007):

1. **Získanie informovaného súhlasu** – umožnenie realizácie ďalších krokov; potenciálny subjekt dostane kópiu informovaného súhlasu a má dostatočný čas na to, aby si dokument pred podpísom prečítal a pochopil obsah; subjekt tiež dostane po podpise kópiu dokumentu potvrdzujúcu schválenie štúdie inštitucionálnou etickou komisiou.
2. **Školenie subjektov** – zapojenie potenciálnych subjektov a ich informovanie o dôležitosti a cieľoch štúdie, ako aj ich účasti na nej; na tomto mieste je potrebné zdôrazniť, že subjekt je (v istom zmysle) súčasťou výskumného tímu.
3. **Odpovedanie na otázky** – odpovedanie na otázky vybuduje dôveryhodnosť a možnosť vytvorenia pozitívnej väzby medzi subjektom a výskumníkom.
4. **Zhromaždenie dát vzhľadom na spôsobilosť subjektov zúčastniť sa štúdie** – zhrnutie získaných údajov napr. vyplnenie dotazníka, vyšetrenia, laboratórne testy.

5. **Poskytnutie inštrukcií v písomnej a ústnej forme** – o ďalšej návšteve, vyšetreniach alebo o zápise do štúdie.
6. **Dokumentácia dát súvisiacich so štúdiou v podobe formulárov** – podpísaný originál informovaného súhlasu a všetky ostatné dokumenty, do ktorých možno počas štúdie v prípade potreby nahliadnuť.
7. **Kontrola spôsobilosti vykonaná hlavným riešiteľom** – zabezpečenie spôsobilosti subjektu zúčastniť sa štúdie.
8. **Kontrolný zoznam prijímacích a vylučovacích kritérií** – zabezpečenie celistvosti výberu a kontrola dodržiavania protokolu, pričom subjekty musia splniť všetky kritériá špecifikované v protokole (zoznam musí byť vytvorený už pred vyšetrením prvého subjektu a následne striktné dodržiavaný).
9. **Dokumentácia výsledkov vyšetrení, hodnotenia, prijímacích a vylučovacích kritérií** – zaistenie správnosti a celistvosti dát.
10. **Zápis subjektov prijatých do štúdie** – umožnenie pokračovania štúdie v ďalších krokoch.

Informovaný súhlas obsahuje tieto informácie: obsah, ciele a význam štúdie, účel a zdôvodnenie naboru subjektov, náplň a dĺžka účasti subjektov, náplň základnej a experimentálnej časti štúdie, rola a zodpovednosť subjektov a členov vedeckého tímu, zoznam vyšetrení a prípadné riziká a pod. Subjekty musia mať dostatočný čas na prečítanie súhlasu, ako aj zodpovedanie prípadných otázok pred vlastným podpisom. Pri tvorbe informovaného súhlasu treba rozlišovať medzi štandardnou klinickou praxou a klinickým výskumom; pri ich zámene sa hovorí o *therapeutical misconception*. Z etického hľadiska je potrebné rozlišovať medzi

1. **subjektom klinickej štúdie** – podpisom informovaného súhlasu sa subjekt vzdáva práva na liečbu, ktorá by inak plne zodpovedala jeho potrebám a preferenciám; subjekt musí byť informovaný o kontrolných podmienkach, podávaní neúčinných liečiv (placebo), randomizácii a zaslepení;
2. **subjektom observačnej štúdie** – podpisom subjekt súhlasí s procedúrami a vyšetreniami špecifikovanými v pláne štúdie.

Príklad 40 (vedecká etika) *Schopnosť porozumieť obsahu informovaného súhlasu môže byť limitovaná pre napr. deti, duševne chorých alebo mentálne postihnutých pacientov. Takéto prípady musia byť legislatívne ošetrené a mali by zahŕňať hodnotenie schopnosti subjektu dať súhlas, splnomocnenie k rozhodovaniu alebo špeciálne odporúčenie inštitucionálnej etickej komisie. Väzni a podmienčne prepustení tiež vyžadujú pozornosť vzhľadom na obmedzenie slobodnej voľby. Subjekty v trestnom konaní, sťahané napr. za zneužívanie návykových látok, tiež vyžadujú pozornosť vzhľadom na etiku, ochranu súkromia alebo pocit bezpečnosti pri účasti v štúdiu. Na všetky vyššie uvedené príklady vyžadujúce špeciálnu legislatívnu pozornosť je potrebné myslieť už pri plánovaní vedeckej štúdie.*

Porušenie prijímacích kritérií. Subjekt, ktorý nespĺňa kritériá štúdie, nazývame **neúspešný kandidát**. Vzhľadom na to, že evidenciu vhodnosti subjektov je potrebné neskôr sumarizovať, je potrebné evidovať všetky dôvody vylúčenia. Niektoré štúdie umožňujú opakované vyšetrenia aj neúspešných subjektov po skončení časového intervalu vyšetrení. Ak sa dôvody nesplnenia stanovených kritérií medzi potenciálnymi subjektmi opakujú, na základe počtu neúspešných kandidátov možno protokol modifikovať. Protokol musí byť dostatočne flexibilný a musí umožniť dodatočné doplnenie ďalších kritérií alebo opakované vyšetrenia, ako sa uvádza v nasledujúcich príkladoch.

Príklad 41 (dodatok k protokolu) *Výskumník potrebuje pridať jeden subjekt do databázy, aby mohol ukončiť nabor a potencionálny subjekt splňa všetky kritériá až na jedno, BMI = 46 kg/m². Vylučovacie kritérium je však BMI ≥ 45 kg/m². Na tomto mieste si môžeme položiť niekoľko otázok.*

Máme právo odporučiť zníženie hmotnosti? Môže výskumník urobiť výnimku a pridať tento subjekt do štúdie a zdokumentovať dôvod prijatia? Odpoveď na obe otázky znie nie. Čo urobiť môže? Subjekty, ktoré nespĺnili kritériá možno znovu vyšetriť, pokiaľ je opakované vyšetrenie špecifikované v protokole a schválené inštitucionálnou etickou komisiou. Alternatívnou je modifikácia existujúceho protokolu pomocou dodatku, ktorá však vyžaduje schválenie.

Príklad 42 (druhé (dobrovoľné) vyšetrenie) *Výskumník vyšetří subjektu systolický krvný tlak (SKT) a zameraná hodnota SKT = 128 mm Hg. Vylučovacie kritérium predstavuje SKT ≤ 130 mm Hg a bolo dopredu stanovené a schválené inštitucionálnou etickou komisiou s možnosťou druhého (dobrovoľného) vyšetrenia ako súčasť protokolu. Presná formulácia v protokole môže byť nasledovná: „Ak je hodnota SKT subjektu na antihypertenznej liečbe počas prvého vyšetrenia menšia ako 130 mm Hg, je možné uskutočniť druhé vyšetrenie merania SKT. Potencionálnym subjektom bude odporúčané, aby na toto vyšetrenie prišli do jedného až dvoch týždňov od prvého vyšetrenia. Ak bude hodnota SKT menšia ako 130 mm Hg, bude subjekt z ďalšieho výskumu vylúčený.“*

1.3.12 Nábor (získavanie) subjektov vo fyzickej a klinickej antropológii

Alternatívou ku klasickým metódam náboru (letáky, periodická tlač, e-mail a telefonovanie) sú sofistikované multimediálne reklamné kampane, globálne telefonické centrá pre multicentrické štúdie, internetové stránky štúdie. Pomocou nich možno nielen identifikovať potencionalný subjekt, ale aj sa s ním spojiť. Štúdiá môže byť dobre naplánovaná, ale bez dostatočného počtu subjektov sa nedá realizovať. Výskumníci musia byť preto kreatívni nielen pri tvorbe stratégie náboru, ale aj pri udržaní si subjektov a pri zabezpečení vernosti subjektov. Tieto stratégie sú často jedinečné a prispôbené konkrétnej štúdiu. Plán náboru sa vytvára už počas plánovania štúdie, kedy si treba strategicky premyslieť, akým spôsobom možno získať prístup k cieľovej populácii, ako prekonať prípadné bariéry zistením charakteristík cieľovej populácie a ako minimalizovať náklady. Nábor je potom možné začať po získaní súhlasu inštitucionálnej etickej komisie.

WWH stratégia. Táto stratégia predstavuje trojicu základných princípov, t.j. kto (*who*), čo (aký alebo aké; *what*) a ako (*how*) v podobe nasledovnej implementácie (McPaul a Toto, 2011):

1. **sledovaná choroba alebo iné podmienky** – definujú, *kto* bude tvoriť cieľovú populáciu; cieľová populácia definuje, *aké* miesta treba použiť na nábor (berúc do úvahy vek, pohlavie, sociálny a ekonomický status, kultúru, etnicitu, gramotnosť a prístupnosť (deti, starí ľudia, väzni a pod.), ako aj prevalenciu choroby); miesta definujú, *ako* vyvinúť realistické stratégie náboru a udržania si subjektov;
2. **príjmacie a vylučovacie kritériá** – vytvárajú sa s cieľom vybrať do štúdie vhodné subjekty, pričom sa vychádza zo systematického prehľadu, z ktorého možno zistiť, *kto* tvoril cieľovú populáciu, *aký* typ dizajnu sa použil, a následne *ako* stanoviť typ najvhodnejšej štúdie na zodpovedanie cieľov a testovanie hypotéz;
3. **spôsob práce** – je potrebné identifikovať, ktoré procedúry a aký spôsob práce (vrátane súvisiacich komplikácií) je potrebný na testovanie hypotéz (môže sa stať, že subjekty nebudú ochotné zúčastniť sa štúdie, ak budú použité **invazívne metódy** či bolestivé, nepohodlné alebo časovo náročné procedúry); pozadie štúdie a jej význam by mali nasmerovať výskumníkov na správnu cestu, t.j. určiť *aké* procedúry sú potrebné, *kto* a *ako* bude vykonávať tieto procedúry potrebné na zodpovedanie cieľov a testovanie hypotéz;
4. **trvanie štúdie** – tento faktor môže ovplyvniť rozhodnutie potencionalných subjektov zúčastniť sa štúdie; ak je štúdia priveľmi dlhá, je vysoká pravdepodobnosť straty subjektu; jej dôvodom môže byť prestahovanie sa, odcestovanie alebo rodinné problémy, ako aj choroba, strata záujmu alebo smrť subjektu; týmto problémom sa možno vyhnúť buď kratším trvaním štúdie, alebo získaním väčšieho množstva subjektov, a to po diskusii s bioštatistikom, čo zaručí dostatočnú istotu a zakomponovanie tejto úpravy do plánu štúdie; takýmto plánovaním v predstihu možno

zobrať do úvahy aj nasledovné skutočnosti: *kto* sú potenciálne subjekty, *aká* frekvencia vyšetrení je potrebná, kde budú vyšetrenia vykonávané a *ako* sa získajú dostatočné ľudské zdroje a grantové prostriedky;

- 5. zázemie a ľudské zdroje** – vedecký tím (koordinátor, spoluriešitelia vrátane bioštatistika, databázový programátor, laboratórni technici, administratívna podpora a pod.), priestor, školenia a výučba bezprostredne súvisiaca s vedeckou štúdiou (bez školenia alebo nedostatočným školením a výučbou môže byť narušená integrita štúdie a vedeckého tímu a zároveň aj poškodené dobré meno hlavného riešiteľa, ktorý získal na štúdiu grantové prostriedky), tovary a služby, prístup k diagnózam a pod.; pokiaľ sa zdroje hľadajú oneskorene, môže to spôsobiť oneskorený začiatok štúdie, chýbanie potenciálnych subjektov a nedosiahnutie cieľov náboru a neudržanie si subjektov a nakoniec aj neschopnosť ukončiť štúdiu;

- 6. grantové prostriedky.**

Príklad 43 (over-recruitment) *Ak bol vypočítaný minimálny rozsah súboru n a očakávaná strata subjektov je 10 %, potom upravený rozsah súboru $n' = n/(1 - 0.1)$. Teda ak $n = 100$, potom $n' = 100/(1 - 0.1) = 111$.*

Príklad 44 (prostriedky na nábor) *Prezentácie štúdie medzi kolegami, zabezpečenie všeobecných informácií o štúdiu na webovej stránke, na nástenke, letáku a v brožúre, zoznam kontaktných informácií riešiteľského kolektívu, vizitky s kontaktným číslom na koordinátora, informácia o tom, čo sa očakáva na každej návšteve, najčastejšie kladené otázky (FAQs), zabezpečenie zmysluplného transportu, použitie elektronických lekárskeho záznamov a pod.*

Príklad 45 (prostriedky na udržanie si subjektov) *Zabezpečenie dopravy, občerstvenie, flexibilný plán náboru realizovaný aj večer a cez víkend, motivačné platby na ocenenie nadčasov, motivačné darčeky, zabezpečenie kalendára štúdie s pripomienkami termínov ďalších návštev, pohľadnice k narodeninám a pod.*

1.4 Úloha bioštatistika pri tvorbe vedeckých štúdií

Vedeckú štúdiu charakterizujeme ako validnú nielen na základe jej výsledkov, ale aj na základe jej plánu. Často sa hovorí „Rob to správne alebo to radšej nerob.“ (**Aplikovaný**) **výskumník** (biológ, antropológ alebo lekár), ktorý vo svojom výskume aplikuje (používa) metódy štatistickej analýzy (takýto výskum štatistickí často nazývajú **aplikovaný výskum**) si často kladú otázku, či potrebujú bioštatistika vo svojom vedeckom tíme. Odpoveď znie jednoznačne áno, pretože bioštatistik môže nielen optimalizovať plán štúdie, analyzovať dáta a interpretovať výsledky, ale môže aj načrtnúť závery. Bioštatistik by sa mal stať členom riešiteľského kolektívu čo najskôr – už na začiatku plánovania štúdie, lebo zle navrhnutú štúdiu, ktorá sa už začala, nemôže zachrániť, rovnako ako nemôže analyzovať zle zozbierané dáta alebo interpretovať výsledky z nevhodne použitých štatistických analýz. Hoci úloha bioštatistika pri štatistickej analýze je celkom očividná, výskumníci si dobre neuvedomujú jeho dôležitosť už pri plánovaní štúdie a vývoji výskumného protokolu. Je dôležité mať na zreteli veľký význam dopredu naplánovaného zberu dát, správne naformulovaných a realistických hypotéz a správne naplánovanej, vykonanej a interpretovanej štatistickej analýzy. Na ich základe musí byť výskumník schopný správne zhodnotiť a interpretovať vedeckú hypotézu/hypotézy. Bioštatistik teda dokáže poradiť aj v dobrej previazanosti hypotéz, ktoré priamo korešpondujú s plánom štúdie.

Interakcia s bioštatistikom. Interakcia (aplikovaného) výskumníka s bioštatistikom je dlhodobý proces, ktorý predstavuje sériu kontaktov, e-mailov alebo telefonátov, počas ktorých výskumník musí koncepčne pochopiť navrhovanú štatistickú metodológiu a terminológiu. Následky zle vyvinutého štatistického prístupu môžu nielen znemožniť získanie grantových prostriedkov na výskum, ale môžu

najmä poškodiť vedeckú štúdiu pre neschopnosť adekvátne testovať navrhované hypotézy. Krátka a oneskorená konzultácia so štatistikom nestačí na vyriešenie všetkých problémov.

Bioštatistik. Bioštatistik musí počas stretnutí s (aplikovaným) výskumníkom koncepcne pochopiť navrhovanú biologickú, antropologickú alebo lekársku metodológiu a terminológiu. (Aplikovaný) výskumník nesmie chápať bioštatistiku a jeho podiel na výskume ako servis, ale ako rovnocennú spoluprácu dvoch (alebo viacerých) vzájomne sa dopĺňujúcich odborov. Tak ako antropológia nie je servisom archeológie, ani štatistika nie je servisom antropológie. Rovnaký princíp platí aj pre spoluprácu bioštatistika s biológom či lekárom.

Vedecká etika. Kvalitný plán štúdie definuje vedecké výhody v porovnaní s rizikami, ktoré na seba berú zaangażované subjekty. Ak je plán štúdie chybný, alebo sa dáta nesprávne analyzovali, potom štúdia nemôže byť odobrená po etickej stránke ani schválená inštitucionálnou vedeckou komisiou.

Medzi základné úlohy (otázky) bioštatistika pri vývoji štatistického plánu patrí:

- Ujasnenie vedeckých otázok. Sú primárne hypotézy jednoznačne formulované, primerané a realistické?
- Identifikácia závislých premenných priamo súvisiacich s vedeckou otázkou/otázkami. Sú základné alebo vedľajšie závislé premenné jednoznačne definované?
- Podáva plán vedeckej štúdie primeraný obraz o navrhovaných hypotézach?
- Sú otázky ohľadom výchyľky, zaslepenia alebo stratifikácie primerane ošetrené a jednoznačne opísané?
- Obsahuje plán vedeckej štúdie jasne špecifikovaný a vhodný plán štatistickej analýzy?
- Sú dáta zozbierané na základe opísaných kritérií, obsahuje štúdia bezpečný plán sledovania alebo pravidiel ukončenia štúdie?
- Je zaistená interná a externá validita štúdie?

Otázky, ktoré zaujímajú bioštatistika:

- Aká je vedecká hypotéza?
- O aký typ plánu štúdie ide?
- Ktorá závislá premenná je najdôležitejšia?
- O aký typ premennej ide a v akých jednotkách sa merala?
- Aký je klinicky/biologicky/antropologicky dôležitý efekt pre primárnu závislú premennú?
- Koľko subjektov možno získať alebo pozorovať v rámci výskumu?
- Koľko skupín alebo typov vyšetrení a pod. bude zahrnutých v pláne štúdie?
- Koľko je sledovaných prediktorov? V akých jednotkách sa merajú?
- Bude každá skupina obsahovať rovnaký počet pozorovaní, t.j. aký je alokačný pomer?
- Ak ide o opakované merania, koľko ich je a aký je časový interval medzi meraniami?

2 Model rozdelenia pravdepodobnosti a štatistický model

Pri riešení biomedicínskych problémov pomocou matematickej štatistiky sa vyskytuje stochastický (náhodný) element, ktorým sa nie je možné zaoberať len pomocou základných zákonov aritmetiky. Preto štatistické metódy potrebujú stochastické modely. Vývoj takýchto modelov tvorí *deduktívny*¹ (matematický) aspekt štatistiky. Štatistické problémy sú však *induktívne*², pretože vznikajú ako dôsledok pozorovania istých javov v reálnych biomedicínskych situáciách. Tieto javy sú výsledkom nejakého experimentu alebo pozorovania. Otázky, ktoré experiment alebo pozorovanie rieši, sú všeobecnejšieho typu. Pýtajú sa na niečo, čo nie je priamo pozorovateľné, ale je logicky obsahnuté v dátach. Hovoríme, že usudzujeme („inferujeme“) niečo na základe dát. Na riešenie deduktívnych problémov matematiky často postačuje čiastočne dostupná informácia, aby sme boli schopní vytvoriť novú matematickú vetu. Na riešenie induktívnych problémov štatistiky potrebujeme všetky dostupné dáta. Len tak môžeme vyvodiť závery. Ignorovanie nejakej časti dát nie je akceptovateľné. Pri deduktívnych problémoch je kvalita novej matematickej vety rovnaká ako kvalita jej predchádzajúcich axiém, definícií alebo viet. Pri induktívnych problémoch je stupeň istoty v záveroch väčší ako v samotných dátach. Čím máme viac dát, tým sa kvalita výstupov zväčšuje. Avšak jedno nové pozorovanie môže naše závery zmeniť.

Dáta môžeme jednoducho popísať aj pomocou **charakteristík (parametrov) polohy a variability** a zobraziť ich pomocou **štatistickej grafiky** (pozri kap. Charakteristiky polohy a variability a štatistická grafika), čo je súčasťou tzv. **exploratórnej analýzy dát** (EDA). Avšak použitím nejakého modelu sa o dátach dozvieme viac v zjednodušenej podobe, tento model nám navyše umožní interpretáciu výsledkov a uľahčí nám aj komunikáciu medzi dátami a biomedicínskou praxou.

Koncepcia modelu rozdelenia pravdepodobnosti a štatistického modelu predstavuje jeden zo základných piliérov bioštatistiky. Tieto modely sú charakterizované ich parametrami v prípade parametrického modelu, ktorým sa budeme podrobnejšie zaoberať. Jeho parametre slúžia na jednoduchú charakterizáciu dát a zjednodušujú interpretáciu výsledkov. Modely rozlišujeme podľa toho, či sú to modely na diskretné alebo spojité dáta. **Model rozdelenia pravdepodobnosti** je charakterizovaný funkciou hustoty a distribučnou funkciou na základe presne špecifikovaných parametrov, ktoré je potrebné odhadnúť z dát pomocou funkcie vierohodnosti – ide teda o „model na dáta“³. Dáta sú realizáciami nahodnej premennej, o ktorej predpokladáme, že má asymptoticky (pre veľké n) nejaké rozdelenie, napr. normálne, binomické, multinomické, súčinnové multinomické alebo Poissonove. Tento asymptotický predpoklad je fundamentálnym základom štatistickej inferencie, ktorá je procesom vyvodenia záverov (na základe dát a z nich vypočítaných odhadov parametrov) prostredníctvom postupu testovania hypotéz, ktorý používa tzv. štatistiku, testovacie štatistiky a ich asymptotické rozdelenia pravdepodobnosti (pozri kap. Testovanie hypotéz). Hypotézy testujeme aj v **štatistických modeloch**, ktoré často predstavujú modely kauzálnej závislosti závislých premenných na prediktorech. V týchto modeloch pomocou funkcie vierohodnosti odhadujeme parametre, ktoré zjednodušujú interpretácie výsledkov, či už štatistiky nesignifikantných alebo signifikantných, ale aj biologicky (medicínsky) nevýznamných alebo významných.

Všetky vyššie uvedené postupy sú súčasťou širšieho pojmu **(bio)štatistická analýza**. Bez správnej formulácie a aplikácie modelu rozdelenia pravdepodobnosti a štatistického modelu na dáta by štatistická analýza nebola možná a závery z nej by boli problematické.

Základom každej empirickej štúdie, či už experimentálnej alebo observačnej, je zabezpečiť **dáta** (**dátový súbor, realizácie**), ktoré označíme \mathbf{x} , procesom, ktorý nazývame **experiment (pokus)** alebo **meranie**. V najjednoduchšej podobe $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$ (vektor pozorovaní, vektor výberových hodnôt, vektor realizácií), kde n je **rozsah (náhodného) výberu** a x_i sú realizácie vždy označované malými písmenami (všeobecne ozn. x). (Jednorozmerná) **náhodná premenná X** je funkcia z výberového priestoru \mathcal{Y} (označovaná aj ako priestor elementárnych udalostí alebo množina

¹Dedukcia – na základe všeobecne platných záverov hľadáme riešenia nejakého konkrétneho prípadu.

²Indukcia – na základe konkrétnych prípadov vyvodzujeme všeobecnejšie platné závery.

³Model rozdelenia pravdepodobnosti je možné použiť aj v súvislosti so štatistikou – tu ide o „model pre štatistiku“ a s testovacou štatistikou – tu ide o „model pre testovaciu štatistiku“, ale aj v súvislosti s chybami štatistického modelu – tu ide o „model pre chyby (reziduály)“.

výsledkov náhodného pokusu) do množiny reálnych čísel \mathbb{R} . Pozorovanie x je realizáciou náhodnej premennej X . Analogicky môžeme definovať **k -rozmerný náhodný vektor** $(X_1, X_2, \dots, X_k)^T$. Príkladom takéhoto vektora je dvojrozmerný náhodný vektor $(X_{1i}, X_{2i})^T$, $i = 1, 2, \dots, n$, s realizáciami $(x_{1i}, x_{2i})^T$ usporiadanými po riadkoch do matice $n \times 2$, ktorá je v tomto prípade dátovým súborom⁴.

Príklad 46 (príklady náhodných premenných) (1) Chirurg vykoná 100 transplantácií srdca, kde náhodná premenná X je napr. počet úspešne vykonaných transplantácií. (2) 50 bežcov beží maratón, kde náhodná premenná X je napr. čas odbehnutia maratónu v hodinách. (3) Hodíme 30-krát kockou, kde náhodná premenná X je napr. počet hodených šestiek. (4) Na 75 deťoch vo veku 10 rokov zmeriame výšku (v metroch) a hmotnosť (v kilogramoch), kde náhodná premenná X je napr. Rohrerov index ($RI = \frac{\text{hmotnosť v kg}}{(\text{výška v m})^3}$).

Príklad 47 (porovnanie dvoch typov modelov) Model rozdelenia pravdepodobnosti je modelom náhodnej premennej X , napr. model rozdelenia pravdepodobnosti náhodnej premennej X šírka dolnej čeľuste alebo (2) model rozdelenia pravdepodobnosti náhodnej premennej X hrúbka kožných rias u dospelých zdravých žien. Štatistický model je modelom náhodnej premennej $Y|X$ (Y kauzálne závisí na X), napr. (1) model závislosti náhodnej premennej Y šírka dolnej čeľuste na premennej X pohlavie alebo (2) model závislosti náhodnej premennej Y hrúbka kožných rias u dospelých zdravých žien na premennej X BMI. Všimnime si, že náhodné premenné označujeme X alebo Y podľa toho, aký model ich charakterizuje.

Základný predpoklad je, že nejaké pozorovanie (výberová hodnota, realizácia) x je hodnota (realizácia) **náhodnej premennej** X a našim cieľom je použiť x na vyvodenie záverov o neznámom modeli (rozdelenia pravdepodobnosti alebo štatistickom) $F_*(\cdot)$ premennej X . Naše závery o $F_*(\cdot)$ sú zaťažené neistotou kvôli náhodnosti X , z ktorej pochádzajú x . Cieľom je zabezpečiť,

1. aby stupeň neistoty bol čo možno najmenší, berúc do úvahy náhodnosť X ,
2. a aby bol tento stupeň neistoty vyjadrený v našich záveroch.

Ekvivalentne $(x_1, x_2, \dots, x_k)^T$ je realizácia náhodného vektora $(X_1, X_2, \dots, X_k)^T$ a našim cieľom je použiť túto realizáciu na vyvodenie záverov o neznámom k -rozmernom modeli $F_*^{(k)}(\cdot)$ náhodného vektora $(X_1, X_2, \dots, X_k)^T$.

Definícia 14 (štatistická inferencia) Štatistická inferencia (zriedkavo nazývaná aj štatistická indukcia) je proces vyvodenia záverov na základe dát prostredníctvom testovania hypotéz, modelu rozdelenia pravdepodobnosti alebo štatistického modelu (Cox, 2006). Tento proces je ovplyvnený náhodnými chybami, náhodným výberom, voľbou testovacieho kritéria, štatistického modelu alebo modelu rozdelenia pravdepodobnosti. Výsledkom tohto procesu sú zmysluplné závery aplikované na dobre definované dostatočne všeobecné situácie.

Podstata vytvárania realizácií x limituje možnosti voľby modelu F_* . Inferencia bude o to presnejšia, o čo lepšie bude vybraná čo najmenšia množina \mathcal{F} tak, aby $F_* \in \mathcal{F}$, kde \mathcal{F} nazývame **množinou modelov** (štatistických modelov a modelov rozdelenia pravdepodobnosti). V mnohých prípadoch predpokladáme, že $X_i, i = 1, 2, \dots, n$, sú **rovnako rozdelené náhodné premenné** (ozn. iid; *independently identically distributed*). V tomto prípade hovoríme o **jednoduchom náhodnom výbere** (srs; *simple random sample*) s rozsahom n , kde X je charakterizované rozdelením $F_*(\cdot)$.

Príklad 48 (jednoduchý náhodný výber) V jednoduchom náhodnom výbere s rozsahom n z populácie s konečným rozsahom N má každý prvok rovnakú pravdepodobnosť vybratia. Ak vyberáme bez vrátenia, hovoríme o **jednoduchom náhodnom výbere bez vrátenia** (Dalgaard, 2008). Ak vyberáme s vrátením, hovoríme o **jednoduchom náhodnom výbere s vrátením**. Majme množinu \mathcal{M} s $N = 10$

⁴Pre dvojrozmerný náhodný vektor sa často používa ozn. $(X, Y)^T$ a pre jeho realizáciu ozn. $(x, y)^T$.

prvkami a chceme z nej vybrať $n = 3$ prvkov (a) bez vrátenia a (b) s vrátením. Koľko máme možností? Ako vyzerá jedna takáto možnosť, ak ide o množinu $\mathcal{M} = \{1, 2, \dots, 10\}$. Zopakujte to isté pre $N = 100$, $n = 30$ a množinu $\mathcal{M} = \{1, 2, \dots, 100\}$.

Riešenie aj v \mathbb{R}

(a) Spolu máme $\binom{N}{n}$ možných náhodných výberov (kombinácie bez opakovania n -tej triedy z N prvkov množiny \mathcal{M}). Ak $N = 10$ a $n = 3$, potom kombinačné číslo $\binom{N}{n} = \frac{N!}{(N-n)!n!} = \binom{10}{3} = 120$ možností. Ak $N = 100$ a $n = 30$, potom $\binom{N}{n} = \binom{100}{30} = 2.937234 \times 10^{25}$ možností.

```

1 | choose(10,3) # pocet vsetkych moznych vyberov bez vratenia
2 | choose(100,30)
3 | library(utils)
4 | combn(10,3) # pocet vsetkych moznych vyberov bez vratenia
5 | combn(100,30)
6 | sample(x=1:10, size=3, replace=FALSE) # jednoduchy nahodny vyber bez vratenia
7 | sample(x=1:100, size=30, replace=FALSE)

```

(b) Spolu máme $\binom{N+n-1}{n}$ možných náhodných výberov (kombinácie s opakováním n -tej triedy z N prvkov množiny \mathcal{M}). Ak $N = 10$ a $n = 3$, potom $\binom{N+n-1}{n} = \frac{(N+n-1)!}{(N-1)!n!} = \binom{10+3-1}{3} = 220$ možností. Ak $N = 100$ a $n = 30$, potom $\binom{N+n-1}{n} = \binom{100+30-1}{30} = 2.009491 \times 10^{29}$ možností.

```

8 | choose(10+3-1,3) # pocet vsetkych moznych vyberov s vratenim
9 | choose(100+30-1,30)
10 | library(utils)
11 | combn(10+3-1,3) # pocet vsetkych moznych vyberov s vratenim
12 | combn(100+30-1,30)
13 | sample(x=1:10, size=3, replace=TRUE) # jednoduchy nahodny vyber s vratenim
14 | sample(x=1:100, size=30, replace=TRUE)

```

Príklad 49 (jednoduchý náhodný výber) *Nech je skupina ľudí označená identifikačnými číslami (ID) od 1 do 30. Vyberte (a) náhodne 5 ľudí z 30 bez návratu, (b) náhodne 5 ľudí z 30 s návratom a nakoniec (c) náhodne 5 ľudí z 30 bez návratu, kde ľudia s ID od 28 do 30 majú pravdepodobnosť vybratia $4 \times$ väčšiu ako ľudia s ID od 1 do 27.*

Riešenie v \mathbb{R}

```

15 | sample(x=1:30, size=5, replace=FALSE)
16 | sample(x=1:30, size=5, replace=TRUE)
17 | sample(x=1:30, size=5, prob=c(rep(1/39, 27), rep(4/39, 3)), replace=FALSE)

```

Distribučná funkcia F náhodnej premennej X je definovaná ako $F_X(x) = \Pr(X < x)$, kde zápis znamená pravdepodobnosť, že náhodná premenná X nadobúda hodnoty menšie alebo rovné ako nejaké číslo x , ktoré nazývame *kvantil*. Dolný index v F_X sa spravidla vynecháva a píšeme F .

Náhodná premenná X sa nazýva **diskrétna**, ak jej distribučná funkcia F je schodovitá funkcia. V tomto prípade hovoríme, že ide o **diskrétne rozdelenie** a množina \mathcal{Y} , z ktorej pochádzajú X je konečná alebo nanaajvyš spočítateľná (má spočítateľne veľa prvkov).

Distribučná funkcia diskkrétnej náhodnej premennej X je definovaná ako (Azzalini, 1996)

$$F_X(x) = \Pr(X \leq x) = \sum_{i: x_i \leq x} \Pr(X = x_i),$$

kde $\sum_{i=1}^{k(\infty)} p_i = 1$, $\Pr(X = x_i) = p_i = f_X(x_i) = f(x_i), \forall x_i$, sa nazýva **pravdepodobnostná funkcia**. Často zapisujeme $\{x_i, p_i\}_{i=1}^{k(\infty)}$, kde x_i sú realizácie, p_i sú pravdepodobnosti výskytu x_i , $k \in \mathbb{N}^+$, kde \mathbb{N}^+ znamená množinu kladných prirodzených čísel⁶.

⁵Detaily o jazyku \mathbb{R} pozri napr. v Chambers (2008), Becker a kol. (1988) alebo Matloff (2011).

⁶Písmeno \mathbb{N} sa v angličtine nazýva *blackboard bold N* (double-struck capital N).

Príklad 50 (diskrétna premenná) (1) počet úspešne vykonaných transplantácií v SR, (2) počet hodených šestiek, (3) štyri vekové kategórie, do ktorých zaradíme subjekty, (4) pohlavie, (5) počet starších súrodencov (o.sib.N; dve kategórie; dáta: two-samples-means-birth.txt), (6) vzdelanie matky (edu.M, štyri kategórie; dáta: anova-newborns.txt).

Náhodná premenná X sa nazýva **spojitá**, ak jej distribučná funkcia F je absolútne spojitá funkcia. V tomto prípade hovoríme, že ide o **spojité rozdelenie** a množina \mathcal{Y} je nekonečná (má nekonečne veľa prvkov).

Distribučná funkcia spojitaj náhodnej premennej X je definovaná ako

$$F_X(x) = \int_{-\infty}^x f(t) dt, f(x) \geq 0,$$

kde $\int_{-\infty}^{\infty} f(x) dx = 1$, $f_X(x) = f(x) = \frac{\partial}{\partial x} F_X(x)$ sa nazýva **hustota**.

Príklad 51 (spojitá premenná) (1) čas odbehnutia maratónu v hodinách; (2) hmotnosť v kilogramoch; (3) výška v centimetroch; (4) Rohrerov index; (5) dĺžkošírkový index lebky vypočítaný ako podiel náhodných premenných najväčšia šírka mozgovne a najväčšia dĺžka mozgovne (skull.B a skull.L; v mm; dáta: one-sample-mean-skull-mf.txt); (6) stranový rozdiel vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej a ľavej strane tela (length.R a length.L; v mm; dáta: paired-means-clavicle2.txt); (7) najväčšia výška mozgovne a morfológická výška tváre (skull.pH a face.H; v mm; dáta: one-sample-correlation-skull-mf.txt).

Rozmery na živom objekte nemožno merať s absolútnou presnosťou a počet desatinných miest závisí na presnosti merania; ako posledné desatinné miesto by sa malo uvádzať to, na ktorom sa pri opakovanom meraní rovnakého objektu na viac desatinných miest zhodujú všetky merania.

Príklad 52 (normálne rozdelenie) Majme náhodnú premennú X (môže to byť napr. výška postavy 10-ročných dievčat) a predpokladáme, že má normálne rozdelenie s parametrami μ (stredná hodnota) a σ^2 (rozptyl), čo zapisujeme ako $X \sim N(\mu, \sigma^2)$, $\mu = 140.83$, $\sigma^2 = 33.79$. Normálne rozdelenie predstavuje model rozdelenia pravdepodobnosti pre túto náhodnú premennú. Vypočítajte pravdepodobnosť $\Pr(a \leq X < b) = \Pr(X < b) - \Pr(X < a) = F_X(b) - F_X(a)$, kde $a = \mu - k\sigma$, $b = \mu + k\sigma$, $k = 1, 2, 3$.

Riešenie (aj v \mathbb{R}); (pozri obrázok 2.1)

$$a = \mu - \sigma = 135.0171, b = \mu + \sigma = 146.6429,$$

$$\Pr(|X - \mu| > \sigma) = 0.3173, \Pr(|X - \mu| < \sigma) = 1 - 0.3173 = 0.6827,$$

$$a = \mu - 2\sigma = 129.2042, b = \mu + 2\sigma = 152.4558,$$

$$\Pr(|X - \mu| > 2\sigma) = 0.0455, \Pr(|X - \mu| < 2\sigma) = 1 - 0.0455 = 0.9545,$$

$$a = \mu - 3\sigma = 123.3913, b = \mu + 3\sigma = 158.2687,$$


$$\Pr(|X - \mu| > 3\sigma) = 0.0027, \Pr(|X - \mu| < 3\sigma) = 1 - 0.0027 = 0.9973.$$

Pozn.: Pravdepodobnosť $\Pr(a < X < b) = \Pr(a \leq X \leq b)$, pretože pravdepodobnosť v bode (tu a a b) je rovná nule pre spojité premenné, t.j. $\Pr(a) = \Pr(b) = 0$. Pre diskrétné premenné to neplatí.

Alternatívny výpočet cez štandardizované normálne rozdelenie (syn. normálne normované rozdelenie) je nasledovný:

```
18 | mu <- 0
19 | sig <- 1
20 | bin <- seq(mu-3*sig, mu+3*sig, by=sig)
21 | pnorm(bin[7])-pnorm(bin[1]) # 0.9973002
22 | pnorm(bin[6])-pnorm(bin[2]) # 0.9544997
23 | pnorm(bin[5])-pnorm(bin[3]) # 0.6826895
```

Dostaneme pravidlo 68.27 – 95.45 – 99.73 (tzv. „miery normálneho rozdelenia“).



Obr. 2.1: Miery normálneho rozdelenia; krivka hustoty s vyfarbeným obsahom pod touto krivkou medzi príslušnými kvantilmi na osi x ; obsah je rovný pravdepodobnosti výskytu subjektov s danou výškou v rozpätí týchto kvantilov

Príklad 53 (normálne rozdelenie) Majme $X \sim N(\mu, \sigma^2)$, kde $\mu = 150, \sigma^2 = 6.25$. Vypočítajte $a = \mu - x_{1-\alpha/2}\sigma$ a $b = \mu + x_{1-\alpha/2}\sigma$ tak, aby $\Pr(a \leq X \leq b) = 1 - \alpha$, bola rovná 0.90, 0.95 a 0.99. Číslo $x_{1-\alpha}$ je kvantil normálneho normovaného rozdelenia, t.j. $\Pr(Z = \frac{X-\mu}{\sigma} < x_{1-\alpha}) = 1 - \alpha, Z \sim N(0, 1)$.

Riešenie (aj v \mathbb{R}); (pozri obrázok 2.2)

$\Pr(\mu - x_{1-\alpha/2}\sigma < X < \mu + x_{1-\alpha/2}\sigma) = \Pr(X < \mu + x_{1-\alpha/2}\sigma) - \Pr(X < \mu - x_{1-\alpha/2}\sigma) = 1 - \alpha = 0.9$. Z -transformáciou⁷ na normálne normované rozdelenie dostaneme $\Pr(-x_{1-\alpha/2} < Z < x_{1-\alpha/2}) = 0.9$, kde $\frac{\mu - x_{1-\alpha/2}\sigma - \mu}{\sigma} = -x_{1-\alpha/2}, \frac{\mu + x_{1-\alpha/2}\sigma - \mu}{\sigma} = x_{1-\alpha/2}, x_{1-\alpha} = x_{0.95} = 1.64$, t.j. 90.00 % dát leží v intervale $\mu \pm 1.64\sigma$.

$\Pr(a < X < b) = 0.95$. Potom $x_{0.975} = 1.96$, t.j. 95.00 % dát leží v intervale $\mu \pm 1.96\sigma$.

$\Pr(a < X < b) = 0.99$. Potom $x_{0.995} = 2.58$, t.j. 99.00 % dát leží v intervale $\mu \pm 2.58\sigma$.

```

24 | Q95 <- qnorm(0.95,0,1) # 1.644854
25 | Q05 <- qnorm(0.05,0,1) # -1.644854
26 | Q975 <- qnorm(0.975,0,1) # 1.959964
27 | Q025 <- qnorm(0.025,0,1) # -1.959964
28 | Q995 <- qnorm(0.995,0,1) # 2.575829
29 | Q005 <- qnorm(0.005,0,1) # -2.575829

```

Dostaneme pravidlo 90 – 95 – 99 (tzv. „upravené miery normálneho rozdelenia“). Použili sme nerovnosť $\Pr(x_{\alpha/2} < Z < x_{1-\alpha/2}) = \Phi(x_{1-\alpha/2}) - \Phi(x_{\alpha/2}) = 1 - \alpha$, kde Φ je distribučná funkcia normálneho normovaného rozdelenia a všeobecne $\alpha \in (0, 1/2)$; v príklade $\alpha = 0.1, 0.05$ a 0.01 .

Príklad 54 (normálne rozdelenie) Predpokladajme model normálneho rozdelenia $N(132, 13^2)$ pre systolický krvný tlak. Aká časť populácie (v %) bude mať hodnoty väčšie ako 160 mm Hg?

Riešenie (aj v \mathbb{R})

Pomocou Z -transformácie dostaneme

$$\Pr(X > 160) = \Pr\left(\frac{X-132}{13} > \frac{160-132}{13}\right) = \Pr\left(\frac{X-132}{13} > 2.154\right) = 0.016.$$


```

30 | (1-pnorm(160,mean=132,sd=13))*100 # 1.562612 %
31 | z.transf <- (160-132)/13
32 | (1-pnorm(z.transf))*100 # 1.562612 %

```

Teda asi 1.6 % populácie z $N(132, 13^2)$ bude mať systolický krvný tlak väčší ako 160 mm Hg.

⁷ Z -transformácia je spôsob transformácie náhodnej premennej $X \sim N(\mu, \sigma^2)$ pomocou centrovania strednou hodnotou μ a normovania smerodajnou odchýlkou σ , kde $Z = \frac{X-\mu}{\sigma}$; $Z \sim N(0, 1)$.



Obr. 2.2: Upravené miery normálneho rozdelenia; krivka hustoty s vyfarbeným obsahom pod touto krivkou medzi príslušnými kvantilmi na osi x ; obsah je rovný pravdepodobnosti výskytu subjektov s danou normovanou výškou v rozpätí týchto kvantilov

Príklad 55 (binomické rozdelenie) Predpokladajme, že počet ľudí uprednostňujúcich liečbu A pred liečbou B sa správa podľa modelu binomického rozdelenia s parametrami p (pravdepodobnosť výskytu udalosti) a N (rozsah náhodného výberu), ozn. $\text{Bin}(N, p)$, kde $N = 20, p = 0.5$, t.j. ľudia preferujú oba typy liečby rovnako. (a) Aká je pravdepodobnosť, že bude 16 a viac pacientov uprednostňovať liečbu A pred liečbou B ? (b) Aká je pravdepodobnosť, že bude 16 a viac a zároveň 4 alebo menej pacientov uprednostňovať liečbu A pred liečbou B ?

Riešenie (aj v \mathbb{R})

(a) $\Pr(X \geq 16) = 1 - \sum_{i: x_i \leq 15} \Pr(X = x_i) = 1 - \sum_{i: x_i \leq 15} \binom{N}{x_i} p^{x_i} (1-p)^{N-x_i} = 1 - \sum_{i: x_i \leq 15} \binom{20}{x_i} 0.5^{x_i} (1-0.5)^{20-x_i} = 0.006$.

```
33 | pbinom(16, size=20, prob=0.5) # 0.9987116
34 | 1-pbinom(16, size=20, prob=0.5) # 0.001288414
```

Z vyššie uvedeného \mathbb{R} -kódu vyplýva, že ide o pravdepodobnosť $\Pr(X \leq 16)$ a $\Pr(X > 16)$, ale my potrebujeme $\Pr(X \geq 16)$. Preto \mathbb{R} -kód upravíme nasledovne

```
35 | 1-pbinom(15, size=20, prob=0.5) # 0.005908966
36 | sum(choose(20, 16:20) * 0.5^(16:20) * 0.5^(20-16:20)) # 0.005908966
```

(b) $\Pr(X \leq 4, X \geq 16) = 1 - \sum_{i: x_i \leq 15} \Pr(X = x_i) + \sum_{i: x_i \leq 4} \Pr(X = x_i) = 0.012$. Táto pravdepodobnosť je dvojnásobkom predchádzajúcej pravdepodobnosti, lebo $\text{Bin}(N, 0.5)$ je symetrické okolo 0.5, t.j.

```
37 | 1-pbinom(15, size=20, prob=0.5) + pbinom(4, size=20, prob=0.5) # 0.01181793
```

Príklad 56 (binomické rozdelenie) Predpokladajme, že pohlavie novorodencov (mužské alebo ženské) sa správa podľa modelu binomického rozdelenia s parametrami p (pravdepodobnosť výskytu chlapcov) a N (rozsah náhodného výberu), ozn. $\text{Bin}(N, p)$, kde $N = 1113, p = 0.52$, t.j. rodí sa o niečo viac chlapcov než dievčat (dáta: *two-samples-probabilities-sexratio.txt*). Aká je pravdepodobnosť, že sa narodí 700 a viac dievčat?

Príklad 57 (binomické rozdelenie) Predpokladajme, že $\Pr(\text{vír}) = 0.533 = p_1$ je pravdepodobnosť výskytu dermatoglyfického vzoru *vír* na palci pravej ruky mužov českej populácie a $\Pr(\text{ostatné}) = 0.467 = p_2$ je pravdepodobnosť výskytu ostatných vzorov na palci pravej ruky mužov českej populácie,

pričom X je počet vírov a Y je počet ostatných vzorov, kde $X \sim \text{Bin}(N, p_1)$ a $Y \sim \text{Bin}(N, p_2)$. Vypočítajte (1) $\Pr(X \leq 120)$, keď $N = 300$ a (2) $\Pr(Y \leq 120)$, keď $N = 300$.

\mathcal{F} môže byť nejaká množina **distribučných funkcií** identifikovateľných pomocou parametra θ z parametrického priestoru $\Theta \in \mathbb{R}^k$ (\mathbb{R} znamená množinu reálnych čísel⁸), čo môžeme formálne zapísať ako (Azzalini, 1996)

$$\mathcal{F} = \{F(\cdot; \theta) : \theta \in \Theta \subseteq \mathbb{R}^k\},$$

kde pre každé fixné θ je $F(\cdot; \theta)$ distribučnou funkciou, ktorej nosič je $\mathcal{Y}_\theta \subseteq \mathbb{R}^n$. **Nosič** \mathcal{Y}_θ je najmenšia množina, na ktorej je hustota definovaná. Výberový priestor je množina \mathcal{Y} všetkých možných hodnôt x , ktoré charakterizujeme modelom. Formálne $\mathcal{Y} = \cup_{\theta \in \Theta} \mathcal{Y}_\theta$. Často však \mathcal{Y}_θ je rovnaký pre všetky θ , a preto koinciduje s \mathcal{Y} .

Príklad 58 (parametre) Príklady parametrov θ – stredná hodnota μ , rozptyl σ^2 , korelačný koeficient ρ , pravdepodobnosť p výskytu nejakej udalosti, rozdiel dvoch stredných hodnôt $\mu_1 - \mu_2$, podiel dvoch rozptylov σ_1^2/σ_2^2 , rozdiel dvoch korelačných koeficientov $\rho_1 - \rho_2$, rozdiel dvoch pravdepodobností $p_1 - p_2$ a pod.

Príklad 59 (parametre) Príkladmi parametrov môžu byť: (1) stredná hodnota μ a (2) rozptyl σ^2 dĺžky lebky (skull-L, v mm) egyptskej stredovekej mužskej populácie; (3) rozdiel medzi strednými hodnotami $\mu_1 - \mu_2$ dĺžky lebky mužskej a ženskej; (4) podiel rozptylov σ_1^2/σ_2^2 hodnôt dĺžky lebky u mužov a u žien (dáta: two-samples-means-skull.txt); (5) korelačný koeficient ρ medzi dĺžkou dolnej končatiny (lowex.L, v mm) a dĺžkou trupu (tru.L, v mm); (6) rozdiel korelačných koeficientov $\rho_1 - \rho_2$ medzi dĺžkou dolnej končatiny a dĺžkou trupu u mužov a u žien (dáta: two-samples-correlations-trunk.txt); (7) pravdepodobnosť p výskytu mužov (sex; m – muž, f – žena); (8) pravdepodobnosť výskytu popôrodných zmiern na ženských panvových kostiach u Afričaniek, ako aj rozdiel pravdepodobností $p_1 - p_2$ výskytu výrazných popôrodných zmiern na panvových kostiach Afričaniek a Inuitiek (dáta: more-samples-probabilities-pubis.txt); (9) rozdiel pravdepodobností $p_1 - p_2$ sexuálnej orientácie na opačné pohlavie (sexor – sexuálna orientácia; op – výlučne na opačné pohlavie, sa – minimálne/občas na rovnaké pohlavie) u mužov a žien (dáta: anova-head.txt).

Čítanie označení. Pojem „model rozdelenia pravdepodobnosti“ sa často skrakuje na „rozdelenie“. Potom hovoríme, že „ X má rozdelenie $F_X(x)$ “, „ X je charakterizované rozdelením $F_X(x)$ “ alebo „ X pochádza z rozdelenia $F_X(x)$ “, čo označujeme ako $X \sim F_X(x)$, kde symbol „ \sim “ čítame ako „je rozdelená ako“ alebo „pochádza z rozdelenia“ (často sa uvádza aj pojem „**asymptoticky**“, čo znamená „pre veľké n “). Mohli by sme písať aj $X \sim f_X(x)$, to sa však používa len zriedkavo. Ak porovnávame rozdelenia dvoch náhodných premenných X a Y , hovoríme „ X a Y majú rovnaké rozdelenie“ alebo „ X a Y sú rovnako rozdelené“, ozn. $X \sim Y$ alebo $F_X(x) \sim F_Y(y)$. Pojem „štatistický model“ sa často skrakuje na „model“.

Tri typy priestorov. Výberový priestor \mathcal{Y} súvisí s náhodnou premennou a jej realizáciou, **nosič** \mathcal{Y}_θ súvisí s hodnotami, na ktorých je definovaná hustota rozdelenia pravdepodobnosti a **parametrický priestor** Θ súvisí s parametrom θ .

Príklad 60 (binomické rozdelenie) Ak $X \sim \text{Bin}(N, \theta)$, $\theta = p \in \langle 0, 1 \rangle$, potom \mathcal{Y}_θ je rovnaký pre všetky θ a koinciduje s výberovým priestorom $\mathcal{Y} = \{0, 1, \dots, N\}$.

⁸ \mathbb{R}^k znamená k -rozmernú množinu reálnych čísel (k je dĺžka vektora parametrov $\theta \in \Theta$), kde ak $k = 1$, potom $\theta \in \Theta$ je číslo (skalár). \mathbb{R}^n znamená n -rozmernú množinu reálnych čísel (n je rozsah náhodného výberu). \mathbb{R}^+ znamená množinu kladných reálnych čísel.

Aproximácia binomického rozdelenia normálnym. Ak $X \sim \text{Bin}(N, p)$, $Np > 5$ a $Nq > 5$, kde $q = 1 - p$, potom rozdelenie náhodnej premennej X môžeme aproximovať normálnym rozdelením, kde $X \sim N(Np, Npq)$; príklady pozri v tabuľke 2.1.

Tabuľka 2.1: Príklady minimálnych N pre fixované p potrebných na aproximáciu

p	0.1	0.2	0.3	0.4	0.5
q	0.9	0.8	0.7	0.6	0.5
N	51	26	17	13	11

Príklad 61 (aproximácia binomického rozdelenia normálnym) Nech $\Pr(\text{muž}) = 0.515$ znamená pravdepodobnosť výskytu mužov v populácii a $\Pr(\text{žena}) = 0.485$ pravdepodobnosť výskytu žien. Nech X je počet mužov a Y počet žien. Za predpokladu modelu $\text{Bin}(N, p)$ vypočítajte (a) $\Pr(X \leq 3)$, ak $N = 5$, (b) $\Pr(X \leq 5)$, ak $N = 10$ a (c) $\Pr(X \leq 25)$, ak $N = 50$. Porovnajte vypočítané pravdepodobnosti s pravdepodobnosťami aproximovanými normálnym rozdelením $N(Np, Npq)$.

Riešenie (aj v \mathbb{R}) (pozri obrázok 2.3 a 2.4)

Aproximácia znamená „približné vyjadrenie“, t.j. buď nejaké rozdelenie aproximujeme iným (majúcim isté výhody oproti tomu, ktoré aproximujeme), alebo aproximujeme dáta nejakým rozdelením (ktoré popisuje dáta pomocou ľahko interpretovateľných parametrov).

(a) $E[X] = Np = 5 \times 0.515 = 2.575$, $E[Y] = 5 \times 0.485 = 2.425$,

$$\Pr(X \leq 3) = \sum_{k \leq 3} \binom{5}{k} 0.515^k 0.485^{5-k} = 0.793,$$

$$\Pr(X \leq 3) = 0.648, N(5 \times 0.515, 5 \times 0.515 \times 0.485).$$

(b) $E[X] = 10 \times 0.515 = 5.15$, $E[Y] = 10 \times 0.485 = 4.85$,

$$\Pr(X \leq 5) = \sum_{k \leq 5} \binom{10}{k} 0.515^k 0.485^{10-k} = 0.586,$$

$$\Pr(X \leq 5) = 0.462, N(10 \times 0.515, 10 \times 0.515 \times 0.485).$$

(c) $E[X] = 50 \times 0.515 = 25.75$, $E[Y] = 50 \times 0.485 = 24.25$,

$$\Pr(X \leq 25) = \sum_{k \leq 25} \binom{50}{k} 0.515^k 0.485^{50-k} = 0.471,$$

$$\Pr(X \leq 25) = 0.416, N(50 \times 0.515, 50 \times 0.515 \times 0.485).$$

```

38 | pbinom(3, size=5, prob=0.515) # 0.7931878
39 | pnorm(3, mean=5*0.515, sd=sqrt(5*0.515*0.485)) # 0.6481396
40 | pbinom(5, size=10, prob=0.515) # 0.5856244
41 | pnorm(5, mean=10*0.515, sd=sqrt(10*0.515*0.485)) # 0.4621927
42 | pbinom(25, size=50, prob=0.515) # 0.4712842
43 | pnorm(25, mean=50*0.515, sd=sqrt(50*0.515*0.485)) # 0.4159648

```

Z príkladu 61 vyplýva, že pre pravdepodobnosť $p = 0.515$ a $N = 50$ aproximácia stále nie je postačujúca (ani na jedno desatinné miesto) a pre $N = 10$ a $N = 5$ ju nie je možné použiť. Pre pravdepodobnosti p blízke sa jednotke alebo nule sú potrebné väčšie početnosti ako pre pravdepodobnosti p blízke hodnote 0.5.

Distribučné funkcie patriace do množiny \mathcal{F} sú distribučnými funkciami diskretných alebo spojitých náhodných premenných. Potom \mathcal{F} môže byť definovaná ako množina **pravdepodobnostných funkcií** alebo **funkcií hustoty** a model môžeme formálne zapísať ako (Casella a Berger, 2002)

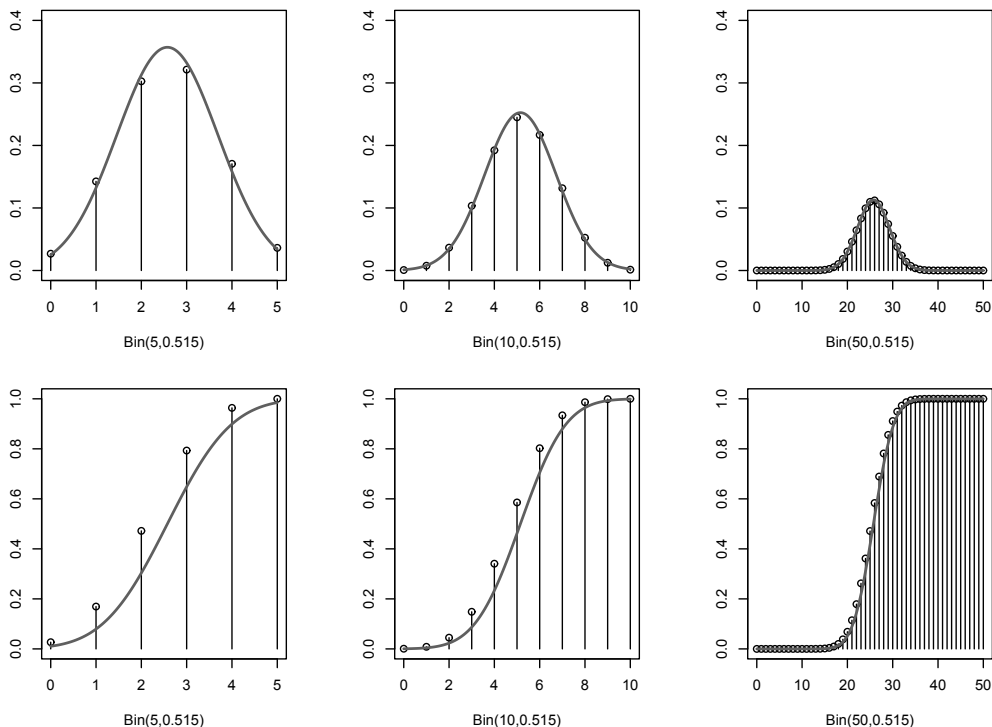
$$\mathcal{F} = \{f(\cdot; \theta) : \theta \in \Theta \subseteq \mathbb{R}^k\}$$

pre nejakú funkciu hustoty f . Vektor θ sa nazýva **parameter**, množina Θ **parametrický priestor** a \mathcal{F} **parametrický model**. Keďže prvky \mathcal{F} sú asociované s prvkami Θ , existuje $\theta_* \in \Theta$ asociovaná s F_* a nazýva sa **skutočná hodnota parametra**. A štatistická inferencia je práve o θ_* . Parametrický štatistický model môže byť charakterizovaný aj pomocou k -rozmerného vektora parametrov θ , preto sa v označení používa \mathbb{R}^k , kde pre skalár θ bude $k = 1$.

Ak však

$$\mathcal{F} = \{\text{množina všetkých hustôt funkcií jednej premennej}\},$$

ide o **neparametrický model** (Wasserman, 2006).



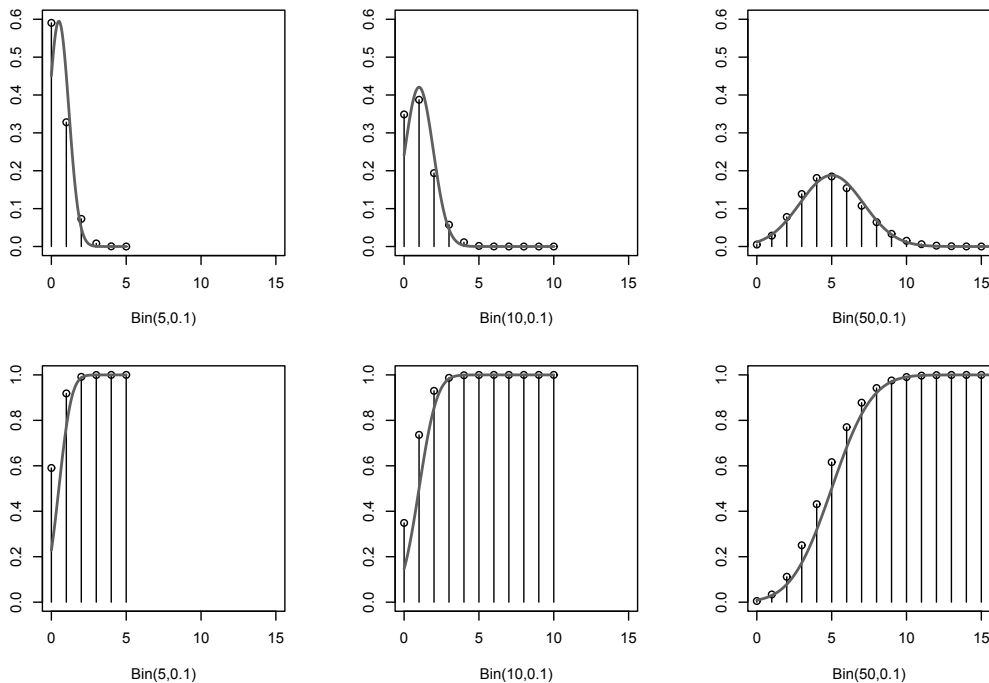
Obr. 2.3: Aproximácia binomického rozdelenia normálnym pre $p = 0.515$ a $N = 5, 10$ a 50 ; spojnicový graf superponovaný hustotou (prvý riadok) a distribučnou funkciou (druhý riadok)

Normálne rozdelenie. Model pre náhodný výber X_1, X_2, \dots, X_n je $N(\mu, \sigma^2)$ a hovoríme, že X_1, X_2, \dots, X_n pochádza z normálneho rozdelenia, t.j. $X \sim N(\mu, \sigma^2)$. Parameter modelu $N(\mu, \sigma^2)$ je vektor $\theta = (\mu, \sigma^2)^T$. Hustota tohto rozdelenia má tvar $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, $x \in \mathbb{R}$.

Príklad 62 (normálne rozdelenie) Predpokladajme, že náhodná premenná X má asymptoticky (pre veľké n) normálne rozdelenie so strednou hodnotou $E[X] = \mu$ a rozptylom $\text{Var}[X] = \sigma^2$, čo zapisujeme ako $X \sim N(\mu, \sigma^2)$. Príkladmi takýchto náhodných premenných sú: (1) dĺžka pravej kľúčovej kosti u mužov (`length.R`; dáta: `paired-means-clavicle2.txt`); (2) šírka lebky u žien (`skull.B`; dáta: `one-sample-mean-skull-mf.txt`).

Štandardizované normálne rozdelenie. Model pre náhodný výber X_1, X_2, \dots, X_n je $N(0, 1)$ a hovoríme, že X_1, X_2, \dots, X_n pochádza zo štandardizovaného normálneho rozdelenia, t.j. $X \sim N(\mu, \sigma^2)$, kde $\mu = 0$ a $\sigma^2 = 1$. Parameter modelu $N(\mu, \sigma^2)$ je vektor $\theta = (0, 1)^T$. Hustota tohto rozdelenia má tvar $\phi(x) = f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$, $x \in \mathbb{R}$.

Príklad 63 (štandardizované normálne rozdelenie) Predpokladáme, že náhodná premenná X šírka lebky u mužov (`skull.B`; dáta: `one-sample-mean-skull-mf.txt`) má asymptoticky normálne rozdelenie so strednou hodnotou μ a rozptylom σ^2 , čo zapisujeme ako $X \sim N(\mu, \sigma^2)$. Keď od X odpočítame jej strednú hodnotu μ a tento rozdiel vydělíme odmocninou z rozptylu $\sigma = \sqrt{\sigma^2}$, dostaneme náhodnú



Obr. 2.4: Aproximácia binomického rozdelenia normálnym pre $p = 0.1$ a $N = 5, 10$ a 50 ; spojnicový graf superponovaný hustotou (prvý riadok) a distribučnou funkciou (druhý riadok)

premennú Z , ktorá má asymptoticky normálne rozdelenie so strednou hodnotou $\mu = 0$ a rozptylom $\sigma^2 = 1$, čo zapisujeme ako $Z \sim N(0, 1)$.

Dvojrozmerné normálne rozdelenie. Náhodný vektor $(X, Y)^T$ má dvojrozmerné normálne rozdelenie

$$N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \text{ kde } \boldsymbol{\mu} = (\mu_1, \mu_2)^T \text{ a } \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix},$$

s hustotou (Casella a Berger, 2002)

$$f(x, y) = \frac{1}{2\pi\sqrt{\sigma_1^2\sigma_2^2(1-\rho^2)}} \exp\left\{-\frac{1}{2(1-\rho^2)}\left\{\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right\}\right\},$$

kde $(x, y)^T \in \mathbb{R}^2$, $\mu_i \in \mathbb{R}^1$, $\sigma_i^2 > 0$, $i = 1, 2$, $\rho \in \langle -1, 1 \rangle$ sú parametre, potom $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$. Výraz v exponente môžeme písať ako

$$-\frac{1}{2} \begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix}^T \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}^{-1} \begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix},$$

marginálne rozdelenia sú $X \sim N(\mu_1, \sigma_1^2)$ a $Y \sim N(\mu_2, \sigma_2^2)$, ρ je koeficient korelácie (detaily maticovej algebry pozri v Gentle (2007)). Marginálne rozdelenie je rozdelenie marginálnej náhodnej premennej, tu X nezávisle na Y a naopak Y nezávisle na X .


Z vyššie uvedeného textu je zjavné, že na dostatočný popis dvojrozmerného normálneho rozdelenia potrebujeme päť parametrov, t.j. strednú hodnotu a rozptyl pre marginálne rozdelenie náhodných

premených X a Y a korelačný koeficient $\rho = \rho(X, Y)$ popisujúci silu lineárneho vzťahu X a Y .

Príklad 64 (dvojrozmerné normálne rozdelenie) (1) Nakreslite hustotu dvojrozmerného normálneho rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ pomocou funkcie `image()` a superponujte ho s kontúrovým grafom hustoty toho istého rozdelenia pomocou funkcie `contour()`. (2) Nakreslite hustotu dvojrozmerného normálneho rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ pomocou funkcie `persp()`. Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Použite nasledovné parametre

- (a) $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$;
 (b) $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$;
 (c) $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1.2, \rho = 0.5$.

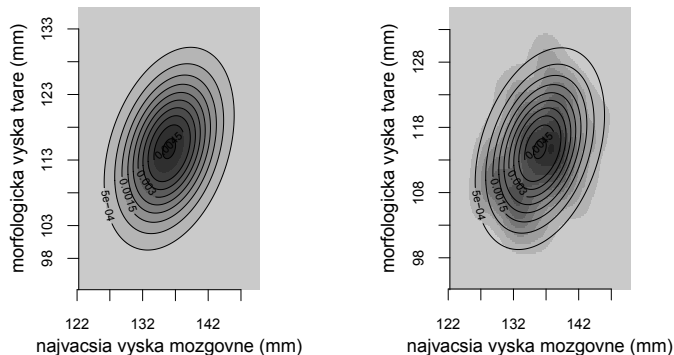
Vzorové riešenie pozri na obrázku 2.5.



Obr. 2.5: Hustoty dvojrozmerného normálneho rozdelenia pri rôznych parametroch (prvý riadok – kontúrový graf, druhý riadok – perspektívny trojrozmerný graf v podobe plochy); čím je ρ odlišnejšie od nuly, tým viac sa kontúry líšia od kruhov (menia sa na elipsy); so zväčšujúcim sa rozdielom medzi σ_1 a σ_2 sa zväčšuje rozdiel rozptýlenia koncentrických kruhov v smere jednotlivých osí (hovoríme, že rozdiel variability premených X_1 a X_2 sa zväčšuje)

Príklad 65 (dvojrozmerné normálne rozdelenie) Nech náhodnou premennou X je najväčšia výška mozgovne u mužov (`skull.pH`; v mm) a náhodnou premennou Y je morfológická výška tváre u mužov (`face.H`; v mm); dáta: `one-sample-correlation-skull-mf.txt`. Nech $E[X] = \mu_1$ je stredná hodnota najväčšej výšky mozgovne a $\text{Var}[X] = \sigma_1^2$ je rozptyl najväčšej výšky mozgovne, $E[Y] = \mu_2$ je stredná hodnota morfológickej výšky tváre a $\text{Var}[Y] = \sigma_2^2$ je rozptyl morfológickej výšky tváre. Predpokladajme, že najväčšia výška mozgovne X má normálne rozdelenie $N(\mu_1, \sigma_1^2)$ a morfológická výška tváre Y má normálne rozdelenie $N(\mu_2, \sigma_2^2)$. Potom $(X, Y)^T$ má dvojrozmerné normálne rozdelenie $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ s parametrami $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, čo je vektor stredných hodnôt a $\sigma_1^2, \sigma_2^2, \rho$, čo sú parametre kovariančnej matice $\boldsymbol{\Sigma}$, kde sila lineárneho vzťahu týchto dvoch premených je daná veľkosťou a znamienkom ρ . Potom $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$. (1) Nakreslite hustotu dvojrozmerného normálneho rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$

pomocou funkcie `image()` a superponujte ho s kontúrovým grafom hustoty toho istého rozdelenia pomocou funkcie `contour()`. (2) Nakreslite dvojrozmerný jadrový odhad hustoty pomocou funkcií `kde2d()` a `image()` a superponujte ho s kontúrovým grafom hustoty dvojrozmerného normálneho rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ pomocou funkcie `contour()`. Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Namiesto $\boldsymbol{\theta}$ použijete vektor $\hat{\boldsymbol{\theta}} = (\bar{x}_1, \bar{x}_2, s_1^2, s_2^2, r)^T$ odhadnutý z dát, kde r je Pearsonov korelačný koeficient. Riešenie pozri na obrázku 2.6.



Obr. 2.6: Hustota dvojrozmerného normálneho rozdelenia s parametrom $\hat{\boldsymbol{\theta}}$, ktorý je odhadnutý z dát (vľavo) a superimpozícia kontúr hustoty dvojrozmerného normálneho rozdelenia s parametrom $\hat{\boldsymbol{\theta}}$, ktorý je odhadnutý z dát a dvojrozmerného jadrového odhadu hustoty (vpravo)

Štandardizované dvojrozmerné normálne rozdelenie. Náhodný vektor $(X, Y)^T$ má dvojrozmerné normálne rozdelenie

$$N_2(\mathbf{0}, \boldsymbol{\Sigma}), \text{ kde } \mathbf{0} = (0, 0)^T \text{ a } \boldsymbol{\Sigma} = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix},$$

s hustotou (Bickel a Doksum, 2006)

$$\phi(x, y) = f(x, y) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left\{-\frac{x^2 - 2\rho xy + y^2}{2(1-\rho^2)}\right\},$$

kde $(x, y)^T \in \mathbb{R}^2$, $\rho \in \langle -1, 1 \rangle$ sú parametre, potom $\boldsymbol{\theta} = (0, 0, 1, 1, \rho)^T$. Výraz v exponente môžeme písať ako

$$-\frac{1}{2} \begin{pmatrix} x \\ y \end{pmatrix}^T \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}^{-1} \begin{pmatrix} x \\ y \end{pmatrix},$$

marginálne rozdelenia sú obe $N(0, 1)$ a ρ je koeficient korelácie.

Príklad 66 (štandardizované dvojrozmerné normálne rozdelenie) *Nech náhodnou premennou $X \sim N(\mu_1, \sigma_1^2)$ je najväčšia výška mozgovne u mužov (skull.pH; v mm) a náhodnou premennou $Y \sim N(\mu_2, \sigma_2^2)$ je morfológická výška tváre u mužov (face.H; v mm). Nech X a Y majú dvojrozmerné normálne rozdelenie s parametrami $(\mu_1, \mu_2)^T$ a σ_1^2, σ_2^2 a ρ sú parametre kovariančnej matice $\boldsymbol{\Sigma}$. Keď od X odpočítame jej strednú hodnotu μ_1 a tento rozdiel vydělíme odmocninou z rozptylu σ_1 , dostaneme náhodnú premennú Z_X , ktorá má asymptoticky normálne rozdelenie so strednou hodnotou $\mu_1 = 0$ a rozptylom $\sigma_1^2 = 1$, čo zapisujeme ako $Z_X \sim N(0, 1)$. Keď od Y odpočítame jej strednú hodnotu μ_2 a tento rozdiel vydělíme odmocninou z rozptylu σ_2 , dostaneme náhodnú premennú Z_Y , ktorá má asymptoticky normálne rozdelenie so strednou hodnotou $\mu_2 = 0$ a rozptylom $\sigma_2^2 = 1$, čo zapisujeme ako*

$Z_Y \sim N(0, 1)$. Potom $(Z_X, Z_Y)^T$ má standardizované dvojrozmerné normálne rozdelenie $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ s parametrami $\boldsymbol{\mu} = (0, 0)^T$ a $\sigma_1^2 = 1$, $\sigma_2^2 = 1$ a ρ sú parametre kovariančnej matice $\boldsymbol{\Sigma}$ (dáta: `one-sample-correlation-skull-mf.txt`).

Príklad 67 (dvojrozmerné normálne rozdelenie) Simuláciu pseudonáhodných čísel z $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ môžeme v \mathbb{R} urobiť použitím nasledovných alternatívnych funkcií:

1) knižnice `library(MASS)` a funkcie `mvrnorm()`;

2) knižnice `library(mvtnorm)` a funkcie `rmvnorm()`;


3) funkcie `rnorm()` a nasledovného algoritmu – nech $X_1 \sim N(0, 1)$ a $X_2 \sim N(0, 1)$; potom $(Y_1, Y_2) \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, čo je vektor stredných hodnôt a σ_1^2 , σ_2^2 a ρ , čo sú parametre kovariančnej matice $\boldsymbol{\Sigma}$, kde sila lineárneho vzťahu Y_1 a Y_2 je daná veľkosťou a znamienkom ρ ; $Y_1 = \sigma_1 X_1 + \mu_1$ a $Y_2 = \sigma_2(\rho X_1 + \sqrt{1 - \rho^2} X_2) + \mu_2$. Nasimulujte pseudonáhodné čísla Y_1 a Y_2 z $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. Vypočítajte dvojrozmerný jadrový odhad hustoty $(Y_1, Y_2)^T$ pomocou funkcie `kde2d()`. Nakreslite ho pomocou funkcie `image()` a superponujte ho s kontúrovým grafom hustoty dvojrozmerného normálneho rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ pomocou funkcie `contour()`. Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Pri simulácii použite nasledovné parametre

(a) $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$; (1) $n = 50$ a (2) $n = 1000$;

(b) $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$; (1) $n = 50$ a (2) $n = 1000$;

(c) $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1.2, \rho = 0.5$; (1) $n = 50$ a (2) $n = 1000$.

Vzorové riešenie pozri na obrázku 2.7.



Obr. 2.7: Hustoty dvojrozmerného normálneho rozdelenia (prvý riadok $n = 50$; druhý riadok $n = 1000$)

Príklad 68 (zmes dvoch dvojrozmerných normálnych rozdelení) Simuláciu pseudonáhodných čísel zo zmesi dvoch normálnych rozdelení $pN_2(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1) + (1 - p)N_2(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$ môžeme v \mathbb{R} urobiť použitím jedného z alternatívnych postupov z príkladu 67. Nasimulujte pseudonáhodné čísla X a Y (1)

zo zmesi $pN_2(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1) + (1-p)N_2(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$, kde $\boldsymbol{\theta} = (\mu_{11}, \mu_{12}, \sigma_{11}^2, \sigma_{12}^2, \rho_1, \mu_{21}, \mu_{22}, \sigma_{21}^2, \sigma_{22}^2, \rho_2)^T$ a (2) z dvojrozmerného rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde parametre predstavujú spoločný vektor stredných hodnôt a spoločnú kovariančnú maticu. t.j. $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$. Pre (1) vypočítajte dvojrozmerný jadrový odhad hustoty $(X, Y)^T$ pomocou funkcie `kde2d()`.

(a) Nakreslite teoretickú hustotu (2) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (2) pomocou funkcie `contour()`. Teoretickým rozdelením v tomto prípade bude $N_2(\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}})$.

(b) Nakreslite teoretickú hustotu (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.


(c) Nakreslite dvojrozmerný jadrový odhad hustoty realizácií (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.

Hustotu rozsekať na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Pri simulácii použite $\boldsymbol{\theta} = (-1.2, -1.2, 1, 1, 0, 1, 1, 1, 1, 0)^T$,

(1) $\hat{\boldsymbol{\theta}} = (\bar{x}_{11}, \bar{x}_{12}, s_{11}^2, s_{12}^2, r_1, \bar{x}_{21}, \bar{x}_{22}, s_{21}^2, s_{22}^2, r_2)^T$, $n_1 = n_2 = 50$ a $p = 0.5$ (odhady pochádzajú z nasimulovaných dát).

(2) $\hat{\boldsymbol{\theta}} = (\bar{x}_1, \bar{x}_2, s_1^2, s_2^2, r)^T$ a $n_1 = n_2 = 50$ (odhady pochádzajú zo spoločného výberu nasimulovaných dát).

Vzorové riešenie pozri na obrázku 2.8.



Obr. 2.8: Spoločná hustota dvojrozmerného normálneho rozdelenia (vľavo), hustota zmesi dvoch dvojrozmerných normálnych rozdelení (uprostred) a dvojrozmerný jadrový odhad superponovaný hustotou zmesi dvoch dvojrozmerných normálnych rozdelení (vpravo) – simulačná štúdia

Príklad 69 (zmes dvoch dvojrozmerných normálnych rozdelení) Nech $(X_1, Y_1)^T$ pochádza z rozdelenia $N_2(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$, kde X_1 je priemerná dĺžka dolnej končatiny `lowex.L` v milimetroch a Y_1 dĺžka trupu `tru.L` v milimetroch (u mužov). Nech $(X_2, Y_2)^T$ pochádza z rozdelenia $N_2(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$, kde X_2 je priemerná dĺžka dolnej končatiny `lowex.L` v milimetroch a Y_2 dĺžka trupu `tru.L` v milimetroch (u žien). Predpokladajme, že X je priemerná dĺžka dolnej končatiny a Y dĺžka trupu pochádzajú (1) zo zmesi $pN_2(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1) + (1-p)N_2(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$, kde $\boldsymbol{\theta} = (\mu_{11}, \mu_{12}, \sigma_{11}^2, \sigma_{12}^2, \rho_1, \mu_{21}, \mu_{22}, \sigma_{21}^2, \sigma_{22}^2, \rho_2)^T$ a (2) z dvojrozmerného rozdelenia $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde parametre predstavujú spoločný vektor stredných hodnôt a spoločnú kovariančnú maticu. t.j. $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$. Pre (1) vypočítajte dvojrozmerný jadrový odhad hustoty $(X, Y)^T$ pomocou funkcie `kde2d()`.

(a) Nakreslite teoretickú hustotu (2) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (2) pomocou funkcie `contour()`.

(b) Nakreslite teoretickú hustotu (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.

(c) Nakreslite dvojrozmerný jadrový odhad hustoty realizácií (1) pomocou funkcie `image()` a superponujte ho kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.


Hustotu rozsekať na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terra-`

`in.colors(12)`.

(1) $\hat{\theta} = (\hat{\mu}_{11}, \hat{\mu}_{12}, \hat{\sigma}_{11}^2, \hat{\sigma}_{12}^2, \hat{\rho}_1, \hat{\mu}_{21}, \hat{\mu}_{22}, \hat{\sigma}_{21}^2, \hat{\sigma}_{22}^2, \hat{\rho}_2)^T$ a $p = n_1/(n_1 + n_2)$; parametre sú odhadnuté z dát.

(2) $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \hat{\rho})^T$; parametre sú odhadnuté zo spoločného výberu.

Vzorové riešenie pozri na obrázku 2.9 (dáta `two-samples-correlations-trunk.txt`).



Obr. 2.9: Spoločná hustota dvojrozmerného normálneho rozdelenia (vľavo), hustota zmesi dvoch dvojrozmerných normálnych rozdelení (uprostred) a dvojrozmerný jadrový odhad superponovaný hustotou zmesi dvoch dvojrozmerných normálnych rozdelení (vpravo) – reálne dáta

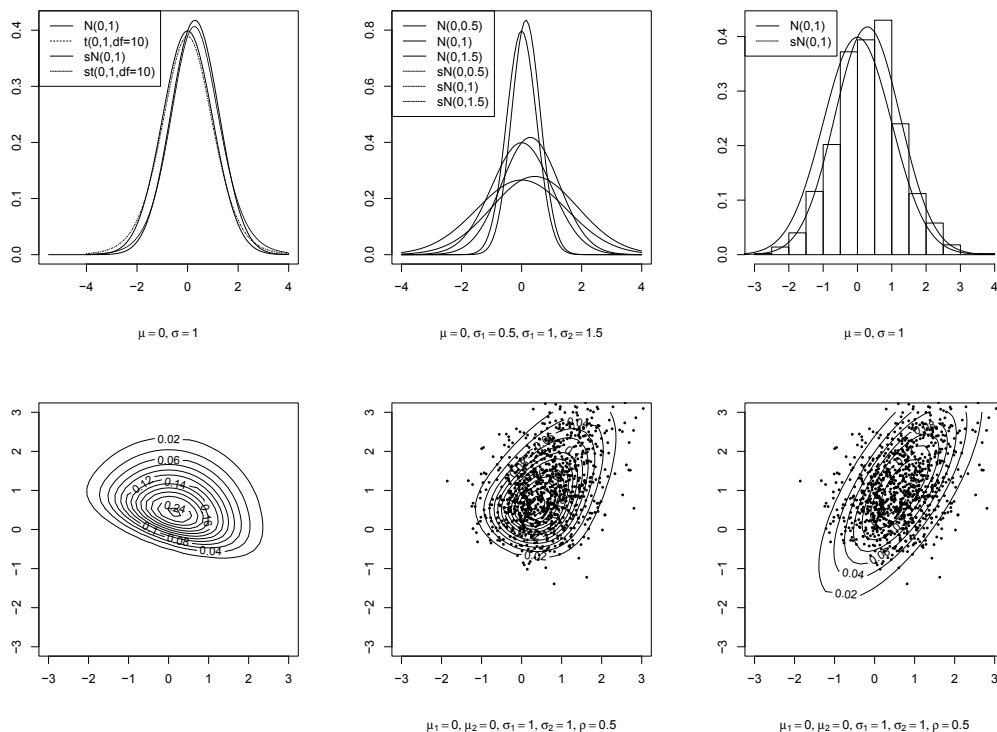
Odlíšnosti od teoretického rozdelenia. Odlíšnosti empirického rozdelenia (rozdelenia realizácií) od teoretického (napr. normálneho) rozdelenia, môžeme charakterizovať napr. ako pravostranne alebo ľavostranne zošíkmené rozdelenie (obrázok 2.10, prvý riadok vľavo a vpravo), ploché alebo špicaté rozdelenie (obrázok 2.10, prvý riadok uprostred). Pri viacrozmerných rozdeleniach je situácia komplikovanejšia. Pri dvojrozmernom normálnom rozdelení môže byť napr. zošíkmená jedna alebo obe premenné (príklad zošíkmenia oboch premenných zľava pozri na obrázku 2.10, dolný riadok).

Binomické rozdelenie. Majme nezávislé identické *Bernoulliho* pokusy s odpoveďami $X_i = 1$ (udalosť nastala) alebo $X_i = 0$ (udalosť nenastala) pre $i = 1, 2, \dots, N$, kde N je počet nezávislých pokusov. Pravdepodobnosť nastatia udalosti pre každý pokus $\Pr(X_i = 1) = p$, pravdepodobnosť neúspechu pre každý pokus $\Pr(X_i = 0) = 1 - p$. Počet nastatí udalosti $X = \sum_{i=1}^N X_i$, pravdepodobnosť nastatia udalosti je p . Náhodná premenná X má binomické rozdelenie s parametrami N a p , t.j. $X \sim \text{Bin}(N, p)$, kde $\theta = p$. Pravdepodobnosť, že X je rovné nejakému číslu $x = n$ (x je realizácia X) zapisujeme ako $\Pr(X = x) = \binom{N}{x} p^x (1 - p)^{N-x}$, pre $x = 0, 1, 2, \dots, N$ (Christensen, 1997). Stredná hodnota náhodnej premennej X je definovaná ako $E[X] = \sum_{x=0}^N x \binom{N}{x} p^x (1 - p)^{N-x} = Np$ a rozptyl $\text{Var}[X] = \sum_{x=0}^N (x - Np)^2 \binom{N}{x} p^x (1 - p)^{N-x} = Np(1 - p)$.

Strieška v označení \hat{p} sa všeobecne používa na označenie odhadov parametrov rozdelení pravdepodobnosti. Tieto odhady sa počítajú z dát. Pre spojité náhodné premenné označujeme rozsah náhodného výberu n , ale pri binomickom (a iných diskretných) rozdeleniach máme početnosti dve – počet úspechov a rozsah náhodného výberu – preto pre počet úspechov rezervujeme ozn. n a rozsah náhodného výberu N . Počet úspechov ozn. aj $x = n$, ak ide o realizáciu náhodnej premennej X .

Ekvivalentne môžeme rozdelenie náhodnej premennej pochádzajúcej z binomického rozdelenia zapísať ako $\mathbf{X} \sim \text{Bin}(N, p, 1 - p)$, kde $\mathbf{X} = (X_1, X_2)^T$, $\boldsymbol{\theta} = (p, 1 - p)^T$, X_1 je počet úspechov, $X_2 = N - X_1$ je počet neúspechov, $X_1 \sim \text{Bin}(N, p)$, $X_2 \sim \text{Bin}(N, 1 - p)$. Potom $E[X_1] = Np$, $E[X_2] = N(1 - p)$, $\text{Var}[X_2] = Np(1 - p) = \text{Var}[X_1]$ nezávisle na p , $\text{Cov}[X_1, X_2] = -Np(1 - p)$ a $\text{Cor}[X_1, X_2] = -1$. (Vysvetlenia označení pozri v poznámke pod čiarou⁹). Realizácie náhodných premenných X_1 a X_2 budeme označovať ako n_1 a n_2 . Tento typ označenia je vhodnejší z dôvodu zovšeobecnenia binomického

⁹ $E[X]$ je označenie pre strednú hodnotu náhodnej premennej X , $\text{Var}[X]$ pre rozptyl, $\text{Cov}[X, Y]$ pre kovarianciu dvoch premenných X a Y a $\text{Cor}[X, Y]$ pre korelačný koeficient.



Obr. 2.10: Hustoty normálneho rozdelenia a zošikmeného normálneho rozdelenia pri rôznych parametroch (prvý riadok); hustoty dvojjazerného zošikmeného normálneho rozdelenia (druhý riadok vľavo a uprostred) a dvojjazerného normálneho rozdelenia (druhý riadok vpravo) pri rôznych parametroch

rozdelenia na viacrozmerne rozdelenia, kde $\mathbf{n} = (n_1, n_2)^T$ a $\mathbf{p} = (p_1, p_2)^T$, $p_1 = p$ a $p_2 = 1 - p$ (pre porovnanie pozri ozn. v práci Verzani, 2005). Potom $\boldsymbol{\theta} = \mathbf{p}$.

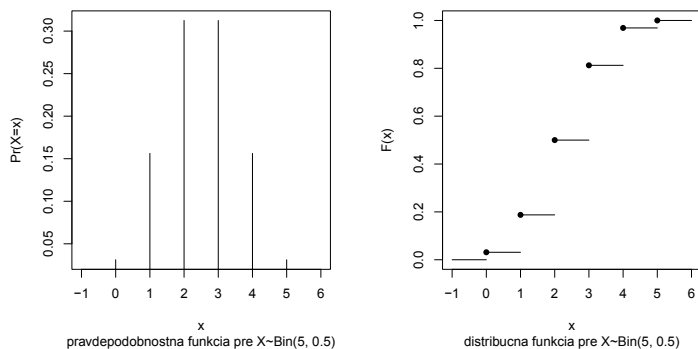
Príklad 70 (binomické rozdelenie, binomický experiment) Experiment pozostávajúci z fixného počtu Bernoulliho experimentov (ozn. N) sa nazýva binomický experiment. Pravdepodobnosť úspechu ozn. p , pravdepodobnosť neúspechu $q = 1 - p$. Náhodná premenná X je počet pozorovaných úspechov počas experimentu. Pravdepodobnosť $X = x$ za podmienky, že X pochádza z binomického rozdelenia $\text{Bin}(N, p)$ píšeme ako $\Pr(X = x) = \binom{N}{x} p^x (1 - p)^{N - x}$, $x = 0, 1, \dots, N$ (Ugarte a kol., 2008). Stredná hodnota $E[X] = Np$ a rozptyl $\text{Var}[X] = Np(1 - p)$. Naprogramujte a zobrazte v \mathbb{R} pravdepodobnostnú funkciu a (kumulatívnu) distribučnú funkciu pre $\text{Bin}(5, 0.5)$.

Riešenie v \mathbb{R} (pozri obrázok 2.11)

```

44 par(mfrow=c(1,2), mar=c(6.5, 1.1), pty="s")
45 plot(0:5, dbinom(0:5, 5, 0.5), type="h", xlab="x", ylab="Pr(X=x)",
46      xlim=c(-1,6))
47 title(sub="hustota_pre_X~Bin(5,0.5)")
48 plot(0:5, pbinom(0:5, 5, 0.5), type="n", xlab="x", ylab="F(x)",
49      xlim=c(-1,6), ylim=c(0,1))
50 segments(-1, 0, 0)
51 segments(0:5, pbinom(0:5, 5, .5), 1:6, pbinom(0:5, 5, .5))
52 lines(0:5, pbinom(0:5, 5, .5), type="p", pch=16)
53 segments(-1, 1, 9, 1, lty=2)
54 title(sub="distribucna_funkcia_pre_X~Bin(5,0.5)")

```

Obr. 2.11: Pravdepodobnostná funkcia a distribučná funkcia $Bin(5, 0.5)$

Multinomické rozdelenie. Nech N je počet nezávislých identických pokusov a v každom z nich môže nastať $J \geq 2$ navzájom disjunktných udalostí s možnými odpoveďami $X_{ij} = 1$ (udalosť nastala) alebo $X_{ij} = 0$ (udalosť nenastala), kde $i = 1, 2, \dots, N$ a $j = 1, 2, \dots, J$. Potom $X_j = \sum_{i=1}^N X_{ij}$. Pravdepodobnosť nastatia j -tej udalosti v i -tom pokuse $\Pr(X_{ij} = 1) = p_j$, $\sum_{j=1}^J p_j = 1$. Náhodná premenná $\mathbf{X} = (X_1, X_2, \dots, X_J)^T$ má (J -rozmerné) multinomické rozdelenie s parametrami N a \mathbf{p} , t.j. $\mathbf{X} \sim Mult_J(N, \mathbf{p})$, kde $\boldsymbol{\theta} = \mathbf{p}$ a $\mathbf{p} = (p_1, p_2, \dots, p_J)^T$. Pravdepodobnosť, že X_j je rovné nejakému číslu n_j zapisujeme ako (Casella a Berger, 2002)

$$\Pr(X_1 = x_1, X_2 = x_2, \dots, X_J = x_J) = \frac{N!}{x_1! x_2! \dots x_J!} p_1^{x_1} p_2^{x_2} \dots p_J^{x_J} = \frac{N!}{\prod_{j=1}^J x_j!} \prod_{j=1}^J p_j^{x_j},$$

kde $N = \sum_{j=1}^J X_j$, $X_j \geq 0$ a $x_j = n_j$ sú realizácie X_j . Potom $\mathbf{n} = (n_1, n_2, \dots, n_J)^T$. Pre marginálne rozdelenie píšeme $X_j \sim Bin(N, p_j)$, kde stredná hodnota $E[X_j] = Np_j$, rozptyl $Var[X_j] = Np_j(1-p_j)$, kovariancia $Cov[X_i, X_j] = -Np_i p_j$, korelačný koeficient $Cor[X_i, X_j] = (-p_i p_j) / \sqrt{p_i(1-p_i)p_j(1-p_j)}$. Stredná hodnota $E[\mathbf{X}] = N\mathbf{p}$ a kovariančná matica $Var[\mathbf{X}] = N(\mathbf{D}_p - \mathbf{p}\mathbf{p}^T)$, kde $\mathbf{D}_p = \text{diag}(\mathbf{p})$ a

$$(\mathbf{D}_p - \mathbf{p}\mathbf{p}^T)_{ij} = \begin{cases} p_i(1-p_i) & \text{ak } i = j \\ -p_i p_j & \text{ak } i \neq j \end{cases}.$$

Disjunktnosť znamená, že v i -tom pokuse mohla udalosť nastať len raz, t.j. výsledkom takéhoto pokusu môže byť vektor napr. $(1, 0, \dots, 0)^T$ alebo $(0, 1, \dots, 0)^T$, kde okrem jednej jednotky na j -tom mieste máme vždy $J-1$ núl na ostatných miestach. Keďže sumácia \mathbf{p} nám dáva jednotku, $Var[\mathbf{X}]$ je singularná matica. Matica $\text{diag}(\mathbf{p})$ má diagonálu v podobe \mathbf{p} a mimodiagonálne prvky rovné 0. Ak $J = 2$, potom $Bin(N, p) \approx Mult_2(N, \mathbf{p})$, t.j. multinomické rozdelenie je zovšeobecnením binomickeho rozdelenia.

Príklad 71 (multinomické rozdelenie; príklady) Príklady premenných, o ktorých predpokladáme, že majú multinomické rozdelenie:

- (1) farba dúhovky – hodnotená podľa škály R. Martina (Martin, 1914/1928) a kategorizovaná do štyroch kategórií: hnedá, hnedozelená, melírovaná a modrá (dáta: `multinom-iris-color.txt`);
- (2) zakončenie troch hlavných dlaňových línií – kategorizované do troch kategórií: vysoké, stredné a nízke (dáta: `multinom-palmar-lines.txt`);
- (3) priláhosť ušného laloka – podľa priláhosťi k hlave kategorizovaná do troch kategórií: priláhlý, stredne priláhlý, odstávajúci (dáta: `multinom-earlobe.txt`);
- (4) krvná skupina – kategorizovaná v AB0 systéme do štyroch kategórií: skupina 0, A, B a AB (dáta: `multinom-blood-groups.txt`).

Príklad 72 (multinomické rozdelenie) Majme náhodné premenné (1) socioekonomický status (vysoký – H, nízky – Lo), (2) politická prislusnosť (demokrat – D, republikán – R) a (3) politická filozofia (liberál – Li, konzervatívce – C). Označme ich interakcie nasledovne X_1 (H-D-Li), X_2 (H-D-C), X_3 (H-R-Li), X_4 (H-R-C), X_5 (Lo-D-Li), X_6 (Lo-D-C), X_7 (Lo-R-Li) a X_8 (Lo-R-C). Predpokladajme, že máme náhodný výber s rozsahom $N = 50$. Pravdepodobnosti p_j pozri v tabuľke 2.2. Vypočítajte $Var[X_1]$, $Var[X_3]$, $Cov[X_1, X_3]$, $Cor[X_1, X_3]$ a očakávané početnosti Np_j , $j = 1, 2, \dots, 8$.

Tabuľka 2.2: Kontingenčná tabuľka 2×3 pravdepodobností p_j pre dva socioekonomické statusy, dve politické prislusnosti a dve politické filozofie (multinomické rozdelenie)

	D-Li	D-C	R-Li	R-C	spolu
H	0.12	0.12	0.04	0.12	0.4
Lo	0.18	0.18	0.06	0.18	0.6
spolu	0.30	0.30	0.10	0.30	1.0

Riešenie

$X = (X_1, X_2, \dots, X_8) \sim Mult_J(N, \mathbf{p})$, kde $N = 50$, $\mathbf{p} = (p_1, p_2, \dots, p_8)^T$, vieme, že $X_j \sim Bin(N, p_j)$, p_j sú v tabuľke 2.2 a $j = 1, 2, \dots, 8$. Potom

$$Var[X_1] = 50 \times 0.12 \times (1 - 0.12) = 5.28,$$

$$Var[X_3] = 50 \times 0.04 \times (1 - 0.04) = 1.92.$$

Vybraná kovariancia a korelácia (medzi počtami prislusných skupín) je rovná

$$Cov[X_1, X_3] = -50 \times 0.12 \times 0.04 = -0.24, \quad Cor[X_1, X_3] = -0.24 / \sqrt{5.28 \times 1.92} = -0.075.$$

Očakávané početnosti pre každú bunku tabuľky sú (všeobecne nemusia byť) celé čísla, pozri tabuľku 2.3.

Tabuľka 2.3: Kontingenčná tabuľka 2×3 očakávaných početností Np_j pre dva socioekonomické statusy, dve politické prislusnosti a dve politické filozofie (multinomické rozdelenie)

	D-Li	D-C	R-Li	R-C
H	6	6	2	6
Lo	9	9	3	9

Súčinové multinomické rozdelenie. Nech N_k je počet nezávislých identických pokusov a v každom z nich môže nastať $J \geq 2$ navzájom disjunktných udalostí s možnými odpoveďami $X_{kji} = 1$ (udalosť nastala) alebo $X_{kji} = 0$ (udalosť nenastala), kde $i = 1, 2, \dots, N_k$, $k = 1, 2, \dots, K$ a $j = 1, 2, \dots, J$. Nech $X_{kj} = \sum_{i=1}^{N_k} X_{kji}$ a $\sum_{k=1}^K N_k = N$. Pravdepodobnosť nastatia (kj) -tej udalosti v i -tom pokuse $\Pr(X_{kji} = 1) = p_{kj}$, $\sum_{k=1}^K \sum_{j=1}^J p_{kj} = 1$. Náhodná premenná $\mathbf{X}_k = (X_{k1}, X_{k2}, \dots, X_{kJ})^T$ má $(J$ -rozmerné) multinomické rozdelenie s parametrami N_k a \mathbf{p}_k , t.j. $Mult_J(N_k, \mathbf{p}_k)$, kde $\theta_k = \mathbf{p}_k$ a $\mathbf{p}_k = (p_{k1}, p_{k2}, \dots, p_{kJ})^T$. Realizácie náhodnej premennej \mathbf{X}_k označujeme ako \mathbf{x}_k . Potom $x_{kj} = n_{kj}$ a navyše $\mathbf{n}_k = (n_{k1}, n_{k2}, \dots, n_{kJ})^T$. Nech \mathbf{X}_k sú nezávislé, potom platí (Christensen, 1997)

$$\Pr(X_{kj} = x_{kj}, \forall k, j; j = 1, 2, \dots, J; k = 1, 2, \dots, K) = \prod_{k=1}^K \Pr(X_{kj} = x_{kj}, \forall j; j = 1, 2, \dots, J)$$

a $\sum_{j=1}^J X_{kj} = N_k$ pre $\forall k$. Ďalej platí

$$\Pr(X_{kj} = x_{kj}, \forall j) = \left(N_k! / \prod_{j=1}^J x_{kj}! \right) \prod_{j=1}^J p_{kj}^{x_{kj}}.$$

Z toho vyplýva, že

$$\Pr(X_{kj} = x_{kj}, \forall k, j; j = 1, 2, \dots, J; k = 1, 2, \dots, K) = \prod_{k=1}^K \left(\left(N_k! / \prod_{j=1}^J x_{kj}! \right) \prod_{j=1}^J p_{kj}^{x_{kj}} \right).$$

Očakávané hodnoty $N_k p_{kj}$, rozptyly $Var[X_{kj}]$ a kovariancie $Cov[X_{kj}]$ a korelácie $Cor[X_{kj}]$ vnútri nejakého \mathbf{X}_k vieme vypočítať. Kovariancie medzi rôznymi \mathbf{X}_k , napr. $Cov[\mathbf{X}_1, \mathbf{X}_2]$, sú nuly kvôli nezávislosti jednotlivých \mathbf{X}_k . Potom $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_K)^T$ má súčinnové multinomické rozdelenie s parametrami $\boldsymbol{\theta}_k = \mathbf{p}_k, k = 1, 2, \dots, K$.

Príklad 73 (súčinnové multinomické rozdelenie; príklady) *Príklady premenných, o ktorých predpokladáme, že majú súčinnové multinomické rozdelenie:*

(1) farba dúhovky – hodnotená podľa škály R. Martina (Martin, 1914/1928) a kategorizovaná do štyroch kategórií (hnedá, hnedozelená, melírovaná a modrá) zisťovaná súčasne s výskytom (prítomnosť, neprítomnosť) radiálnych útvarov v štruktúre dúhovky (dáta: `multinom-iris-color.txt`);

(2) zakončenie hlavných dľaňových línií – kategorizované do troch kategórií (vysoké, stredné a nízke) zisťované súčasne s odtieňmi farby vlasov (svetlá, stredná a tmavá) na základe štandardnej Fischer-Sallerovej stupnice odtieňov (dáta: `multinom-palmar-lines.txt`);

(3) priláhosť ušného laloka – podľa priláhlosti k hlave kategorizovaná do troch kategórií (priláhlý, stredne priláhlý, odstávajúci) zisťovaná u mužov a u žien (dáta: `multinom-earlobe.txt`);

(4) krvná skupina – kategorizovaná v ABO systéme do štyroch kategórií (0, A, B a AB) zisťovaná v Košiciach a v Prahe (dáta: `multinom-blood-groups.txt`).

Príklad 74 (súčinnové multinomické rozdelenie) *Majme dáta z príkladu 72 a náhodný výber s rozsahom $N_1 = 30$ zo skupiny H, ďalší náhodný výber s rozsahom $N_2 = 20$ zo skupiny Lo. Označme interakcie premenných nasledovne $X_{11} = X_{1|1}$ (H-D-Li), $X_{12} = X_{2|1}$ (H-D-C), $X_{13} = X_{3|1}$ (H-R-Li), $X_{14} = X_{4|1}$ (H-R-C), $X_{21} = X_{1|2}$ (Lo-D-Li), $X_{22} = X_{2|2}$ (Lo-D-C), $X_{23} = X_{3|2}$ (Lo-R-Li) a $X_{24} = X_{4|2}$ (Lo-R-C), kde $\mathbf{X}_1 = (X_{11}, X_{12}, X_{13}, X_{14})^T$ a $\mathbf{X}_2 = (X_{21}, X_{22}, X_{23}, X_{24})^T$. Potom $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2)$ má súčinnové multinomické rozdelenie s $K = 2, N_1 = 30, J_1 = 4, N_2 = 20, J_2 = 4$. Zápis s $X_{j|k}$, kde $j = 1, 2, 3, 4$ a $k = 1, 2$ zdôrazňuje fakt, že rozdelenie je podmienené socioekonomickým statusom (vysoký – H, nízky – Lo), t.j. rozdelenie v stĺpcoch tabuľky je podmienené jej riadkom. Realizácie $X_{j|k}$ označujeme ako $n_{j|k} = n_{kj}$, pravdepodobnosti ekvivalentné $X_{j|k} = X_{kj}$ ako $p_{j|k} = p_{kj}$. Vypočítajte podmienené pravdepodobnosti $p_{j|k}$, očakávané početnosti $N_k p_{kj}$, $Var[X_{13}]$, $Cov[X_{21}, X_{23}]$ a $Cor[X_{11}, X_{23}]$.*

Riešenie

Pravdepodobnosti štyroch kategórií asociovaných s H statusom sú podmienené pravdepodobnosti dané H statusom. Napr. $\Pr(X_{3|1}) = 0.04/0.4 = 0.1$, $\Pr(X_{1|1}) = 0.12/0.4 = 0.3$, $\Pr(X_{3|2}) = 0.06/0.6 = 0.1$. Musíme ale tabuľku 2.2 prepísať na súčinnovo-multinomický model, teda podmienené pravdepodobnosti $p_{j|i}$ budú dané socioekonomickým statusom i (pozri tabuľku 2.4).

Tabuľka 2.4: Kontingenčná tabuľka 2×3 pravdepodobností $p_{j|i}$ pre dva socioekonomické statusy, dve politické príslušnosti a dve politické filozofie (súčinnové multinomické rozdelenie)

	D-Li	D-C	R-Li	R-C	spolu
H	0.3	0.3	0.1	0.3	1.0
Lo	0.3	0.3	0.1	0.3	1.0

Pre $N_1 = 30$ a $N_2 = 20$ pozri očakávané početnosti v tabuľke 2.5.

Tabuľka 2.5: Kontingenčná tabuľka 2×3 očakávaných početností $N_i p_{j|i}$ pre dva socioekonomické statusy, dve politické príslušnosti a dve politické filozofie (súčinnové multinomické rozdelenie)

	D-Li	D-C	R-Li	R-C	spolu
H	9	9	3	9	30
Lo	6	6	2	6	20

$$Var(X_{3|1}) = 30 \times 0.1 \times (1 - 0.1) = 2.7.$$

Vybrané kovariancie (medzi počtami príslušných skupín) sú rovné

$$\begin{aligned} \text{Cov} [X_{1|2}, X_{3|2}] &= -20 \times 0.3 \times 0.1 = -0.6, \\ \text{Cov} [X_{1|1}, X_{3|2}] &= 0, \text{ lebo } \mathbf{X}_1 \text{ a } \mathbf{X}_2 \text{ sú nezávislé.} \end{aligned}$$

Príklad 75 (farba očí a vlasov) Majme premenné farba vlasov (blond BlH , hnedá BrH , ryšavá RH) a farba očí (modrá BlE , hnedá BrE , zelená GE). Ich interakcie sú usporiadané v tabuľke ako X_1 ($BlH-BlE$), X_2 ($BlH-BrE$), X_3 ($BlH-GE$), X_4 ($BrH-BlE$), X_5 ($BrH-BrE$), X_6 ($BrH-GE$), X_7 ($RH-BlE$), X_8 ($RH-BrE$), X_9 ($RH-GE$). Nim zodpovedajúce pravdepodobnosti $p_j, j = 1, 2, \dots, 9$, pozri v tabuľke 2.6. $\mathbf{X} = (X_1, X_2, \dots, X_9)^T \sim \text{Mult}_9(N, \mathbf{p})$. Transformujte multinomický model na súčinnový multinomický model nasledovne – vypočítajte (a) riadkové marginálne pravdepodobnosti $p_{1.} = \sum_{j=1}^3 p_j$, $p_{2.} = \sum_{j=4}^6 p_j$, $p_{3.} = \sum_{j=7}^9 p_j$, (b) stĺpcové marginálne pravdepodobnosti $p_{.1} = p_1 + p_4 + p_7$, $p_{.2} = p_2 + p_5 + p_8$, $p_{.3} = p_3 + p_6 + p_9$, (c) podmienené pravdepodobnosti $p_{j|k} = p_{kj}$; (d) podmienené pravdepodobnosti $p_{k|j} = p_{jk}$; (e) akému číslu sú rovné sumy $\sum_{j=1}^3 p_{j|k}$ pre každé k a $\sum_{k=1}^3 p_{k|j}$ pre každé j ?

Tabuľka 2.6: Kontingenčná tabuľka 3×3 pravdepodobností p_j pre tri farby vlasov a tri farby očí (multinomické rozdelenie)

farba vlasov/farba očí	modrá (BlE)	hnedá (BrE)	zelená (GE)
blond (BlH)	0.12	0.15	0.03
hnedá (BrH)	0.22	0.34	0.04
ryšavá (RH)	0.06	0.01	0.03

Riešenie (čiastkové)

Marginálne pravdepodobnosti sú

$$\Pr(BlH) = 0.3, \Pr(BrH) = 0.6, \Pr(RH) = 0.1,$$

$$\Pr(BlE) = 0.4, \Pr(BrE) = 0.5, \Pr(GE) = 0.1.$$

Podmienené pravdepodobnosti $p_{k|j}$ sú

$$\Pr(BlH|BlE) = \Pr(BlH \cap BlE) / \Pr(BlE) = 0.12/0.4 = 0.3,$$

$$\Pr(BlH|BrE) = \Pr(BlH),$$

$$\Pr(BrH|BlE) = 0.22/0.4 = 0.55,$$

$$\Pr(BrH) = 0.6.$$

Ak vieme, že niekto má modré oči, potom bude menej pravdepodobné, že má hnedé vlasy v porovnaní s tým, keď nevieme, akej farby má oči. Teda

$$\Pr(BlE|BlH) = 0.12/0.3 = 0.4,$$

$$\Pr(BlE|BrH) = \Pr(BlE),$$

$$\Pr(BrE|BlH) = \Pr(BrE),$$

$$\Pr(GE|BlH) = \Pr(GE).$$

Informácia, že má niekto blond vlasy, nám nedáva ďalšiu informáciu o farbe jeho očí.

Binomické, multinomické a súčinnové multinomické rozdelenie sú vhodné v prípadoch, keď máme počet pokusov N nie príliš veľké a pravdepodobnosti výskytu udalostí p nie príliš malé. V opačnom prípade je vhodné Poissonovo rozdelenie (Agresti, 2002).

Poissonovo rozdelenie. Poissonovo rozdelenie je limitným prípadom Binomického rozdelenia $\text{Bin}(N, p)$, kde $N \rightarrow \infty, p \rightarrow 0$, teda $Np \rightarrow \lambda$. Ak je X náhodná premenná s Poissonovým rozdelením a parametrom $\theta = \lambda$, $X \sim \text{Poiss}(\lambda)$, potom (Casella a Berger, 2002)

$$\Pr(X = x) = \frac{\lambda^x e^{-\lambda}}{x!}, x = 0, 1, \dots$$

Realizáciu náhodnej premennej X označujeme ako $x = n$. $E[X] = \lambda$ a $\text{Var}[X] = \lambda$. Tomu korešponduje

$$\binom{N}{x} p^x (1-p)^{N-x} = \left[(Np)^x (1-p)^N / x! \right] (1-p)^{-x} \frac{N!}{(N-x)! N^x},$$

ak $N \rightarrow \infty, p \rightarrow 0$ a $Np \rightarrow \lambda \Rightarrow (Np)^x \rightarrow \lambda^x, (1-p)^N \rightarrow e^{-\lambda}, (1-p)^{-x} \rightarrow 1, \frac{N!}{(N-x)! N^x} \rightarrow 1$.

Znak „ \rightarrow “ čítame ako „konverguje“ (do nekonečna, k nule, k λ a pod.). V prípade, že za „ \rightarrow “ je znak nekonečna, napr. $N \rightarrow \infty$, potom čítame celý výraz ako „pre (dostatočne) veľké N “ alebo „ N konverguje do nekonečna“.

Príklad 76 (Poissonovo rozdelenie; počet havárií za týždeň) Ak každý z 50 miliónov ľudí šoféruje auto v Taliansku budúci týždeň nezávisle, potom pravdepodobnosť smrti pri autonehode bude 0.000002, kde počet úmrtí má binomické rozdelenie $\text{Bin}(50\text{mil}, 0.000002)$ alebo limitne Poissonovo rozdelenie s parametrom $50\text{mil} \times 0.000002 = 100$.

Príklad 77 (Poissonovo rozdelenie; príklady) Príklady premenných, o ktorých predpokladáme, že majú Poissonove rozdelenie:

- (1) početnosť absencie palmárneho trirádia d (Okajima a Iwayanagi, 1986);
- (2) incidencia os japonsicum (os zygomaticum bipartitum/tripartitum), variety líčnej kosti, kedy bežne celistvá kosť je aj v dospelosti rozdelená švami na dve až tri časti, pozri Hauser, De Stefano a kol. (1989, s. 222) a Dodo (1974);
- (3) celková perioperačná mortalita, t.j. mortalita v súvislosti s výkonom chirurgických operačných zákrokov (Bainbridge a kol., 2012);
- (4) výskyt ďalšieho infarktu myokardu do 30 dní po operácii u pacientov, ktorí boli liečení na ochorenie koronárnych tepien chirurgickým zásahom pomocou by-passu, kde operácia prebehla klasickým spôsobom so zastavením srdca a umelou cirkuláciou (Cheng a kol., 2005);
- (5) výskyt ďalšieho infarktu myokardu do 30 dní po operácii u pacientov, ktorí boli liečení na ochorenie koronárnych tepien chirurgickým zásahom pomocou by-passu, kde operácia prebehla moderným postupom na tlčúcom srdci (off-pump coronary artery bypass; Cheng a kol. (2005);
- (6) výskyt bilaterálnej agenézy horných laterálnych rezákov 12 a 22 (Alt a kol., 2013).

Príklad 78 (Poissonovo rozdelenie; pruské armádne jednotky) Nech početnosti Pruských armádnych jednotiek, v ktorých nastalo n úmrtí zapríčinených kopnutím koňom za rok (von Bortkiewicz, 1898), má Poissonovo rozdelenie s parametrom λ , t.j. $X \sim \text{Poiss}(\lambda)$. Pravdepodobnosť, že niekto bude smrteľne zranený v danom dni je extrémne malá. Majme 10 vojenských jednotiek za 20-ročnú periódu s rozsahom $M = 200$ ($200 = 10 \times 20$), kde popri početnostiach úmrtí $n = 1, 2, 3, 4, 5+$, v danej jednotke a v danom roku, zaznamenávame aj početnosti vojenských jednotiek m_n pri danom n , kde $M = \sum m_n$ (pozri tabuľku 2.7). Vypočítajte očakávané početnosti, za predpokladu $X \sim \text{Poiss}(\lambda)$, kde $\lambda = \frac{\sum_n n m_n}{\sum_n m_n}$.

Tabuľka 2.7: Pozorované a očakávané početnosti m_n (zaokrúhlené na nula desiatinných miest) Pruských armádnych jednotiek, v ktorých nastalo n úmrtí zapríčinených kopnutím koňom

n	0	1	2	3	4	5+
pozorované m_n	109	65	22	3	1	0
očakávané m_n	109	66	20	4	1	0

Príklad 79 (Poissonove rozdelenie; tri typy havárií) Nech n_1 je počet ľudí, ktorí zahynú pri automobilovej nehode, n_2 je počet ľudí, ktorí zahynú pri havárii lietadla, n_3 je počet ľudí, ktorí zahynú pri havárii vlaku v Taliansku budúci týždeň. Potom Poissonov model pre X_1 , X_2 a X_3 pre nezávislé poissonovské náhodné premenné s parametrami λ_1 , λ_2 a λ_3 je definovaný ako $X_1 + X_2 + X_3 \sim \text{Poiss}(\lambda_1 + \lambda_2 + \lambda_3)$.

Zovšeobecnením príkladu 79 dostaneme

$$X_1 + X_2 + \dots + X_J \sim \text{Poiss}(\lambda_1 + \lambda_2 + \dots + \lambda_J)$$

Poissonovo vs. multinomické rozdelenie. Dá sa ukázať, že

$$(X_1 + X_2 + \dots + X_J) | N \sim \text{Mult}_J(N, p_1, p_2, \dots, p_J),$$

kde $N = \sum_j X_j$ a $p_j = \lambda_j / \sum_j \lambda_j, j = 1, 2, \dots, J$. Ak $X_j, j = 1, 2, \dots, J$ sú nezávislé, $X_j \sim \text{Pois}(\lambda_j)$, kde $E(X_j) = \lambda_j$, potom podmienená pravdepodobnosť, že všetky $X_j = x_j$ za podmienky $N = \sum_j X_j$ sa rovná

$$\begin{aligned} \Pr \left[(X_1 = x_1, X_2 = x_2, \dots, X_J = x_J) \mid \sum_j X_j = N \right] &= \frac{\Pr(X_1 = x_1, X_2 = x_2, \dots, X_J = x_J)}{\Pr(\sum_j X_j = N)} \\ &= \frac{\prod_j \lambda_j^{x_j} e^{-\lambda_j} / x_j!}{\lambda^N e^{-\lambda} / N!} = \frac{N! e^{-\lambda} \prod_j \lambda_j^{x_j}}{\prod_j \lambda^x e^{-\lambda} x_j!} \\ &= \frac{N!}{\prod_j x_j!} \prod_j \left(\frac{\lambda_j}{\lambda} \right)^{x_j}, \text{ kde } p_j = \frac{\lambda_j}{\lambda}. \end{aligned}$$

Toto podmienené rozdelenie sa často používa pri log-lineárnych modeloch. Ak máme početnosti X_j pochádzajúce z Poissonovho rozdelenia, potrebujeme ich celkovú sumu N (*grand total*). Teda potrebujeme podmienené rozdelenie pri danom N , čo je v podstate multinomické rozdelenie.

Overdispersion a underdispersion. V praxi často variabilita presahuje variabilitu danú binomickým či Poissonovým modelom alebo je variabilita menšia ako variabilita daná binomickým či Poissonovým modelom. Prepokladáme, že každý človek má rovnakú pravdepodobnosť úmrtia pri dopravnej nehode budúci týždeň. Realistickejšie však tieto pravdepodobnosti varujú napr. podľa času stráveného šoféovaním, závisia od toho, či osoba má zapnuté pásy, závisia od geografickej polohy a pod.

V prípade *overdispersion*, teda v prípade, keď rozptyl presahuje strednú hodnotu, je realistickejšie nahradiť Poissonovo rozdelenie **negatívne binomickým rozdelením** (Agresti, 2002). Ak máme binomické (príp. multinomické) rozdelenie, tiež môže nastať prípad *overdispersion*, pretože skutočné rozdelenie je zmes rôznych binomických rozdelení s parametrami varujúcimi kvôli nenameraným (mätiacim) premenným.

Negatívne binomické rozdelenie. Majme nezávislé identické *Bernoulliho* pokusy s odpoveďami $X_i = 1$ (udalosť nastala) alebo $X_i = 0$ (udalosť nenastala) pre $i = 1, 2, \dots$. Pravdepodobnosť nastatia udalosti pre každý pokus $\Pr(X_i = 1) = p$, pravdepodobnosť neúspechu pre každý pokus $\Pr(X_i = 0) = 1 - p$. Nech X je počet úspechov pred k -tým neúspechom. Potom $\Pr(X = x) = \binom{x+k-1}{x} p^x (1-p)^k$ má negatívne binomické rozdelenie s $E[X] = k \frac{p}{1-p}$ a $\text{Var}[X] = k \frac{p}{(1-p)^2}$, ozn. $X \sim \text{Negbin}(k, p)$. Poissonovo rozdelenie je limitným prípadom negatívne binomického rozdelenia, kde $k \rightarrow \infty, p \rightarrow 0$ a fixovaným $kp = \lambda$.

Príklad 80 (podiel chlapcov a dievčat v rodinách) Nech X predstavuje početnosť chlapcov medzi deťmi v rodinách. Tu môžeme predpokladať, že $X \sim \text{Bin}(N, p)$, t.j. rodina môže mať vychýlený pomer pohlaví detí v smere ku chlapcom alebo dievčatám. V realite teda môžeme mať príliš veľa rodín len s chlapcami alebo len s dievčatami a nemáme dostatok rodín s pomerom pohlaví blízkym 51 : 49 (pomer chlapcov ku dievčatám). Z toho nám vyplýva, že rozptyl početnosti chlapcov bude v skutočnosti väčší ako rozptyl predpokladaný binomickým modelom $\text{Bin}(N, p)$.

Overdispersion v binomickom modeli. Nech $X_i \sim \text{Bin}(N, p_i)$ a nech $X = X_I$ je náhodne zvolené z X_i , kde náhodný index $I = i$ má pravdepodobnosť $1/m$. Budeme teda mať zmes binomických rozdelení s marginálnou pravdepodobnosťou

$$\Pr(X = x) = E[\Pr(X_I = x | I)] = \frac{1}{m} \sum_{i=1}^m \Pr(X_i = x) = \frac{1}{m} \sum_{i=1}^m \binom{N}{x} p_i^x (1-p_i)^{N-x},$$

$$E[X] = E[E[X_I|I]] = \frac{1}{m} \sum_{i=1}^m E[X_i] = \frac{N}{m} \sum_{i=1}^m p_i = N\pi,$$

kde $\pi = \sum_{i=1}^m p_i/m$ a

$$\begin{aligned} \text{Var}[X] &= E[\text{Var}[X_I|I]] + \text{Var}[E[X_I|I]] = \frac{1}{m} \sum_{i=1}^m \text{Var}[X_i] + \frac{1}{m} \sum_{i=1}^m E^2[X_i] - \left(\sum_{i=1}^m E[X_i]/m \right)^2 \\ &= \frac{1}{m} \sum_{i=1}^m Np_i(1-p_i) + \frac{1}{m} \sum_{i=1}^m (Np_i)^2 - (N\pi)^2 = N\pi(1-\pi) + N(N-1)\sigma_p^2, \end{aligned}$$

kde σ_p^2 je definovaná ako pri *underdispersion*. Z toho vyplýva, že pri náhodnej voľbe z rôznych individuálnych pravdepodobností p_i je rozptyl väčší ako rozptyl za platnosti binomického modelu.

Príklad 81 (overdispersion v binomickom modeli) V klasickej štúdiu pomeru pohlaví u ľudí z roku 1889 na základe záznamov z nemocníc v Sasku (bližšie pozri Lindsey a Altham, 1998; Geissler, 1889) zaznamenal rozdelenie počtu chlapcov v rodinách. Medzi $M = 6115$ rodinami s $N = 12$ deťmi pozoroval početnosti chlapcov (pozri tabuľku 2.8). Vypočítajte m_n za predpokladu, že početnosti chlapcov X v rodinách majú binomické rozdelenie s parametrami $\pi = \frac{\sum_{n=0}^N nm_n}{NM} = 0.5192$ a $N = 12$, ozn. $X \sim \text{Bin}(N, \pi)$.

Tabuľka 2.8: Pozorované početnosti rodín m_n s n chlapcami

n	0	1	2	3	4	5	6	7	8	9	10	11	12
pozorované m_n	3	24	104	286	670	1033	1343	1112	829	478	181	45	7

Riešenie

Tabuľka 2.9: Očakávané početnosti rodín m_n (zaokrúhlené na nula desatinných miest) s n chlapcami (binomické rozdelenie)

n	0	1	2	3	4	5	6	7	8	9	10	11	12
očakávané m_n	1	12	72	258	628	1085	1367	1266	854	410	133	26	2

Keď porovnáme pozorované m_n (pozri tabuľku 2.8) a vypočítané (teoretické) m_n (pozri tabuľku 2.9) zistíme, že pozorované poukazujú na *overdispersion*, t.j. máme väčšie početnosti rodín s malým a veľkým množstvom chlapcov v porovnaní s teoretickými početnosťami.

Underdispersion v binomickom modeli. Nech X_1, X_2, \dots, X_N sú nezávislé binomické pokusy s pravdepodobnosťami p_1, p_2, \dots, p_N . Nech $X = \sum_{i=1}^N X_i$, potom $E[X] = \sum_{i=1}^N p_i = N\pi$, kde $\pi = \frac{1}{N} \sum_{i=1}^N p_i$, ale

$$\begin{aligned} \text{Var}[X] &= \sum_{i=1}^N \text{Var}[X_i] = \sum_{i=1}^N p_i(1-p_i) = \sum_{i=1}^N p_i - \sum_{i=1}^N p_i^2 \\ &= \sum_{i=1}^N p_i - \frac{\left(\sum_{i=1}^N p_i\right)^2}{N} - \left(\sum_{i=1}^N p_i^2 - \frac{\left(\sum_{i=1}^N p_i\right)^2}{N} \right) \\ &= N\pi - N\pi^2 - N\sigma_p^2 = N\pi(1-\pi) - N\sigma_p^2, \end{aligned}$$

kde $\sigma_p^2 = \frac{1}{N} \left(\sum_{i=1}^N p_i^2 - \frac{\left(\sum_{i=1}^N p_i\right)^2}{N} \right)$ je rozptyl medzi p_i . Z toho vyplýva, že pri rôznych individuálnych pravdepodobnostiach p_i je rozptyl menší ako rozptyl za platnosti binomického modelu.

Overdispersion v Poissonovom modeli. Predpokladajme, že náhodná premenná X má rozptyl $Var[X]$ podmienený strednou hodnotou $E[X] = \mu$, kde μ je náhodná premenná so strednou hodnotou $E[\mu]$ a rozptylom $Var[\mu] = \sigma_\mu^2$. Teda pre jednotlivé subjekty μ , charakterizujúca napr. nehodu, varíruje. Hoci počet nehôd na subjekt má rozdelenie $Poiss(\mu)$, marginálne rozdelenie bude charakterizované *overdispersion*, a teda

$$E[X_\mu] = E[E[X_\mu|\mu]] = E[\mu] \text{ a } Var[X_\mu] = E[Var[X_\mu|\mu]] + Var[E[X_\mu|\mu]] = E[\mu] + \sigma_\mu^2,$$

čo poukazuje na väčšiu variabilitu v porovnaní s Poissonovým modelom. Za predpokladu, že μ má **gama rozdelenie**, môžeme ľahko spočítať marginálne pravdepodobnosti, t.j. ak X_μ má Poissonovo rozdelenie so strednou hodnotou μ , μ má hustotu $f(\mu) = \frac{1}{\Gamma(\alpha)}\mu^{\alpha-1}\lambda^\alpha e^{-\lambda\mu}$. Náhodná premenná X predstavujúca zmes X_μ má strednú hodnotu $E[X] = E[\mu] = \frac{\alpha}{\lambda}$ a rozptyl $Var[X] = E[\mu] + Var[\mu] = \frac{\alpha}{\lambda} + \frac{\alpha}{\lambda^2}$. Marginálna pravdepodobnosť pre $x = 0, 1, \dots$, je potom rovná

$$\begin{aligned} \Pr(X = x) &= E[\Pr(X_\mu = x|\mu)] = E[e^{-\mu} \frac{\mu^x}{x!}] = \frac{\lambda^\alpha}{\Gamma(\alpha)x!} \int e^{-\mu} \mu^x \mu^{\alpha-1} e^{-\lambda\mu} d\mu \\ &= \frac{\lambda^\alpha \Gamma(x + \alpha)}{(\lambda + 1)^{x+\alpha} \Gamma(\alpha)x!} = \binom{x + \alpha - 1}{\alpha - 1} \left(\frac{\lambda}{\lambda + 1}\right)^\alpha \left(1 - \frac{\lambda}{\lambda + 1}\right)^x, \end{aligned}$$

kde $(x + \alpha - 1)! = \Gamma(x + \alpha)$. Ide teda o negatívne binomické rozdelenie, kde X je počet neúspechov (úrazov, zlyhaní) zaznamenaných po α úspechoch, pravdepodobnosť úspechu $\pi = \frac{\lambda}{\lambda+1}$ a pomer zlyhaní $\mu = \frac{1-\pi}{\pi}\alpha$.

Príklad 82 (overdispersion v Poissonovom modeli) *Majme početnosti robotníkov m_n s n úrazmi v továrni (pozri v tabuľku 2.10; Greenwood a Yule (1920)). Vypočítajte očakávané početnosti robotníkov za predpokladu, že početnosti úrazov na robotníka X majú Poissonove rozdelenie s parametrom $\lambda = \frac{\sum_n n m_n}{\sum_n m_n} = 0.47$, ozn. $X \sim Poiss(\lambda)$.*

Tabuľka 2.10: Pozorované početnosti robotníkov m_n s n úrazmi v továrni

n	0	1	2	3	4	≥ 5
pozorované m_n	447	132	42	21	3	2

Riešenie

Ked' porovnáme pozorované m_n (pozri tabuľku 2.10) a vypočítané (teoretické, očakávané) m_n (pozri tabuľku 2.11) zistíme, že pozorované poukazujú na *overdispersion*, t.j. máme viac robotníkov bez úrazu ako aj viac robotníkov s väčším množstvom úrazov v porovnaní s teoretickými početnosťami.

Tabuľka 2.11: Očakávané početnosti robotníkov m_n (zaokrúhlené na nula desiatinných miest) s n úrazmi v továrni (Poissonovo rozdelenie)

n	0	1	2	3	≥ 4
očakávané m_n	406	189	44	7	1

2.1 *Simulačný experiment ako nástroj štúdia teoretických vlastností modelov

Monte Carlo (MC) experiment. Pojem MC metóda je známy od 40. rokov dvadsiateho storočia a zaviedli ho fyzici pracujúci na projekte o jadrových zbraniach v Los Alamos National Laboratory, menovite Stanislav Ulam, Enrico Fermi, John von Neuman a Nicholas Metropolis. MC je odvodené od kasína v Monaku, kde Ulamov strýko hrával hazardné hry. Použitie tzv. **náhodnosti a opakovateľnosti MC procesu** je analogické aktivitám v kasíne. Prvýkrát metódu použil Enrico Fermi v roku 1930 na výpočet vlastností novoobjaveného neutrónu. MC experiment bol použitý tiež v 50. rokoch 20. storočia počas vývoja vodíkovej bomby. U.S. Air Force bola v tom čase hlavnou organizáciou zodpovednou za financovanie a rozšírenie informácie o MC metódach, ktoré si začali hľadať cestu

k mnohým ďalším aplikáciám, najprv vo fyzike, neskôr v chémii a nakoniec aj v matematike a štatistike. V štatistike sa MC metódy používajú na študovanie asymptotických vlastností odhadov a testovacích štatistík (príp. štatistických modelov) a zisťovanie ich správania sa za kontrolovaných podmienok (pozri napr. Rizzo, 2007; Gentle, 2009). Jediný predpoklad **dobrej simulácie pseudonáhodných čísel** používaný v MC metódach je **dostatočná náhodnosť v širšom slova zmysle** (Suess a Trumbo, 2010).

Simulačný experiment (mnohonásobne opakované náhodné výbery) musí spĺňať nasledovné tri kritériá (Robert a Casella, 2010)

1. **relevantnosť** – vygenerované (simulované) dáta musia byť generované na základe relevantných pravidiel, napr. kombinácia minulých skúseností a súčasných dát, *hypotetického pravdepodobnostného* alebo *štatistického modelu*, ktorý chceme študovať a pod.;
2. **stabilita** – *centrálna limitná veta* (CLV; použiteľná aj pre n menšie ako 100) a *dva zákony veľkých čísel* (použiteľné pre n väčšie ako 100 alebo 1000) garantujú, že ak je plán simulačnej štúdie správny a simulácia má dostatočne veľa opakovaní, dostaneme stabilný výsledok namiesto náhodného šumu;
3. **diagnostika** – pomocou rôznych numerických a grafických metód môžeme rozlíšiť signál od šumu, napr. porovnanie numerického a analytického riešenia, porovnanie viacerých podobných modelov, použitie dostatočného množstva opakovaní a pod.

Veta 1 (CLV) *Nech X_i , $i = 1, 2, \dots, n$, sú iid náhodné premenné s rovnakou strednou hodnotou $E[X_i] = \mu \in \mathbb{R}$ a konečným rozptylom $\text{Var}[X_i] = \sigma^2 < \infty$. Potom $\frac{1}{\sigma\sqrt{n}}(\sum_{i=1}^n X_i - n\mu)$ má limitne (pre dostatočne veľké n) štandardizované normálne rozdelenie (t.j. konverguje v distribúcii k štandardizovanému normálnemu rozdeleniu $N(0, 1)$; Wasserman (2006).*

Veta 2 (Slabý zákon veľkých čísel) *Nech X_i , $i = 1, 2, \dots, n$, sú iid náhodné premenné s rovnakou strednou hodnotou $E[X_i] = \mu \in \mathbb{R}$ a konečným rozptylom $\text{Var}[X_i] = \sigma^2 < \infty$. Nech $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Potom pre každé $\epsilon > 0$ platí $\lim_{n \rightarrow \infty} \Pr(|\bar{X}_n - \mu| < \epsilon) = 1$, t.j. pre dostatočne veľké n platí, že \bar{X}_n konverguje v pravdepodobnosti k μ (Lehmann, 1999).*

Veta 3 (Silný zákon veľkých čísel) *Nech X_i , $i = 1, 2, \dots, n$, sú iid náhodné premenné s rovnakou strednou hodnotou $E[X_i] = \mu \in \mathbb{R}$ a konečným rozptylom $\text{Var}[X_i] = \sigma^2 < \infty$. Nech $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Potom pre každé $\epsilon > 0$ platí $\Pr(\lim_{n \rightarrow \infty} |\bar{X}_n - \mu| < \epsilon) = 1$, t.j. pre dostatočne veľké n platí, že \bar{X}_n konverguje skoro iste k μ (Lehmann, 1999).*


CLV a zákony veľkých čísel nám v praxi zabezpečia použitie nejakého modelu rozdelenia pravdepodobnosti na reálne dáta za predpokladu, že máme dostatočne veľký rozsah náhodného výberu (DasGupta, 2008). Dôsledky použitia modelu rozdelenia pravdepodobnosti na reálne dáta s malým rozsahom siahajú od nesprávneho použitia štatistického modelu po nesprávne použitie štatistického testu, čoho dôsledkom je nedôveryhodná interpretácia výsledkov štatistickej analýzy.

Príklad 83 (binomický rozdelenie, simulačná štúdia) *Vygenerujte pseudonáhodné čísla X (početnosti úspechov) opakovane M -krát ($M = 1000$) z $\text{Bin}(N, p)$, kde $N = 5$ a $p = 0.5$. Vytvorte tabuľku vygenerovaných (simulovaných) ako aj teoretických relatívnych početností (pre $n = 0, 1, \dots, 5$). Superponujte histogram vygenerovaných pseudonáhodných čísel s teoretickou pravdepodobnostnou funkciou.*

Riešenie (pozri tabuľku 2.12 a obrázok 2.12)

Tabuľka 2.12: Simulované a teoretické relatívne početnosti úspechov

relatívne početnosti/ n	0	1	2	3	4	5
simulované	0.025	0.151	0.310	0.322	0.168	0.024
teoretické	0.031	0.156	0.312	0.312	0.156	0.031



Obr. 2.12: Histogram vygenerovaných pseudonáhodných čísel superponovaný spojnicovým grafom teoretickej pravdepodobnostnej funkcie X

Príklad 84 (binomické vs. normálne rozdelenie) *Nech $X_N \sim \text{Bin}(N, p)$, potom môžeme aproximovať binomické rozdelenie normálnym nasledovne - $X_N \sim N(Np, Np(1-p))$, kde tiež platí $Z_N = \frac{X_N - Np}{\sqrt{Np(1-p)}} \sim N(0, 1)$. Ukážte, že CLV platí pre $N = 100$ a $p = 1/2$ na tri desatinné miesta.*

Riešenie (aj v \mathbb{R})

Príklad hovorí o tom, ako dobre normálne rozdelenie aproximuje binomické pri rozsahu $N = 100$, čo je dôležité pri testovaní hypotéz.

$$E[X_N] = Np = 50, \quad \sqrt{\text{Var}[X_N]} = \sqrt{Np(1-p)} = 5.$$

Ak $Y_N = X_N/N$, potom $\Pr(|Y_N - 1/2| < \epsilon) = 0.236$, kde $\epsilon = 0.02$. $\Pr(0.48 < Y_{100} < 0.52) = \Pr(48 < X_{100} < 52) = \Pr(48.5 < X_{100} < 51.5) = \Pr(\frac{48.5-50}{5} < Z_{100} < \frac{51.5-50}{5})$, kde $X_{100} \sim N(50, 5)$ s použitím úpravy na spojitosť.

```
55 | pbinom(51,100,.5)-pbinom(48,100,.5) # 0.2356466
56 | pnorm(51.5,50,5)-pnorm(48.5,50,5) # 0.2358228
```

Výsledky sa zhodujú na tri desatinné miesta. Všeobecne platí $X_M \sim N(M/2, M/4)$ a $Y_M = X_M/M \sim N(1/2, 1/(4M))$.

Príklad 85 (normálne rozdelenie, simulačná štúdia) *Na základe simulačnej štúdie preverte, že ak $X \sim N(150, 6.25)$, potom $\bar{X}_n \sim N(150, 6.25/n)$. Použite (1) $n = 5$, (2) $n = 30$ a (3) $n = 100$. Pre každú simuláciu X vypočítajte aritmetické priemery \bar{x}_m , $m = 1, 2, \dots, M$, kde $M = 1000$. Superponujte ich histogram v relatívnej škále s teoretickou krivkou hustoty pre \bar{X}_n . Vypočítajte $\Pr(\bar{X}_n > 151)$ pre $n = 30$ zo simulovaných dát a porovnajte tento výsledok s teoretickou (očakávanou) pravdepodobnosťou.*


Riešenie (aj v \mathbb{R}) (pozri obrázok 2.13)

Príklad hovorí o tom, že ak má náhodná premenná X_n normálne rozdelenie, bude mať normálne rozdelenie aj aritmetický priemer \bar{X}_n , čo je dôležité pri testovaní hypotéz.

$$\Pr(\bar{X}_n > 151) = \Pr\left(\frac{\bar{X}_n - 150}{\sqrt{6.25/n}} > \frac{151 - 150}{\sqrt{6.25/n}}\right) \approx \Phi(2.190890) = 0.01422987, \text{ kde } n = 30.$$

```
57 | M <- 1000; n30 <- 30
58 | X30 <- matrix(0,M,n30)
59 | for (i in 1:M) X30[i,] <- rnorm(n30,150,sqrt(6.25))
60 | x.bar30 <- rowMeans(X30)
61 | # pravdepodobnosti
62 | mean(x.bar30 > 151) # 0.014238
63 | 1-pnorm((151-150)/sqrt(6.25/n30)) # 0.01422987
64 | # obrazok pre n=30
65 | windows(5,5)
66 | par(mar=c(5,4.5,1,1))
67 | hist(x.bar30, probability=TRUE, col="gray", main="", ylab="hustota", xlab="priemery", sub="n=30", cex.lab=1.2,
68 |      cex.sub=1.2)
69 | xmin <- 150-3*sqrt(6.25/n30)
70 | xmax <- 150+3*sqrt(6.25/n30)
71 | curve(dnorm(x,150,sqrt(6.25/n30)), from=xmin, to=xmax, lwd=2, add=TRUE)
```

Pri dostatočne veľkom počte opakovaní vidíme zhodu medzi teoretickým a simulovaným rozdelením \bar{X}_n na tri desatiné miesta (pri výpočte zadanej pravdepodobnosti).



Obr. 2.13: Histogram vygenerovaných priemerov superponovaný teoretickou krivkou hustoty \bar{X}_n

Príklad 86 (normálne rozdelenie, simulačná štúdia) *Nech (a) $X \sim N(\mu, \sigma^2)$, $\mu = 0$, $\sigma^2 = 1$, (b) $X \sim \text{Exp}(\lambda)$, $\lambda = 1/3$, (c) $X \sim \text{Unif}(\min, \max)$, $\min = 0$, $\max = 1$, (d) $X \sim [pN(0, 1) + (1 - p)N(0, 10)]$, kde $p = 0.9$. Použite \mathbb{R} na simuláciu pseudonáhodných čísel z daných rozdelení – rozsahy náhodných výberov $n = 2, 5, 20, 50, 100$ a 500 . Pre každú simuláciu X vypočítajte aritmetické priemery \bar{x}_m , $m = 1, 2, \dots, M$, kde $M = 1000$. Zobrazte ich do histogramu v relatívnej škále a superponujte ho s teoretickou krivkou hustoty $N(\mu, \sigma^2/n)$ prislúchajúcej danej simulácii.*

Príklad 86 slúži na zistenie vlastností rozdelenia výberového priemeru pri rôznych situáciách. $\text{Exp}(\lambda)$ je exponenciálne rozdelenie s parametrom λ , $\text{Unif}(\min, \max)$ je rovnomerné rozdelenie s parametrami \min a \max . Zmes dvoch normálnych rozdelení predstavuje 10% prímies normálneho rozdelenia s väčším rozptylom rovným $\sigma^2 = 10$ v normálnom rozdelení s menším rozptylom rovným $\sigma^2 = 1$, čím sme docielili výskyt 10 % odľahlých pozorovaní.

Príklad 87 (normálne rozdelenie, simulačná štúdia) *Nech $X \sim N(\mu_1, \sigma_1^2)$ a $Y \sim N(\mu_2, \sigma_2^2)$. Potom $\bar{X}_{n_1} - \bar{Y}_{n_2} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2})$. Generujte pseudonáhodné čísla X a Y rozdelení $N(\mu_j, \sigma_j^2)$, $j = 1, 2$, kde $\mu_1 = 100$, $\sigma_1 = 10$, $\mu_2 = 50$, $\sigma_2 = 9$ pri (a) $n_1 = 4$, $n_2 = 5$, (b) $n_1 = 100$, $n_2 = 81$. Pre každú simuláciu X a Y vypočítajte rozdiel $\bar{x}_m - \bar{y}_m$, $m = 1, 2, \dots, M$, kde $M = 1000$. Superponujte histogram týchto rozdielov v relatívnej škále s teoretickou krivkou hustoty rozdielu $\bar{X}_{n_1} - \bar{Y}_{n_2}$. Pre prípad (a) aj (b) vypočítajte $\Pr(\bar{X}_{n_1} - \bar{Y}_{n_2}) < 52$ na základe empirického (vygenerovaného) a teoretického rozdelenia $\bar{X}_{n_1} - \bar{Y}_{n_2}$.*

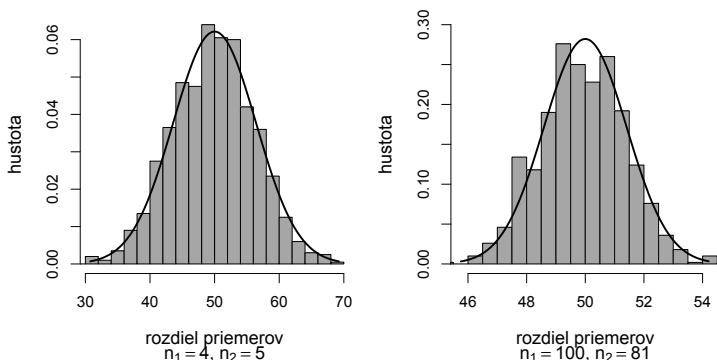
Príklad 87 slúži na zistenie vlastností rozdelenia rozdielu dvoch výberových priemerov pri rôznych situáciách. Pri dostatočne veľkom počte opakovaní vidíme zhodu medzi teoretickým a simulovaným rozdelením $\bar{X}_{n_1} - \bar{Y}_{n_2}$ na dve desatiné miesta (pri výpočte zadanej pravdepodobnosti; pozri obrázok 2.14).

2.2 *Štatistika

Definícia 15 (štatistika) *Ľubovoľná funkcia $T(\cdot): \mathcal{Y} \rightarrow \mathbb{R}^r$, pre nejaké $r \in \mathbb{N}^+$ náhodného výberu $(X_1, X_2, \dots, X_n)^T$, kde funkcia $T = T(X_1, X_2, \dots, X_n)$ nezávislá na θ sa nazýva **štatistika** a hodnota $t = T(x_1, x_2, \dots, x_n)$ korešpondujúca realizáciám x_1, x_2, \dots, x_n sa nazýva **realizácia štatistiky** (pozorovaná hodnota štatistiky).*

Príklad 88 (štatistika) *Majme náhodný výber $(X_1, X_2, \dots, X_n)^T$, kde $X_i \in \mathbb{R}$, $i = 1, 2, \dots, n$, potom príkladmi štatistík sú: $T_1 = \sum_{i=1}^n X_i \in \mathbb{R}$, $T_2 = \sum_{i=1}^n X_i^2 \in \mathbb{R}^+ \cup \{0\}$, $T_3 = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2) \in \mathbb{R}^2$.*

Štatistiky teda môžu byť náhodné premenné alebo náhodné vektory, ktoré sumarizujú informáciu o dátach, zjednodušujú pohľad na ne a umožňujú na ich základe dáta jednoduchšie popísať a ľahšie interpretovať.



Obr. 2.14: Histogram vygenerovaných rozdielov priemerov superponovaný teoretickou krivkou hustoty rozdelenia rozdielov výberových aritmetických priemerov

Príklad 89 (štatistika; príklady) (a) Vypočítajte štatistiku $T_1 = \sum_{i=1}^n X_i$ pre realizácie náhodnej premennej X najväčšia dĺžka mozgovne (skull.L; mm; dáta: one-sample-mean-skull-mf.txt). V tomto prípade ide o čitateľ aritmetického priemeru \bar{x} . (b) vypočítajte štatistiku $T_2 = \sum_{i=1}^n X_i^2$ pre realizácie náhodnej premennej $X = X_1 - X_2$, kde X predstavuje stranový rozdiel vertikálneho priemeru v strede dĺžky tela klúčnej kosti na pravej aj ľavej strane tela (length.R a length.L; v mm; dáta: paired-means-clavicle2.txt). V tomto prípade ide o sumu štvorcov stranových rozdielov.

Definícia 16 (postačujúca štatistika) Pre štatistický model \mathcal{F} je štatistika $T(x)$ **postačujúca** pre parameter θ , ak má rovnakú hodnotu pre dva body rôzne x_1 a x_2 z výberového priestoru \mathcal{Y} iba ak tieto body majú ekvivalentné funkcie vierohodnosti (Azzalini, 1996), t.j. pre

$$\forall x_1, x_2 \in \mathcal{Y} : T(x_1) = T(x_2) \Rightarrow L(\theta, x_1) \approx L(\theta, x_2) \text{ pre všetky } \theta \in \Theta.$$

Detaily o funkcii vierohodnosti pozri v kapitole 2.3 *Funkcia vierohodnosti. Aj napriek tomu, že nebijektívna transformácia obsahuje „všetku informáciu o dátach“, treba mať na zreteli, že to súvisí s voľbou modelu, t.j. ak sa zmení model, štatistika už nemusí byť postačujúca (Bickel a Doksum, 2006). Preto je voľba modelu veľmi dôležitá. Anděl (2011) uvádza inú definíciu postačujúcej štatistiky.

Definícia 17 (postačujúca štatistika) Štatistika $T(\mathbf{X})$ sa nazýva **postačujúca štatistika** pre parameter θ , ak podmienené rozdelenie vektora $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$ pri danom $T(\mathbf{X})$ nezávisí na θ .

Predchádzajúca definícia hovorí o tom, že ak $T(\mathbf{X})$ je postačujúca štatistika pre θ , potom každá inferencia o θ závisí na \mathbf{X} len cez hodnotu $T(\mathbf{X})$, t.j. ak \mathbf{x} a \mathbf{y} sú dve realizácie a $T(\mathbf{x}) = T(\mathbf{y})$, potom inferencia o θ bude rovnaká nezávisle na tom, či sme pozorovali $\mathbf{X} = \mathbf{x}$ alebo $\mathbf{Y} = \mathbf{y}$.

Veta 4 (postačujúca štatistika) Ak $f_1(\mathbf{x}|\theta)$ je združená hustota \mathbf{X} a $f_2(t|\theta)$ je hustota $T(\mathbf{X})$, potom $T(\mathbf{X})$ je postačujúca štatistika pre θ , ak pre všetky \mathbf{x} je podiel $f_1(\mathbf{x}|\theta)/f_2(t|\theta)$ konštanta nezávislá na θ (Casella a Berger, 2002).

Príklad 90 (postačujúca štatistika binomického rozdelenia) Nech X_i , $i = 1, 2, \dots, N$, sú iid Bernoulliho pokusy a $X = \sum_{i=1}^N X_i$. Potom $X \sim \text{Bin}(N, p)$. Ukážte, že $T(\mathbf{X}) = \sum_{i=1}^N X_i$ je postačujúca štatistika pre p .

Riešenie

$f_1(\mathbf{x}|p)/f_2(t|p) = \prod_{i=1}^N p^{x_i}(1-p)^{1-x_i} / \binom{N}{t} p^t(1-p)^{N-t} = 1 / \binom{N}{\sum x_i}$. Tento podiel je nezávislý na p , t.j. súčet jednotiek obsahuje všetku informáciu o p , ktorá je v dátach.

Príklad 91 (postačujúca štatistika normálneho rozdelenia) *Nech $X_i \sim N(\mu, \sigma^2)$, kde $i = 1, 2, \dots, n$, sú iid premenné a σ^2 poznáme. Ukážte, že $T(\mathbf{X}) = \sum_{i=1}^n X_i/n = \bar{X}$ je postačujúca štatistika pre μ .*

Riešenie

$f_1(\mathbf{x}|\mu)/f_2(t|\mu) = \prod_{i=1}^n f(x_i, \mu)/f_2(t|\mu)$, kde $f(x_i, \mu)$ je hustota normálneho rozdelenia a $f_2(t|\mu) = (2\pi\sigma^2/n)^{-1/2} \exp(-n(\bar{x} - \mu)^2/(2\sigma^2))$. Po viacerých algebraických úpravách dostaneme

$$f_1(\mathbf{x}|\mu)/f_2(t|\mu) = n^{-1/2}(2\pi\sigma^2)^{-(n-1)/2} \exp\left(-\sum_{i=1}^n (x_i - \bar{x})^2/(2\sigma^2)\right).$$

Tento podiel je nezávislý na μ , t.j. \bar{X} obsahuje všetku informáciu o μ , ktorá je v dátach.

Dá sa ukázať, že ak $X_i \sim N(\mu, \sigma^2)$, kde $i = 1, 2, \dots, n$, sú iid premenné, potom $T_1(\mathbf{X}) = (\bar{X}, \sum_{i=1}^n X_i^2)^T$ a $T_2(\mathbf{X}) = (\bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2)^T$ sú postačujúce štatistiky $\boldsymbol{\theta} = (\mu, \sigma^2)^T$.

Špeciálnym prípadom štatistiky je **testovacia štatistika**, ktorá má kľúčovú úlohu pri testovaní hypotéz.

Príklad 92 (testovacia štatistika, simulačná štúdia) *Na základe simulačnej štúdie preverte, že ak náhodná premenná X má asymptoticky binomické rozdelenie $\text{Bin}(N, p)$, potom testovacia štatistika $Z_W = \frac{X/N-p}{\sqrt{(p(1-p))/N}}$, má asymptoticky normálne rozdelenie $N(0, 1)$. Použite $p = 0.1, 0.5, 0.9$, a $N = 5, 10, 30, 50$ a 100 . Okomentujte výsledky v spojitosti s Haldovou podmienkou $Np(1-p) > 9$. Pre každú simuláciu X vypočítajte $z_{W,m}$, $m = 1, 2, \dots, M$, kde $M = 1000$. Superponujte histogram vygenerovaných testovacích štatistík v relatívnej škále s teoretickou krivkou hustoty Z_W .*

Príklad 92 hovorí o použití jednovýberovej testovacej štatistiky pre parameter binomického rozdelenia (pravdepodobnosť) pre rôzne pravdepodobnosti a rôzne početnosti. Ak Haldova podmienka nie je splnená, nie je možné testovaciu štatistiku použiť.

Príklad 93 (testovacia štatistika, simulačná štúdia) *Na základe simulačnej štúdie preverte, že (a) $X \sim N(\mu, \sigma^2)$, kde $\mu = 0, \sigma^2 = 1$ a (b) $X \sim [(1-p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$, kde $p = 0.05$ a $\sigma_1^2 = 2$, potom testovacia štatistika $F = \frac{(n-1)S^2}{\sigma^2}$ má asymptoticky χ_{n-1}^2 rozdelenie s $n-1$ stupňami voľnosti. Použite rozsahy náhodných výberov $n = 15$ a $n = 100$. Pre každú simuláciu X vypočítajte $F_{\text{obs},m}$, $m = 1, 2, \dots, M$, kde $M = 1000$. Superponujte histogram vygenerovaných testovacích štatistík v relatívnej škále s teoretickou krivkou hustoty F .*

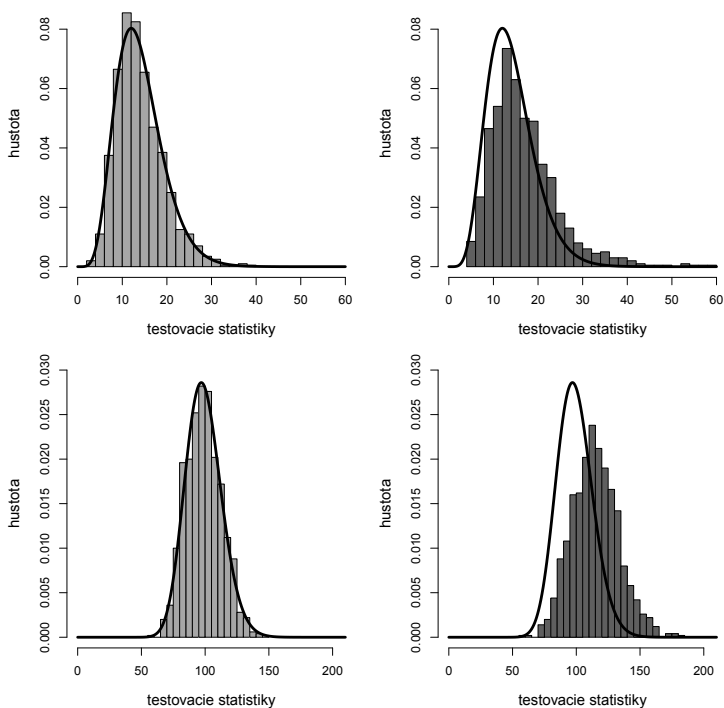
Riešenie

Príklad hovorí o použití jednovýberovej testovacej štatistiky pre parameter normálneho rozdelenia (rozptyl) pre rôzne teoretické rozdelenia a rôzne rozsahy náhodných výberov. Ak sú výchyľky od normality príliš veľké, nie je možné testovaciu štatistiku použiť. Vieme, že $E[S^2] = \sigma^2 = 1$ a $\text{Var}[S^2] = 2\sigma^4/(n-1) = 2/(n-1)$, $E[F] = n-1$ a $\text{Var}[F] = 2(n-1)$, t.j. chceme, aby sa výsledky simulačnej štúdie priblížili týmto teoretickým hodnotám (pozri tabuľku 2.13).

Tabuľka 2.13: Teoretické hodnoty stredných hodnôt a rozptylov S^2 a F a ich odhady zo simulačnej štúdie pri $n = 15$ a $n = 100$

odhady počítané pri simulácii	$E[S^2]$	$\text{Var}[S^2]$	$E[F]$	$\text{Var}[F]$
teoretické hodnoty, $n = 15$	1.0000	0.1429	14.0000	28.0000
$N(\mu, \sigma^2)$, $n = 15$	1.0003	0.1458	14.0039	28.5763
$X \sim [(1-p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$, $n = 15$	1.2015	0.2943	16.8213	57.6880
teoretické hodnoty, $n = 15$	1.0000	0.0202	99.0000	198.0000
$N(\mu, \sigma^2)$, $n = 100$	0.9985	0.0198	98.8552	193.7022
$X \sim [(1-p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$, $n = 100$	1.1596	0.0342	114.8005	335.5359

Pri dostatočne veľkom počte opakovaní vidíme zhodu medzi teoretickým a simulovaným rozdelením F , len ak ide o dáta z normálneho rozdelenia (pozri obrázok 2.15).



Obr. 2.15: Histogramy vygenerovaných testovacích štatistík v relatívnej škále superponované s teoretickými krivkami hustoty F ; $X \sim N(0, 1)$ (ľavý stĺpec) a $X \sim [(1 - p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$ (pravý stĺpec); $n = 15$ (horný riadok), $n = 100$ (dolný riadok)

2.3 *Funkcia vierohodnosti

Funkcia vierohodnosti je najpoužívanejšou funkciou v štatistike. Sumarizuje informácie dostupné z dát v podobe logaritmu, prvej a druhej derivácie. Používa sa nielen pri odhadovaní parametrov rozdelení pravdepodobnosti, ale aj pri testovaní hypotéz a štatistickom modelovaní.

Majme štatistický model $\mathcal{F} = \{f(\cdot; \theta) : \theta \in \Theta \subseteq \mathbb{R}^k\}$. Nech $k = 1$. Ak už bolo x pozorované, hodnota funkcie hustoty $f(\theta, \mathbf{x})$ závisí len od θ . Táto funkcia nám dáva pravdepodobnosť (hustotu) pozorovaní, a priori vo vzťahu k experimentu, ktoré sme predtým pozorovali. Ak chceme porovnať alebo zoradiť $\theta_1, \theta_2 \in \Theta$ podľa dôležitosti, použijeme podiel $f(\mathbf{x}, \theta_1)/f(\mathbf{x}, \theta_2)$, ak existuje. Tento podiel sa nezmení, ak čitateľ a menovateľ vynásobíme nejakou konštantou c nezávislou na θ . Dá sa preto povedať, že $f(\theta, \mathbf{x})$ je vhodná na porovnanie prvkov množiny Θ až na multiplikatívnu konštantu c (Pawitan, 2001).

Definícia 18 (funkcia vierohodnosti) Pre štatistický model \mathcal{F} , na základe ktorého predpokladáme, že $x \in \mathbb{R}$ boli pozorované, použijeme pojem **vierohodnosť** (**vierohodnostná funkcia**) pre funkciu $\Theta \rightarrow \mathbb{R}^+ \cup \{0\}$ definovanú ako (Cox, 2006)

$$L(\theta, \mathbf{x}) = c(\mathbf{x})f(\mathbf{x}, \theta),$$

kde $c \in \mathbb{R}$ je nezávislá na θ a $f(\mathbf{x}, \theta) = \prod_{i=1}^n f(x_i, \theta)$.

Zápis $L(\theta, \mathbf{x})$ neindikuje závislosť na \mathbf{x} , a preto sa často používa zápis $L(\theta|\mathbf{x})$; podobné platí aj pre hustotu, t.j. často sa používa $f(x_i|\theta)$. Tiež je jedno, či píšeme c alebo $c(\mathbf{x})$, keďže vierohodnosť je funkciou θ . V skutočnosti $L(\theta|\mathbf{x})$ definuje triedu funkcií, ktorej prvky sa odlišujú vďaka multiplikatívnej konštantе c . Z vyššie uvedenej definície vyplýva, že dva body asociované s proporcionálnymi hustotami determinujú rovnakú vierohodnosť, t.j. ich vierohodnosti sú ekvivalentné. Vierohodnosť ale nie

je pravdepodobnosťou. Vierohodnosť je nezáporná a vo väčšine prípadov pozitívna pre všetky θ , preto môžeme definovať **prirodzený logarimus funkcie vierohodnosti** ako (Brazzale a kol., 2007)

$$\ln(L(\theta|\mathbf{x})) = l(\theta|\mathbf{x}) = \ln c + \ln(f(\mathbf{x}|\theta)),$$

kde $l(\theta|\mathbf{x}) = -\infty$ ak $L(\theta|\mathbf{x}) = 0$. V zmysle c ide teda o triedu funkcií.

Definícia 19 (slabý princíp vierohodnosti) Pre štatistický model $\mathcal{F} = \{f(\cdot; \theta) : \theta \in \Theta\}$ dva body $x_1, x_2 \in \mathbb{R}$, kde platí $L(\theta, x_1) \approx L(\theta, x_2)$, musia viesť k rovnakému záveru (inferenčnému záveru).

Z definície 19 vyplýva, že všetka informácia o θ je obsiahnutá vo funkcii vierohodnosti pre realizácie x (z nejakého experimentu). Dve funkcie vierohodnosti parametra θ obsahujú rovnakú informáciu o θ , ak sú proporcionálne pre nejaké x (z rovnakých alebo rozdielnych experimentov).

Definícia 20 (silný princíp vierohodnosti) Majme x_1 z modelu $\mathcal{F}_1 = \{f_1(\cdot; \theta) : \theta \in \Theta\}$ a x_2 z modelu $\mathcal{F}_2 = \{f_2(\cdot; \theta) : \theta \in \Theta\}$, kde $L_1(\theta, x_1) \approx L_2(\theta, x_2)$. Potom body $x_1, x_2 \in \mathbb{R}$ musia viesť k rovnakému záveru (inferenčnému záveru).

Príklad 94 (princípy vierohodnosti) Majme binomické rozdelenie (N je fixované a náhodná premenná je počet úspechov) a negatívne binomického rozdelenia (počet úspechov je fixovaný vopred a náhodná premenná je počet zlyhaní pozorovaný pred zastavením sekvencie pokusov). Ak x_1 je počet úspechov a x_2 počet neúspechov a θ pravdepodobnosť úspechu, potom (Azzalini, 1996)

$$L_1(\theta|x_1, x_2) = \binom{N}{x_1} \theta^{x_1} (1 - \theta)^{x_2}, x_1 = 1, 2, \dots, N; x_2 = N - x_1,$$

a

$$L_2(\theta|x_1, x_2) = \binom{x_1 + x_2 - 1}{x_1} \theta^{x_1} (1 - \theta)^{x_2}; x_1 = 1, 2, \dots; x_2 = 1, 2, \dots,$$

kde jadro funkcie vierohodnosti pre oba prípady bude rovné $L_1(\theta|x_1, x_2) = L_2(\theta|x_1, x_2) = \theta^{x_1} (1 - \theta)^{x_2}$.

Časť funkcie vierohodnosti zahŕňajúca parameter sa nazýva **jadro (kernel)**. Keďže maximalizácia funkcie je vo vzťahu k parametru, zvyšok (nejaká konštanta) nezávislý na parametri je pri maximalizácii nepotrebný. Jadro funkcie vierohodnosti je často značené rovnako ako samotná funkcia vierohodnosti (ku ktorej je proporcionálne).

Štatistická teória je kompromis rôznych logicky korektných požiadaviek použitých v kombinácii smerujúci k praktickým potrebám. V praxi slabý princíp vierohodnosti platí takmer vždy, ale silný princíp vierohodnosti iba niekedy (Cox a Donnelly, 2011).

Definícia 21 (maximálne vierohodný odhad) Maximálne vierohodný odhad parametra θ , ozn. $\hat{\theta}_{ML} = \hat{\theta}$ (ozn. ML často neuvádzame a nahrádzame ho slovným spojením „MLE θ je rovné $\hat{\theta}$ “ alebo skrátene „MLE $\hat{\theta}$ “) je taká hodnota parametra θ , ktorá maximalizuje funkciu vierohodnosti $L(\theta|x)$; pozri Cox (2006); Lehmann a Casella (1998).

Ak $X \sim N(\mu, \sigma^2)$, potom maximálne vierohodnými odhadmi parametrov μ a σ^2 sú $\hat{\mu} = \bar{x}$ a $\hat{\sigma}^2 = \frac{(n-1)}{n} s^2$. Ak $X \sim \text{Bin}(N, p)$, potom maximálne vierohodný odhad p je $\hat{p} = x/N$.

Definícia 22 (funkcia vierohodnosti binomického rozdelenia a jej jadro) Nech X je náhodná premenná, ktorá má binomické rozdelenie s parametrami N a p , t.j. $X \sim \text{Bin}(N, p)$. Realizácia X je $x = n$. Potom jadro funkcie vierohodnosti má tvar $L(p|x) = p^x (1 - p)^{N-x}$ a jeho logarimus je rovný $l(p|x) = x \ln p + (N - x) \ln (1 - p)$; pozri Bickel a Doksum (2006). Binomický koeficient, kombinačné číslo $\binom{N}{x}$, nepíšeme, lebo ho pri maximalizácii nepotrebujeme.

Definícia 23 (funkcia vierohodnosti multinomického rozdelenia a jej jadro) Nech \mathbf{X} je náhodná premenná, ktorá má (J -rozmerné) multinomické rozdelenie s parametrami N a \mathbf{p} , t.j. $\mathbf{X} \sim \text{Mult}_J(N, \mathbf{p})$, kde $\mathbf{X} = (X_1, X_2, \dots, X_J)^T$. Realizácia X_j je $x_j = n_j$. Funkcia vierohodnosti je proporcionálna ku jadru vierohodnosti $L(\mathbf{p}|\mathbf{x}) = \prod_{j=1}^J p_j^{x_j}$ a jej logaritmus $l(\mathbf{p}|\mathbf{x}) = \sum_{j=1}^J x_j \ln p_j$ (Casella a Berger, 2002). Konštantu $N! / \prod_j x_j!$ nepíšeme, lebo ju pri maximalizácii nepotrebujeme.

Definícia 24 (funkcia vierohodnosti Poissonovho rozdelenia a jej jadro) Nech X je náhodná premenná, ktorá má Poissonovo rozdelenie s parametrom λ , t.j. $X \sim \text{Poiss}(\lambda)$. Potom jadro vierohodnosti (Casella a Berger, 2002)

$$L(\lambda|\mathbf{x}) = \lambda^{\sum_{i=1}^N x_i} e^{-N\lambda},$$

a jeho logaritmus $l(\lambda|\mathbf{x}) = \sum_{i=1}^N x_i \ln \lambda - N\lambda$. Menovateľ funkcie vierohodnosti $x_1!x_2!\dots x_N!$ nepíšeme, lebo ho pri maximalizácii nepotrebujeme.

Príklad 95 (maximálne vierohodné odhady; Poissonovo rozdelenie) Každý rok za posledných päť rokov boli v nejakom meste registrované 3, 2, 5, 0 a 4 zemetrasenia za rok. Za predpokladu, že počet zemetrasení za rok X má Poissonovo rozdelenie s parametrom λ , t.j. $X \sim \text{Poiss}(\lambda)$, odhadnite λ (a predstavuje očakávanú početnosť zemetrasení za rok).

Riešenie

Logaritmus funkcie vierohodnosti $l(\lambda|\mathbf{x}) = \sum_{i=1}^N x_i \ln \lambda - N\lambda$, potom $\frac{\partial l(\lambda|\mathbf{x})}{\partial \lambda} = \frac{N\bar{x}}{\lambda} - N$, z čoho vyplýva, že $\hat{\lambda} = \bar{x}$. Teda ak $N = 5$, vieme vypočítať $\hat{\lambda} = \frac{\sum x_i}{N} = \bar{x}$, ktorý je rovný 2.8.

Vo všeobecnosti píšeme funkciu vierohodnosti pre Poissonove rozdelenie s parametrom λ a pozorovanými početnosťami m_n ako $L(\lambda|\mathbf{x}) = \prod_n p_n^{m_n}$, kde $p_n = \Pr(X = n) = e^{-\lambda} \lambda^n / n!$ a logaritmus jadra funkcie vierohodnosti ako $l(\lambda|\mathbf{x}) = -\lambda \sum_n m_n + \sum_n m_n \ln \lambda$. Maximálne vierohodný odhad $\hat{\lambda} = \frac{\sum_n n m_n}{\sum_n m_n}$.

Maximálne vierohodný odhad zjednodušuje pohľad na funkciu vierohodnosti, pretože číslo predstavujúce odhad je jednoduchšie ako funkcia. Všeobecne však jedno číslo (odhad parametra) nie je postačujúce na to, aby reprezentovalo funkciu vierohodnosti. Ak je funkcia vierohodnosti dobre **aproximovaná nejakou kvadratickou funkciou**, potom potrebujeme na jej opis najmenej dve charakteristiky – **polohu maxima a zakrivenie v maxime**. Presnejšie potrebujeme aproximáciu logaritmu funkcie vierohodnosti **okolo maximálne vierohodného odhadu θ polohy maxima** nejakou kvadratickou funkciou. V tomto prípade nazývame funkciu vierohodnosti **regulárnou**. Prvú deriváciu logaritmu funkcie vierohodnosti nazývame **skóre funkcia** a označujeme ju ako $S(\theta) = \frac{\partial}{\partial \theta} l(\theta|\mathbf{x})$. Z tejto rovnosti je zrejmé, že maximálne vierohodný odhad $\hat{\theta}$ je riešením **vierohodnostných (skóre) rovníc** $S(\theta) = 0$. V maxime je druhá derivácia logaritmu funkcie vierohodnosti záporná a zakrivenie v bode $\hat{\theta}$ bude rovné **Fisherovej miere informácie** $\mathcal{I}(\hat{\theta})$, kde $\mathcal{I}(\hat{\theta}) = -\frac{\partial^2}{\partial \theta^2} l(\theta|\mathbf{x})|_{\theta=\hat{\theta}}$. Veľké zakrivenie zodpovedá strmému a úzkemu vrcholu, čo indikuje menšiu neistotu o θ . $\mathcal{I}(\hat{\theta})$ nazývame **pozorovaná Fisherova miera informácie**. **Maximálne vierohodný odhad rozptylu** odhadu parametra θ potom môžeme definovať ako $\widehat{\text{Var}}[\hat{\theta}] = 1/\mathcal{I}(\hat{\theta})$. **Očakávaná Fisherova miera informácie** je definovaná ako $I(\theta) = E[S^2(\theta)] = \text{Var}[S(\theta)] = -E[\frac{\partial}{\partial \theta} S(\theta)]$. Keďže $X_i, i = 1, 2, \dots, n$, sú nezávislé, potom platí $I(\theta) = ni(\theta)$, kde $i(\theta)$ je Fisherova miera informácie jedného pozorovania.

Príklad 96 ($\mathcal{I}(\hat{p})$ a rozptyl pre p ; $X \sim \text{Bin}(N, p)$) Z funkcie vierohodnosti odvoďte pozorovanú Fisherovu mieru informácie $\mathcal{I}(\hat{p})$ a rozptyl $\widehat{\text{Var}}[\hat{p}]$.

Riešenie

$l(p|x) = x \ln p + (N - x) \ln(1 - p) = N\hat{p} \ln p + N(1 - \hat{p}) \ln(1 - p)$, potom

$$\frac{\partial^2}{\partial p^2} l(p|x) = -(N\hat{p})/p^2 - N(1 - \hat{p})/(1 - p)^2.$$

Ak dosadíme $p = \hat{p}$, dostaneme

$$\begin{aligned} \frac{\partial^2}{\partial p^2} l(p|x)|_{p=\hat{p}} &= -(N\hat{p})/\hat{p}^2 - N(1 - \hat{p})/(1 - \hat{p})^2 = [-N(1 - \hat{p}) - N\hat{p}]/[\hat{p}(1 - \hat{p})] \\ &= -N/[\hat{p}(1 - \hat{p})], \end{aligned}$$

z čoho vyplýva, že

$$\frac{1}{\mathcal{I}(\hat{p})} = \widehat{\text{Var}}[\hat{p}] = \frac{\hat{p}(1-\hat{p})}{N}.$$

Príklad 97 ($\mathcal{I}(\hat{\lambda})$ a rozptyl pre λ ; $X \sim \text{Poiss}(\lambda)$) Každý rok za posledných päť rokov boli v nejakej meste registrované 3, 2, 5, 0 a 4 zemetrasenia za rok. Za predpokladu, že počet zemetrasení za rok $X \sim \text{Poiss}(\lambda)$, odhadnite rozptyl parametra λ a vypočítajte hodnotu tohoto odhadu rozptylu pre počet zemetrasení.

Riešenie

$\frac{\partial^2}{\partial \lambda^2} l(\lambda|\mathbf{x}) = -\frac{N\bar{x}}{\lambda^2}$, z čoho po dosadení $\lambda = \hat{\lambda}$ dostaneme $\frac{1}{\mathcal{I}(\hat{\lambda})} = \widehat{\text{Var}}[\hat{\lambda}] = \frac{\bar{x}}{N}$, ktorý je rovný 0.56.

Ako vhodný spôsob aproximácie logaritmu funkcie vierohodnosti $l(\theta|\mathbf{x})$ a $l(\theta|\mathbf{x})$ a nejakej funkcie $g(\theta)$ a $g(\theta)$, sa javí jednorozmerný a mnohorozmerný **Taylorov rozvoj r -tého rádu**. Táto aproximácia je dostatočne dobrá z hľadiska konvergenzie ku funkcii, ktorú aproximujeme.

Definícia 25 (Taylorov rozvoj r -tého rádu) Ak existujú r -té derivácie funkcie $g(x)$, ozn. $g^{(r)}(x) = \frac{\partial^r}{\partial x^r} g(x)$, potom definujeme Taylorov rozvoj r -tého rádu pre nejakú konštantu a nasledovne (Casella a Berger, 2002)

$$T_r(x) = \sum_{j=0}^r \frac{g^{(j)}(a)}{j!} (x-a)^j.$$

Pri praktických aplikáciách budeme predpokladať, že zvyšok $g(x) - T_r(x)$ bude rýchlo konvergovať k nule (pozri nasledujúcu vetu). Explicitná forma zvyšku nebude dôležitá a budeme ho zanedbávať, pretože nás bude zaujímať iba samotná aproximácia. Jedna z možných podôb zvyšku je nasledovná

$$g(x) - T_r(x) = \int_a^x \frac{g^{(r+1)}(t)}{r!} (x-t)^r dt.$$

Veta 5 (Taylorova veta) Ak derivácia $g^{(r)}(a) = \frac{\partial^r}{\partial x^r} g(x)|_{x=a}$ existuje, potom (Casella a Berger, 2002)

$$\lim_{x \rightarrow a} \frac{g(x) - T_r(x)}{(x-a)^r} = 0.$$

V štatistických aplikáciách Taylorovej vety budeme používať Taylorov rozvoj prvého alebo druhého rádu. Rovnako budeme používať aj mnohorozmerné rozšírenie Taylorovej vety.

Majme **kvadratickú aproximáciu logaritmu funkcie vierohodnosti** pomocou Taylorovho rozvoja druhého rádu okolo $\hat{\theta}$ definovanú ako

$$l(\theta|\mathbf{x}) \approx l(\hat{\theta}|\mathbf{x}) + S(\hat{\theta})(\theta - \hat{\theta}) - \frac{1}{2} \mathcal{I}(\hat{\theta})(\theta - \hat{\theta})^2,$$

z ktorej dostaneme **aproximáciu logaritmu relatívnej (štandardizovanej) funkcie vierohodnosti**

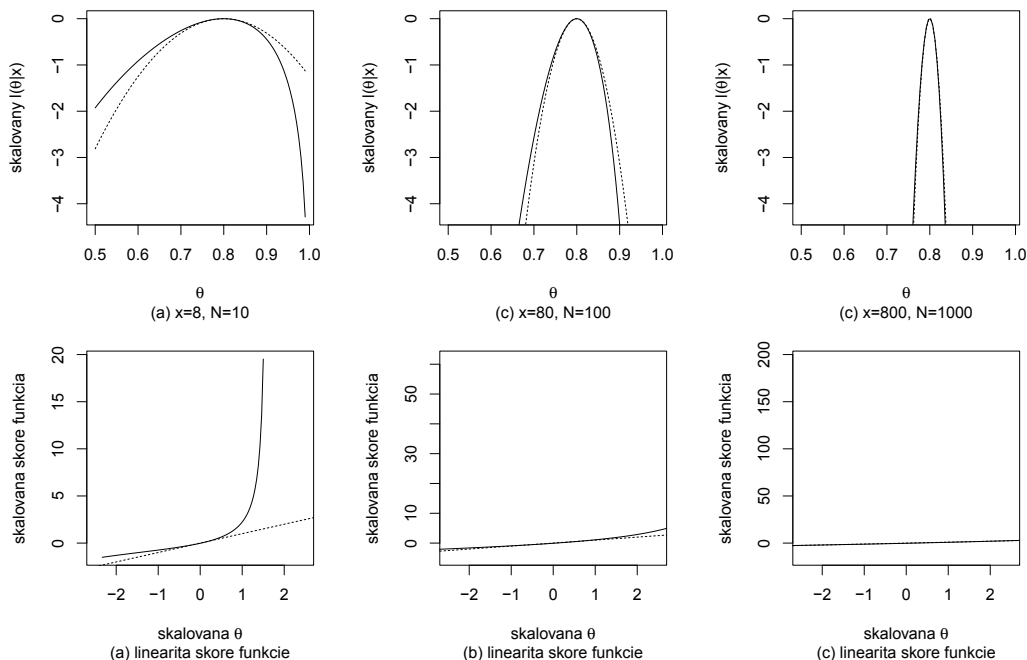
$$\ln \mathcal{L}(\theta|\mathbf{x}) = \ln \frac{L(\theta|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})} = l(\theta|\mathbf{x}) - l(\hat{\theta}|\mathbf{x}) \approx -\frac{1}{2} \mathcal{I}(\hat{\theta})(\theta - \hat{\theta})^2.$$

Posledná rovnosť predstavuje kvadratickú aproximáciu normalizovaného logaritmu funkcie vierohodnosti okolo $\hat{\theta}$. Na porovnanie skutočnej funkcie vierohodnosti a jej kvadratickej aproximácie tieto dve funkcie nakreslíme do jedného obrázka. Pri zobrazovaní fixujeme maximum logaritmu funkcie vierohodnosti do nuly a rozsah stanovíme od -4 do 0 .

Praktické pravidlo – dostatočne regulárna funkcia vierohodnosti indikuje normalitu X . Alternatívne môžeme zobrať deriváciu kvadratickej aproximácie, kde dostaneme $S(\theta) \approx -\mathcal{I}(\hat{\theta})(\theta - \hat{\theta})$ alebo $-\mathcal{I}^{-1/2}(\hat{\theta})$

$S(\theta) \approx \mathcal{I}^{1/2}(\hat{\theta})(\theta - \hat{\theta})$. Posledná rovnosť nie je závislá na mierke θ . Potom kvadratickú aproximáciu môžeme preveriť graficky zobrazením $-\mathcal{I}^{-1/2}(\hat{\theta})S(\theta)$ oproti $\mathcal{I}^{1/2}(\hat{\theta})(\theta - \hat{\theta})$. Za platnosti kvadratickej aproximácie je grafom priamka s jednotkovým sklonom. Pre normálne rozdelené dáta to musí platiť presne. Keďže každá funkcia je lokálne lineárna, je potrebné preveriť, na akom intervale linearitu očakávame. V ideálnom prípade $\mathcal{I}^{1/2}(\hat{\theta})(\theta - \hat{\theta}) \sim N(0, 1)$, preto kontrolu urobíme aspoň na intervale $\langle -2, 2 \rangle$.

Príklad 98 (kvadratická aproximácia funkcie vierohodnosti) (1) Nakreslite škálovaný logaritmus funkcie vierohodnosti binomického rozdelenia. Na osi x bude p a na osi y $\ln \mathcal{L}(p|\mathbf{x}) = l(p|\mathbf{x}) - \max(l(p|\mathbf{x}))$. Porovnajte $\ln \mathcal{L}(p|\mathbf{x})$ s kvadratickou aproximáciou vypočítanou pomocou Taylorovho rozvoja $\ln \mathcal{L}(p|\mathbf{x}) = \ln\left(\frac{L(p|\mathbf{x})}{L(\hat{p}|\mathbf{x})}\right) \approx -\frac{1}{2}\mathcal{I}(\hat{p})(p - \hat{p})^2$. (2) Nech skóre funkcia $S(p) = \frac{\partial}{\partial p} \ln L(p|\mathbf{x})$. Keď zoberieme deriváciu kvadratickej aproximácie uvedenej vyššie, dostaneme $S(p) \approx -\mathcal{I}(\hat{p})(p - \hat{p})$ alebo $-\mathcal{I}^{-1/2}(\hat{p})S(p) \approx \mathcal{I}^{1/2}(\hat{p})(p - \hat{p})$. Potom zobrazením pravej strany na osi x a ľavej strany na osi y dostaneme asymptoticky lineárnu funkciu s jednotkovým sklonom. Asymptoticky tiež platí $\mathcal{I}^{1/2}(X/N)(p - X/N) \stackrel{\mathcal{D}}{\sim} N(0, 1)$. Je postačujúce mať rozsah osi x rovný $\langle -2, 2 \rangle$, pretože funkcia je asymptoticky (lokálne) lineárna na tomto intervale. Rozumne škáľujte os y . Zobrazte pre (a) $n = 8, N = 10$, (b) $n = 80, N = 100$ a (c) $n = 800, N = 1000$ ($p \in (0.5, 0.99)$). Okomentujte rozdiely medzi (a), (b) a (c). Grafické riešenie je na obrázku 2.16.



Obr. 2.16: Porovnanie škálovaného logaritmu funkcie vierohodnosti (plná čiara) s jeho kvadratickou aproximáciou (čiarkovaná čiara) v prvom riadku a porovnanie škálovanovej skóre funkcie a priamky s nulovým interceptom a jednotkovým sklonom v druhom riadku

Ak je funkcia vierohodnosti viacrozmerná, je problém ju zobrazit'. Ak je θ dvojrozmerný vektor, potom môžeme $L(\theta|\mathbf{x})$ zobrazit' ako kontúrový graf alebo perspektívny trojrozmerný graf v podobe plochy. Nech $\theta = (\theta_1, \theta_2, \dots, \theta_k)^T$. Za predpokladu diferencovateľnosti $L(\theta|\mathbf{x})$ je **skóre funkcia** definovaná ako vektor $S(\theta)$, ktorého jednotlivé členy $S(\theta) = \frac{\partial}{\partial \theta_i} l(\theta|\mathbf{x}), i = 1, 2, \dots, k$, a maximálne vierohodný odhad θ_i je riešením vierohodnostných rovníc $S(\theta) = 0$. **Pozorovaná Fisherova informačná matica** druhých derivácií $l(\theta|\mathbf{x})$ má tvar $\mathcal{I}_{ij}(\hat{\theta})$ je rovný $-\frac{\partial^2}{\partial \theta_i \partial \theta_j} l(\theta|\mathbf{x})|_{\theta=\hat{\theta}}$. Maximálne vierohodný

odhad kovariančnej matice $\widehat{Var}[\widehat{\boldsymbol{\theta}}] = \mathcal{I}^{-1}(\widehat{\boldsymbol{\theta}})$, t.j. odhad kovariančnej matice $\widehat{Var}[\widehat{\boldsymbol{\theta}}]$ je rovný inverzii pozorovanej Fisherovej informačnej matice $\mathcal{I}(\widehat{\boldsymbol{\theta}})$. **Očakávaná Fisherova informačná matica** je definovaná ako $I(\boldsymbol{\theta}) = E[S(\boldsymbol{\theta})(S(\boldsymbol{\theta}))^T] = Var[S(\boldsymbol{\theta})] = -E[\frac{\partial}{\partial \boldsymbol{\theta}} S(\boldsymbol{\theta})]$. Keďže $X_i, i = 1, 2, \dots, n$, sú nezávislé, potom platí $I(\boldsymbol{\theta}) = ni(\boldsymbol{\theta})$, kde $i(\boldsymbol{\theta})$ je Fisherova miera informácie jedného pozorovania.

Kvadratická aproximácia logaritmu funkcie vierohodnosti pomocou Taylorovho rozvoja druhého rádu okolo $\widehat{\boldsymbol{\theta}}$ je definovaná ako

$$l(\boldsymbol{\theta}|\mathbf{x}) \approx l(\widehat{\boldsymbol{\theta}}|\mathbf{x}) + S(\widehat{\boldsymbol{\theta}})(\boldsymbol{\theta} - \widehat{\boldsymbol{\theta}}) - \frac{1}{2}(\boldsymbol{\theta} - \widehat{\boldsymbol{\theta}})^T \mathcal{I}(\widehat{\boldsymbol{\theta}})(\boldsymbol{\theta} - \widehat{\boldsymbol{\theta}}).$$

Pre normálne rozdelené X platí

$$\ln \mathcal{L}(\boldsymbol{\theta}|\mathbf{x}) = \ln \frac{L(\boldsymbol{\theta}|\mathbf{x})}{L(\widehat{\boldsymbol{\theta}}|\mathbf{x})} = l(\boldsymbol{\theta}|\mathbf{x}) - l(\widehat{\boldsymbol{\theta}}|\mathbf{x}) \approx -\frac{1}{2}(\boldsymbol{\theta} - \widehat{\boldsymbol{\theta}})^T \mathcal{I}(\widehat{\boldsymbol{\theta}})(\boldsymbol{\theta} - \widehat{\boldsymbol{\theta}}),$$

t.j. funkcia vierohodnosti a jej kvadratická aproximácia sú identické.

Definícia 26 (funkcia vierohodnosti normálneho rozdelenia) *Nech X_1, X_2, \dots, X_n sú nezávislé rovnako rozdelené premenné, $X_i \sim N(\mu, \sigma^2)$, kde $i = 1, 2, \dots, n$, $\boldsymbol{\theta} = (\mu, \sigma^2)^T \in \Theta = \mathbb{R} \times \mathbb{R}^+$. Vďaka nezávislosti X_i dostaneme*

$$\begin{aligned} L(\boldsymbol{\theta}|\mathbf{x}) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2}\left(\frac{x_i - \mu}{\sigma}\right)^2\right) \\ &= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2}\left(\sum_{i=1}^n x_i^2 - 2\mu \sum_{i=1}^n x_i + n\mu^2\right)\right) \end{aligned}$$

a korešpondujúci logaritmus

$$l(\boldsymbol{\theta}|\mathbf{x}) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i^2 - 2\mu \sum_{i=1}^n x_i + n\mu^2\right).$$

Príklad 99 ($\mathcal{I}(\widehat{\boldsymbol{\theta}})$ pre vektor $\boldsymbol{\theta} = (\mu, \sigma^2)^T$; $X_i \sim N(\mu, \sigma^2)$) *Nech $X_i \sim N(\mu, \sigma^2)$, kde $i = 1, 2, \dots, n$. Čomu je rovná pozorovaná Fisherova informačná matica $\mathcal{I}(\widehat{\boldsymbol{\theta}})$, kde $\widehat{\boldsymbol{\theta}} = (\widehat{\mu}, \widehat{\sigma}^2)^T$?*

Riešenie

Logaritmus funkcie vierohodnosti má tvar

$$l(\boldsymbol{\theta}|\mathbf{x}) = -\frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2.$$

Derivácie funkcie vierohodnosti v μ a σ^2 budú nasledovné

$$\begin{aligned} S_1(\boldsymbol{\theta}) &= \frac{\partial}{\partial \mu} l(\boldsymbol{\theta}|\mathbf{x}) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu), \\ S_2(\boldsymbol{\theta}) &= \frac{\partial}{\partial \sigma^2} l(\boldsymbol{\theta}|\mathbf{x}) = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2. \end{aligned}$$

Potom

$$\mathcal{I}(\widehat{\boldsymbol{\theta}}) = \begin{pmatrix} \frac{n}{\widehat{\sigma}^2} & 0 \\ 0 & \frac{n}{2\widehat{\sigma}^4} \end{pmatrix}.$$

Príklad 100 ($\mathcal{I}(\widehat{\mathbf{p}})$ a rozptyl pre \mathbf{p} ; $\mathbf{X} \sim \text{Mult}_J(N, \mathbf{p})$) *Z funkcie vierohodnosti odvod'ite pozorovanú Fisherovu informačnú maticu $\mathcal{I}(\widehat{\mathbf{p}})$ a kovariančnú maticu $\widehat{Var}[\widehat{\mathbf{p}}]$.*

Riešenie

Označme $p_J = 1 - \sum_{j=1}^{J-1} p_j$ a predefinujme J -rozmerný vektor \mathbf{p} na $(J-1)$ -rozmerný vektor $\mathbf{p} = (p_1, p_2, \dots, p_{J-1})^T$. Potom $l(\mathbf{p}|\mathbf{x}) = \sum_{j=1}^{J-1} n_j \ln p_j + n_J \ln(1 - \sum_{j=1}^{J-1} p_j)$ a $\frac{\partial}{\partial p_j} l(\mathbf{p}|\mathbf{x}) = \frac{n_j}{p_j} - \frac{n_J}{p_J}$, ktoré tvoria $S(\mathbf{p})$. Fisherovu informačnú maticu dostaneme nasledovne

$$\mathcal{I}(\mathbf{p}) = -\frac{\partial}{\partial \mathbf{p}} S(\mathbf{p}) = \text{diag} \left(\frac{n_1}{p_1^2}, \frac{n_2}{p_2^2}, \dots, \frac{n_{J-1}}{p_{J-1}^2} \right) + \frac{n_J}{p_J^2} \mathbf{1}\mathbf{1}^T,$$

kde $\mathbf{1}$ je $(J-1)$ -rozmerný vektor jednotiek. Potom pozorovaná Fisherova informačná matica bude rovná

$$\mathcal{I}(\hat{\mathbf{p}}) = N \left(\text{diag} \left(\frac{1}{\hat{p}_1}, \frac{1}{\hat{p}_2}, \dots, \frac{1}{\hat{p}_{J-1}} \right) + \frac{\mathbf{1}\mathbf{1}^T}{\hat{p}_J} \right) = N \begin{pmatrix} \frac{1}{\hat{p}_1} + \frac{1}{\hat{p}_J} & \frac{1}{\hat{p}_J} & \frac{1}{\hat{p}_J} & \dots & \frac{1}{\hat{p}_J} \\ \frac{1}{\hat{p}_J} & \frac{1}{\hat{p}_2} + \frac{1}{\hat{p}_J} & \frac{1}{\hat{p}_J} & \dots & \frac{1}{\hat{p}_J} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{1}{\hat{p}_J} & \frac{1}{\hat{p}_J} & \dots & \frac{1}{\hat{p}_J} & \frac{1}{\hat{p}_{J-1}} + \frac{1}{\hat{p}_J} \end{pmatrix}$$

a

$$\widehat{\text{Var}}[\hat{\mathbf{p}}] = \mathcal{I}^{-1}(\hat{\mathbf{p}}) = \frac{1}{N} (\text{diag}(\hat{\mathbf{p}}) - \hat{\mathbf{p}}\hat{\mathbf{p}}^T) = \frac{1}{N} \begin{pmatrix} \hat{p}_1(1-\hat{p}_1) & -\hat{p}_1\hat{p}_2 & \dots & -\hat{p}_1\hat{p}_{J-1} \\ -\hat{p}_2\hat{p}_1 & \hat{p}_2(1-\hat{p}_2) & \dots & -\hat{p}_2\hat{p}_{J-1} \\ \vdots & \vdots & \vdots & \vdots \\ -\hat{p}_{J-1}\hat{p}_1 & -\hat{p}_{J-1}\hat{p}_2 & \dots & \hat{p}_{J-1}(1-\hat{p}_{J-1}) \end{pmatrix}.$$

Ak do $\widehat{\text{Var}}[\hat{\mathbf{p}}]$ pridáme jeden riadok a jeden stĺpec zodpovedajúce \hat{p}_J , dostaneme singulárnu kovariančnú maticu J -rozmerného vektora $\hat{\mathbf{p}}$.

Profilová vierohodnosť. Aj napriek tomu, že funkcia vierohodnosti je často viacrozmerná, je jednoduchšie ju zobrazovať pre každý parameter θ_i zvlášť alebo pre nejakú podmnožinu parametrov vektora $\boldsymbol{\theta}$. Napr. pri modeli normálneho rozdelenia nás zaujíma len stredná hodnota μ , pričom rozptyl σ^2 je tzv. rušivý parameter (potrebný kvôli adaptácii modelu na variabilitu v dátach). Potrebujeme teda metódu, ktorá koncentruje vierohodnosť len na parameter záujmu eliminovaním rušivého parametra. Vierohodnostný prístup na elimináciu rušivého parametra pozostáva zo substitúcie jeho maximálne vierohodným odhadom v každej fixovanej hodnote parametra záujmu. Výsledkom je **profilová vierohodnostná funkcia**.

Zakrivenie profilovej vierohodnosti. Zakrivenie profilovej funkcie vierohodnosti súvisí s Fisherovou informačnou maticou. Ak napr. parametrom záujmu je θ_1 z vektora $\boldsymbol{\theta} = (\theta_1, \theta_2)^T$, potrebujeme $\mathcal{I}(\hat{\boldsymbol{\theta}})$ a jej inverziu $\mathcal{I}^{-1}(\hat{\boldsymbol{\theta}})$ v nasledovnom tvare

$$\mathcal{I}(\hat{\boldsymbol{\theta}}) = \begin{pmatrix} I_{11} & I_{12} \\ I_{21} & I_{22} \end{pmatrix}, \mathcal{I}^{-1}(\hat{\boldsymbol{\theta}}) = \begin{pmatrix} I^{11} & I^{12} \\ I^{21} & I^{22} \end{pmatrix}.$$

Potom zakrivenie profilovej funkcie vierohodnosti v $\hat{\theta}_1$ nie je I_{11} ale $(I^{11})^{-1}$, kde $(I^{11})^{-1}$ je vo všeobecnosti menšie ako I_{11} . Interpretácia je nasledovná – informačné číslo I_{11} je zakrivením profilovej funkcie vierohodnosti v θ_1 , kde o θ_2 sa predpokladá, že je známe v pozorovanom odhade $\hat{\theta}_2$; avšak $(I^{11})^{-1}$ je zakrivením profilovej funkcie vierohodnosti v θ_1 , ktoré berie do úvahy, že θ_2 je neznáme. Z toho je potom zrejmé, že $(I^{11})^{-1}$ je menšie ako I_{11} . Na základe vyššie uvedeného môžeme kvadraticky aproximovať logaritmus profilovej funkcie vierohodnosti použitím $\hat{\theta}_i$ a $(I^{ii})^{-1}$, kde

$$\mathcal{L}(\theta_i|\mathbf{x}) = \ln \frac{L(\theta_i|\mathbf{x})}{L(\hat{\theta}_i|\mathbf{x})} = l(\theta_i|\mathbf{x}) - l(\hat{\theta}_i|\mathbf{x}) \approx -\frac{1}{2}(I^{ii})^{-1}(\theta_i - \hat{\theta}_i)^2.$$

Podobným spôsobom je možné kvadraticky aproximovať aj plochu vierohodnosti.

Invariantnosť maximálne vierohodného odhadu. Invariantnosť maximálne vierohodného odhadu znamená, že ak $\hat{\theta}$ je maximálne vierohodný odhad θ (t.j. $\hat{\theta} = \hat{\theta}_{ML}$) a $g(\theta)$ je funkciou θ , potom $g(\hat{\theta})$ je tiež maximálne vierohodný odhad $g(\theta)$. Maximálne vierohodný odhad rozptylu $g(\theta)$ potom môžeme definovať ako $\widehat{Var}[g(\hat{\theta})] = [\frac{\partial}{\partial \theta} g(\theta)|_{\theta=\hat{\theta}}]^2 / \mathcal{I}(\hat{\theta})$. V prípade vektora θ je $\widehat{Var}[\mathbf{g}(\hat{\theta})] = \Delta^T \mathcal{I}^{-1}(\hat{\theta}) \Delta$, kde $\Delta = \frac{\partial}{\partial \theta} \mathbf{g}(\theta)|_{\theta=\hat{\theta}}$. Tento vzorec vychádza z **delta metódy**, ktorá je postavená na Taylorovom rozvoji prvého rádu (t.j. jeho lineárnej zložky) okolo bodu $\hat{\theta} = \theta$, kde

$$\mathbf{g}(\hat{\theta}) \approx \mathbf{g}(\theta) + \sum_{i=1}^k \left(\frac{\partial}{\partial \theta_i} \mathbf{g}(\theta) \Big|_{\theta=\hat{\theta}} \right) (\hat{\theta}_i - \theta_i) = \mathbf{g}(\theta) + \Delta^T (\hat{\theta} - \theta),$$

potom

$$\widehat{Var}[\mathbf{g}(\hat{\theta})] \approx \sum_{i=1}^k \left(\frac{\partial}{\partial \theta_i} \mathbf{g}(\theta) \Big|_{\theta=\hat{\theta}} \right)^2 \hat{\sigma}_i^2 + 2 \sum_{i=1}^{k-1} \sum_{j=i+1}^k \left(\frac{\partial}{\partial \theta_i} \mathbf{g}(\theta) \Big|_{\theta=\hat{\theta}} \right) \left(\frac{\partial}{\partial \theta_j} \mathbf{g}(\theta) \Big|_{\theta=\hat{\theta}} \right) \hat{\sigma}_{ij} = \Delta^T \widehat{\Sigma} \Delta,$$

kde $\widehat{\Sigma} = \widehat{Var}[\hat{\theta}]$, $\hat{\sigma}_i^2 = \widehat{Var}[\hat{\theta}_i]$, $\hat{\sigma}_{ij} = \widehat{Cov}[\hat{\theta}_i, \hat{\theta}_j]$ a $i \neq j; i, j = 1, 2, \dots, k$. Δ je matica $k \times k_1$, kde derivovanie prebieha po zložkách, t.j. (i, j) -ty element Δ je rovný $\frac{\partial g_j(\theta)}{\partial \theta_i} \Big|_{\theta=\hat{\theta}}$, $\mathbf{g}(\theta) = (g_1(\theta), g_2(\theta), \dots, g_{k_1}(\theta))^T$, $i = 1, 2, \dots, k$; $j = 1, 2, \dots, k_1 \leq k$. V praxi sa často vyskytuje situácia $k \neq 1$ a $k_1 = 1$, napr. $\theta = (p_1, p_2)^T$ a $g(\theta) = \frac{p_1}{p_2}$. Ak $k = k_1 = 1$, potom

$$\widehat{Var}[g_1(\hat{\theta}_1)] = \widehat{Var}[g(\hat{\theta})] = \left(\frac{\partial}{\partial \theta} g(\theta) \Big|_{\theta=\hat{\theta}} \right)^2 \hat{\sigma}^2,$$

kde $\hat{\sigma}^2 = \widehat{Var}[\hat{\theta}]$.

Príklad 101 (profilová vierohodnosť; normálne rozdelenie) *Profilová funkcia vierohodnosti pre μ je rovná $L(\mu|\mathbf{x}) = c \exp(-n\hat{\sigma}_\mu^2/(2\hat{\sigma}^2))$, kde c je nejaká konštanta a $\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$, t.j. ide o rez $L((\mu, \sigma^2)^T|\mathbf{x})$ v bode $\sigma^2 = \hat{\sigma}^2$. Profilová funkcia vierohodnosti pre σ^2 je rovná $L(\sigma^2|\mathbf{x}) = c(\sigma^2)^{-n/2} \exp(-n\hat{\sigma}^2/(2\sigma^2))$, kde c je nejaká konštanta a $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$.*

Príklad 102 (kvadratická aproximácia profilovej funkcie vierohodnosti) (1) *Nakreslite škálovaný logaritmus profilovej funkcie vierohodnosti normálneho rozdelenia pre μ . Na osi x bude μ a na osi y $\ln L(\mu|\mathbf{x}) = l(\mu|\mathbf{x}) - \max(l(\mu|\mathbf{x}))$. Porovnajte $\ln L(\mu|\mathbf{x})$ s kvadratickou aproximáciou vypočítanou pomocou Taylorovho rozvoja $\ln L(\mu|\mathbf{x}) = \ln(\frac{L(\mu|\mathbf{x})}{L(\hat{\mu}|\mathbf{x})}) \approx -\frac{1}{2} \mathcal{I}(\hat{\mu})(\mu - \hat{\mu})^2$.* (2) *Nech skóre funkcia $S(\mu) = \frac{\partial}{\partial \mu} \ln L(\mu|\mathbf{x})$. Keď zoberieme deriváciu kvadratickej aproximácie uvedenej vyššie, dostaneme $S(\mu) \approx -\mathcal{I}(\hat{\mu})(\mu - \hat{\mu})$ alebo $-\mathcal{I}^{-1/2}(\hat{\mu})S(\mu) \approx \mathcal{I}^{1/2}(\hat{\mu})(\mu - \hat{\mu})$. Potom zobrazením pravej strany na osi x a ľavej strany na osi y dostaneme asymptoticky lineárnu funkciu s jednotkovým sklonom. Asymptoticky tiež platí $\mathcal{I}^{1/2}(\bar{X})(\mu - \bar{X}) \stackrel{\mathcal{D}}{\sim} N(0, 1)$. Je postačujúce mať rozsah osi x rovný $\langle -2, 2 \rangle$, pretože funkcia je asymptoticky (lokálne) lineárna na tomto intervale. Rozumne škáľujte os y . Zobrazte pre (a) $n = 10$, (b) $n = 100$ a (c) $n = 1000$. Použite (1) $X \sim N(0, 1)$ a (2) $X \sim (1-p)N(0, 1) + pN(0, 2)$, kde $p = 0.05$. Okomentujte rozdiely medzi (a), (b) a (c), ako aj rozdiely medzi (1) a (2).*

2.4 *Maximalizácia funkcie vierohodnosti

Maximálne vierohodný odhad $\hat{\theta}$ je možné vypočítať pomocou metód numerickej optimalizácie (pozri napr. Horová a Zelinka, 2008) aplikovaných na funkciu vierohodnosti $L(\theta|\mathbf{x})$ alebo jej logaritmus $l(\theta|\mathbf{x})$.

Newtonova (Newton-Raphsonova) metóda (metóda dotyčníc) je pomenovaná po Isaacovi Newtonovi (1643–1727) a Josephovi Raphsonovi (1648–1715). Majme kvadratickú aproximáciu logaritmu funkcie vierohodnosti pomocou Taylorovho rozvoja druhého rádu okolo nejakého bodu θ_0 definovanú ako

$$l(\theta|\mathbf{x}) \approx l(\theta_0|\mathbf{x}) + S(\theta_0)(\theta - \theta_0) - \frac{1}{2} \mathcal{I}(\theta_0)(\theta - \theta_0)^2$$

alebo lineárnu aproximáciu skóre funkcie pomocou Taylorovho rozvoja prvého rádu

$$S(\theta) \approx S(\theta_0) - \mathcal{I}(\theta_0)(\theta - \theta_0).$$

Z tejto aproximácie môžeme odvodiť nasledovnú iteračnú funkciu

$$\theta_0 + \frac{S(\theta_0)}{\mathcal{I}(\theta_0)}.$$

Postup je nasledovný:

1. inicializácia metódy použitím vhodne zvoleného štartovacieho parametra $\theta^{(0)}$, pre ktorý platí $\mathcal{I}(\theta^{(0)}) \neq 0$,
2. iterácia rovnosti

$$\theta^{(i)} = \theta^{(i-1)} + \frac{S(\theta^{(i-1)})}{\mathcal{I}(\theta^{(i-1)})},$$

kde $\mathcal{I}(\theta^{(i-1)}) \neq 0$, pre $i = 1, 2, \dots$, pokiaľ nebude $|l(\theta^{(i)}|\mathbf{x}) - l(\theta^{(i-1)}|\mathbf{x})| < \epsilon$, kde ϵ je vhodne zvolené malé číslo (prahová hodnota).

Newton-Raphsonova má jednoduchú geometrickú interpretáciu – bod $\theta^{(i)}$ je priesečník dotyčnice ku grafu skóre funkcie $S(\cdot)$ v bode $[\theta^{(i-1)}, S(\theta^{(i-1)})]$ s osou x . Táto metóda konverguje kvadraticky, t.j. počet správnych cifier odhadu sa v každom iteračnom kroku zdvojnásobí (rád metódy je rovný dvom). Konvergencia k lokálnemu extrému však nie je zaručená – metóda môže konvergovať k lokálnemu minimu alebo divergovať, ak začneme iterácie v $\theta^{(0)}$ z konvexnej časti $l(\theta|\mathbf{x})$. Aj keď je funkcia konkávná, konvergencia k lokálnemu maximumu nie je zaručená (metóda nerozlišuje lokálne maximum a minimum, pretože rieši rovnosť $S(\theta) = 0$). Ak je funkcia záujmu multimodálna, nemôžeme očakávať, že metóda bude konvergovať ku globálnemu extrému. Ak je $S(\theta)$ dvakrát diferencovateľná, prvá a druhá derivácia nemenia znamienko na intervale $\langle \theta_D, \theta_H \rangle$, funkcia $S(\theta)$ má jednoduchý koreň ($S'(\theta) \neq 0$ pre každé $\theta \in \langle \theta_D, \theta_H \rangle$) a štartovací bod $\theta^{(0)}$ je ten z krajných bodov θ_D, θ_H , v ktorom je znamienko $S(\cdot)$ rovnaké ako znamienko jej druhej derivácie na intervale $\langle \theta_D, \theta_H \rangle$, potom metóda konverguje.

Newton-Raphsonova metóda je implementovaná v \mathbb{R} vo funkcii `optimize(f, interval, maximum=FALSE, tol, ...)`, kde vstupným argumentom je buď funkcia vierohodnosti alebo jej logaritmus (`f`), štartovací interval (`interval`) a zvolená prahová hodnota (`tol`). Vo všeobecnosti nie je potrebné do funkcie pridávať argument obsahujúci prvú deriváciu funkcie záujmu, pretože je vypočítaná numericky. V prípade zadania argumentu `hessian=TRUE`, vo výsledkoch sa objaví aj $-\mathcal{I}(\hat{\theta})$.

Alternatívnymi, avšak pomalšími, metódami sú **metóda zlatého rezu** a **metóda sukcesívnej parabolickej interpolácie**. V prvej z nich, kde derivácia funkcie záujmu nie je potrebná, sa interval $\langle \theta_D^{(i-1)}, \theta_H^{(i-1)} \rangle$, v ktorom leží maximum $l(\theta|\mathbf{x})$, v každom kroku delí v pomere zlatého rezu. Interval sa teda zužuje o $(3 - \sqrt{5})/2 \doteq 0.382$ (t.j. komplement zlatého rezu) jeho dĺžky, pričom deliaci bod intervalu je $\theta_{zr}^{(i-1)}$. Metóda zlatého rezu konverguje lineárne (rád metódy je rovný jednej), t.j. chyba sa znižuje v každom iteračnom kroku $(1 - (3 - \sqrt{5})/2)$ -krát. Druhou metódou sa dopĺňa vo funkcii `optimize()` prvá v čase, keď je interval $\langle \theta_D^{(i-1)}, \theta_H^{(i-1)} \rangle$ príliš úzky. Bodmi $\theta_D^{(i-1)}, \theta_{zr}^{(i-1)}, \theta_H^{(i-1)}$ je preložená parabola (kvadratický interpolačný polynóm) a jej maximum bude novým bodom $\theta^{(i)}$. Prednastavené je hľadanie minima (`maximum=FALSE`) v štartovacom intervale (`interval`), čo môže byť zmenené na maximum (`maximum=TRUE`). Vo výstupoch funkcie `optimize()` bude $\hat{\theta}$ (minimum alebo maximum) a $l(\hat{\theta}|\mathbf{x})$ (`objective`).

Majme kvadratickú aproximáciu logaritmu funkcie vierohodnosti pomocou Taylorovho rozvoja druhého rádu okolo nejakého bodu θ_0 definovanú ako

$$l(\theta|\mathbf{x}) \approx l(\theta_0|\mathbf{x}) + S(\theta_0)(\theta - \theta_0) - \frac{1}{2}(\theta - \theta_0)^T \mathcal{I}(\theta_0)(\theta - \theta_0)$$

alebo lineárnu aproximáciu skóre funkcie pomocou Taylorovho rozvoja prvého rádu

$$S(\theta) \approx S(\theta_0) - \mathcal{I}(\theta_0)(\theta - \theta_0).$$

Z tejto aproximácie môžeme odvodiť nasledovnú iteračnú funkciu

$$\boldsymbol{\theta}_0 + (\mathcal{I}(\boldsymbol{\theta}_0))^{-1}S(\boldsymbol{\theta}_0).$$

Postup je nasledovný:

1. inicializácia metódy použitím vhodne zvoleného štartovacieho parametra $\boldsymbol{\theta}^{(0)}$, pre ktorý platí $\mathcal{I}(\boldsymbol{\theta}^{(0)}) \neq \mathbf{0}$,
2. iterácia rovnosti

$$\boldsymbol{\theta}^{(i)} = \boldsymbol{\theta}^{(i-1)} + (\mathcal{I}(\boldsymbol{\theta}^{(i-1)}))^{-1}S(\boldsymbol{\theta}^{(i-1)}),$$

$\mathcal{I}(\boldsymbol{\theta}^{(i-1)}) \neq \mathbf{0}$, pre $i = 1, 2, \dots$, pokiaľ nebude $|l(\boldsymbol{\theta}^{(i)}|\mathbf{x}) - l(\boldsymbol{\theta}^{(i-1)}|\mathbf{x})| < \epsilon$, kde ϵ je vhodne zvolené malé číslo (prahová hodnota). Vo všeobecnosti sa $-\mathcal{I}(\boldsymbol{\theta}^{(i-1)}) = l''(\boldsymbol{\theta}^{(i-1)}|\mathbf{x})$ nazýva *hesián*.

Namiesto $(\mathcal{I}(\boldsymbol{\theta}^{(i-1)}))^{-1}$ je lepšie použiť riešenie systému rovníc $(\mathcal{I}(\boldsymbol{\theta}^{(i-1)}))\mathbf{z}_{i-1} = S(\boldsymbol{\theta}^{(i-1)})$ pre nejaké \mathbf{z} a potom $\boldsymbol{\theta}^{(i)} = \boldsymbol{\theta}^{(i-1)} + \mathbf{z}_{i-1}$. V niektorých štatistických modeloch (napr. v logistickom regresnom modeli) sa namiesto $\mathcal{I}(\boldsymbol{\theta}^{(i-1)})$ používa $I(\boldsymbol{\theta}^{(i-1)})$, ktorá má často jednoduchší tvar. Potom hovoríme o **Fisherovej skóringovej metóde**. Ak namiesto $\mathcal{I}(\boldsymbol{\theta}^{(i-1)})$ použijeme jej pozitívne definitnú aproximáciu počítanú pomocou sukcesívne počítaných gradientov, hovoríme o **quasi Newtonovej metóde** (v angličtine nazývanej aj *variable metric method*). Fisherova skóringová metóda je potom vlastne quasi Newtonova metóda. Gradient nemusí byť špecifikovaný ako funkcia, ale môže byť počítaný numericky, napr. *centrálnou rozdielovou aproximáciou*, ako

$$\frac{\partial}{\partial \theta_i} l(\boldsymbol{\theta}|\mathbf{x}) \approx \frac{l(\boldsymbol{\theta} + \epsilon \mathbf{e}_i|\mathbf{x}) - l(\boldsymbol{\theta} - \epsilon \mathbf{e}_i|\mathbf{x})}{2\epsilon}, \text{ kde } i = 1, 2, \dots, k,$$

i -ty komponent bazálneho vektora \mathbf{e}_i obsahuje jednotku a na ostatných miestach sú nuly a ϵ je malé číslo. Derivácia v i -tom smere je potom pre $\epsilon \rightarrow 0$ nahradená jej konečnou aproximáciou. Quasi Newtonova metóda je implementovaná v \mathbb{R} vo funkcii `optim(par,fn,gr,method,control,hessian=FALSE,...)`, kde gradient môže byť špecifikovaný voliteľným argumentom `gr` (prednastavená je metóda spomenutá vyššie¹⁰). Populárnou metódou aproximácie hesiánu je **Broyden-Fletcher-Goldfarb-Shannova (BFGS) metóda**, kde

$$l''(\boldsymbol{\theta}^{(i)}|\mathbf{x}) \approx l''(\boldsymbol{\theta}^{(i-1)}|\mathbf{x}) + \frac{\mathbf{y}^{(i-1)}(\mathbf{y}^{(i-1)})^T}{(\mathbf{y}^{(i-1)})^T \mathbf{s}^{(i-1)}} - \frac{l''(\boldsymbol{\theta}^{(i-1)}|\mathbf{x})\mathbf{s}^{(i-1)}(l''(\boldsymbol{\theta}^{(i-1)}|\mathbf{x})\mathbf{s}^{(i-1)})^T}{(\mathbf{s}^{(i-1)})^T l''(\boldsymbol{\theta}^{(i-1)}|\mathbf{x})\mathbf{s}^{(i-1)}},$$

kde $\mathbf{y}^{(i-1)} = S(\boldsymbol{\theta}^{(i)}) - S(\boldsymbol{\theta}^{(i-1)})$ a $\mathbf{s}^{(i-1)} = \boldsymbol{\theta}^{(i)} - \boldsymbol{\theta}^{(i-1)} = (\mathcal{I}(\boldsymbol{\theta}^{(i-1)}))^{-1}S(\boldsymbol{\theta}^{(i-1)})$. BFGS metóda je implementovaná vo funkcii `optim()` pri nastavení argumentu `method="BFGS"`. Strata kvadratickej konvergencie oproti Newtonovej metóde je spôsobená aproximáciou hesiánu. BFGS metóda patrí do tzv. *Broydenovej triedy*, kde je hodnota $l''(\boldsymbol{\theta}^{(i)}|\mathbf{x})$ modifikovaná štvrtým členom, ktorý je pri BFGS nulový (pozri Givens a Hoeting, 2005).

Vo funkcii `optim()` je prednastavená **Nelder-Meadova metóda** (nazývaná aj **metóda simplexov**; argument `method="Nelder-Mead"`), ktorá nepoužíva gradient. Je robustná na nespojité funkcie, ale konverguje pomaly. Je vytvorená na základe myšlienky „preskokov“ cez trojuholníky. V každom kroku majme trojuholník definovaný troma bodmi $\boldsymbol{\theta}_1^{(i-1)}$, $\boldsymbol{\theta}_2^{(i-1)}$, $\boldsymbol{\theta}_3^{(i-1)}$, kde platí $l(\boldsymbol{\theta}_1^{(i-1)}|\mathbf{x}) < l(\boldsymbol{\theta}_2^{(i-1)}|\mathbf{x}) < l(\boldsymbol{\theta}_3^{(i-1)}|\mathbf{x})$ a snažíme sa $\boldsymbol{\theta}_1^{(i-1)}$ nahradiť „lepším“ bodom $\boldsymbol{\theta}_1^{(i)}$, pre ktorý platí $l(\boldsymbol{\theta}_1^{(i)}|\mathbf{x}) > l(\boldsymbol{\theta}_1^{(i-1)}|\mathbf{x})$. Ak je tak možné urobiť, nový bod definujeme pomocou stredovej súmernosti a extrapolácie ako

$$\boldsymbol{\theta}_1^{(i)} = \boldsymbol{\theta}_{23}^{(i-1)} + 2 \left(\boldsymbol{\theta}_{23}^{(i-1)} - \boldsymbol{\theta}_1^{(i-1)} \right),$$

kde $\boldsymbol{\theta}_{23}^{(i-1)} = \frac{\boldsymbol{\theta}_2^{(i-1)} + \boldsymbol{\theta}_3^{(i-1)}}{2}$. Z vyššie uvedeného vyplýva, že bod $\boldsymbol{\theta}_1^{(i-1)}$ zobrazujeme cez stred úsečky s krajnými bodmi $\boldsymbol{\theta}_2^{(i-1)}$ a $\boldsymbol{\theta}_3^{(i-1)}$ do bodu $\boldsymbol{\theta}_{23}^{(i-1)} + \left(\boldsymbol{\theta}_{23}^{(i-1)} - \boldsymbol{\theta}_1^{(i-1)} \right)$ a potom postupujeme po tejto polpriamke ešte ďalej do bodu $\boldsymbol{\theta}_1^{(i)}$. Ak $l(\boldsymbol{\theta}_1^{(i)}|\mathbf{x}) > l(\boldsymbol{\theta}_1^{(i-1)}|\mathbf{x})$, potom trojuholník nahradíme novým trojuholníkom definovaným bodmi $\boldsymbol{\theta}_1^{(i)}$, $\boldsymbol{\theta}_2^{(i-1)}$, $\boldsymbol{\theta}_3^{(i-1)}$.

¹⁰Centrálna rozdielová aproximácia hrá kľúčovú úlohu pri aproximácii hesiánu, ktorý sa používa v maximálnej vierohodnosti na odhad rozptylu.

Pri maximalizácii logaritmu funkcie vierohodnosti je vo vstupe funkcie `optim()` potrebné nastaviť `hessian=TRUE` a argument `control=list(fnscale=-1)`, ktorý robí maximalizáciu namiesto prednastavenej minimalizácie (v argumente `control` je možné nastaviť aj maximálne množstvo iterácií pomocou `maxit`). Argument `par` predstavuje štartovaciu hodnotu parametra. Vo výstupoch funkcie `optim()` bude $\hat{\theta}$ (`par`), $l(\hat{\theta}|\mathbf{x})$ (`value`) a $l''(\hat{\theta}|\mathbf{x})$ (`hessian`). Ak je vo výstupe `convergence` rovné nule, potom maximalizácia skonvergovala (k lokálnemu maximu, ktoré nemusí byť globálne).

Príklad 103 (maximálne vierohodný odhad μ a σ^2) Vygenerujte pseudonáhodné čísla z $X \sim N(4, 1)$, $n = 1000$. (a) Napíšte logaritmus profilovej funkcie vierohodnosti pre μ a σ^2 a preverte, či sú maximálne vierohodné odhady μ a σ^2 dostatočne blízko k ich skutočným hodnotám. Nakreslite grafy $l(\mu|\mathbf{x})$ a $l(\sigma^2|\mathbf{x})$, kde zvýrazníte polohu maxim týchto funkcií. (b) Napíšte logaritmus funkcie vierohodnosti pre $\theta = (\mu, \sigma^2)^T$ a preverte, či je maximálne vierohodný odhad $\hat{\theta}$ dostatočne blízko k jeho skutočnej hodnote. (c) Nakreslite graf $l(\theta|\mathbf{x})$ použitím funkcie `image()` a superponujte ho s kontúrovým grafom použitím funkcie `contour()`. Zvýraznite polohu maxima.

Riešenie (pozri obrázok 2.17)


Logaritmus funkcie vierohodnosti pre jednotlivé parametre má tvar

$$l(\mu|\mathbf{x}) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i^2 - 2\mu \sum_{i=1}^n x_i + n\mu^2 \right), \text{ kde } \mu \in (2, 6), \sigma_1 = 1;$$

$$l(\sigma^2|\mathbf{x}) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{\sum_{i=1}^n (x_i - \mu_1)^2}{2\sigma^2}, \text{ kde } \mu_1 = 4, \sigma \in (0.5, 1.5);$$

$$l(\theta|\mathbf{x}) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}, \text{ kde } \mu \in (2, 6) \text{ a } \sigma \in (0.5, 1.5).$$

Výsledky simulácie: $\hat{\mu} = 4.019708$ a $\hat{\sigma}^2 = 1.000038$.



Obr. 2.17: Profilová funkcia vierohodnosti pre μ (vľavo), σ^2 (uprostred) a funkcia vierohodnosti pre oba parametre (vpravo); $X \sim N(4, 1)$; maximálne vierohodné odhady strednej hodnoty a rozptylu sú označené zvislou čiarkovanou čiarou (vľavo a uprostred) a maximálne vierohodný odhad vektora parametrov je označený \bullet (vpravo)

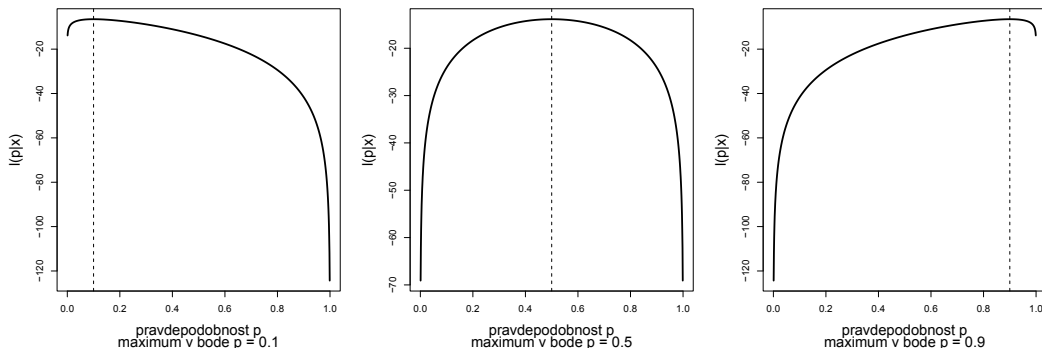
Ak náhodná premenná X nebude mať normálne rozdelenie, funkcia vierohodnosti pre strednú hodnotu nemusí mať symetrický parabolický tvar okolo strednej hodnoty. Odhad strednej hodnoty môže byť potom vychýlený.

Príklad 104 (maximálne vierohodné odhady) Za predpokladu normality rozdelenia náhodnej premennej X vypočítajte maximálne vierohodné odhady strednej hodnoty μ (ozn. $\hat{\mu}$) a rozptylu σ^2 (ozn. $\hat{\sigma}^2$) pomocou logaritmov funkcií vierohodnosti $l(\mu|\mathbf{x})$, resp. $l(\sigma^2|\mathbf{x})$. Porovnajtie tieto odhady s aritmetickým priemerom \bar{x} a rozptylom s^2 . Musí platiť $\hat{\mu} = \bar{x}$ a $\hat{\sigma}^2 = \frac{(n-1)}{n} s^2$. Realizáciami náhodnej premennej X sú hodnoty $x_i, i = 1, 2, \dots, n$, premenných: (a) dĺžka pravej kľúčnej kosti (`length.R`; dáta: `paired-means-clavicle2.txt`); (b) morfológická výška tváre (`face.H`; dáta: `one-sample-correlation-skull-mf.txt`); (c) šírka lebky (`skull.B`; dáta: `one-sample-mean-skull-mf.txt`).

Príklad 105 (binomické rozdelenie, maximálne vierohodný odhad p) Nech $X \sim \text{Bin}(N, p)$ a realizácie X sú $x = n$. Predpokladajme, že sme pozorovali (a) $x = 2$, (b) $x = 10$ a (c) $x = 18$ úspechov v $N = 20$ pokusoch. Pomocou \mathbb{R} vypočítajte maximálne vierohodný odhad p . Výsledok zobrazte do grafu spolu s funkciou vierohodnosti.

Riešenie (pozri obrázok 2.18)

Logaritmus funkcie vierohodnosti pre p má tvar $l(p|\mathbf{x}) = x \log(p) + (N - x) \log(1 - p)$, kde $p \in (0, 1)$.



Obr. 2.18: Funkcia vierohodnosti pre $X \sim \text{Bin}(N, p)$ ($p = 0.1, 0.5, 0.9$ a $N = 20$); odhady \hat{p} sú označené zvislou čiarkovanou čiarou

Ďalej derivujeme

$$\frac{\partial l(p|\mathbf{x})}{\partial p} = \frac{x/p - (N - x)/(1 - p)}{1 - p} = \frac{[x(1 - p) - (N - x)p]}{[p(1 - p)]} = \frac{(x - Np)}{[p(1 - p)]} = 0,$$

potom $\hat{p} = x/N$.

(a) $\hat{p} = x/N = 2/20 = 0.1$,

(b) $\hat{p} = x/N = 10/20 = 0.5$,

(c) $\hat{p} = x/N = 18/20 = 0.9$.

Z grafov na obrázku 2.18 je zreteľné, že funkcia vierohodnosti pre p je symetrická len pre $p = 0.5$, pre ostatné p je asymetrická. Navyiac pre p a $1 - p$ dostaneme grafy, ktoré možno transformovať jeden na druhý pomocou osi zrkadlenia definovanej ako vertikálna priamka v $p = 0.5$.


Príklad 106 (maximálne vierohodné odhady; binomické rozdelenie) Za predpokladu, že náhodná premenná X má binomické rozdelenie, vypočítajte maximálne vierohodný odhad \hat{p} pomocou logaritmu funkcie vierohodnosti $l(p|\mathbf{x})$. Porovnajme tento odhad s výrazom $\sum_{i=1}^N x_i/N$. Realizáciami náhodnej premennej X sú nasledujúce binárne premenné: (a) pohlavie (sex; dáta: `one-sample-probability-sexratio.txt`), kde ozn. pohlavia dievča „f“ preznačíme na 1 a ozn. pohlavia chlapec „m“ preznačíme na 0; (b) pohlavie (sex; dáta: `two-samples-probabilities-sexratio.txt`), kde ozn. pohlavia muž „m“ preznačíme na 1 a ozn. pohlavia žena „f“ preznačíme na 0. V prípade (a) počítame pravdepodobnosť výskytu dievčat a v prípade (b) pravdepodobnosť výskytu chlapcov.

Príklad 107 (maximálne vierohodné odhady; multinomické rozdelenie) Nech náhodná premenná X má multinomické rozdelenie. Potom vypočítajte maximálne vierohodné odhady \hat{p}_1 a \hat{p}_2 pomocou logaritmu funkcie vierohodnosti $l(\mathbf{p}|\mathbf{x})$. Porovnajme odhad p_1 s odhadom p z príkladu 106, kde pravdepodobnosť \hat{p}_1 bola označená ako \hat{p} . Realizáciami X sú binárne premenné: (a) pohlavie (sex; dáta: `one-sample-probability-sexratio.txt`), kde ozn. pohlavia dievča „f“ preznačíme na 1 a ozn. pohlavia chlapec „m“ preznačíme na 0; (b) pohlavie (sex; dáta: `two-samples-probabilities-sexratio.txt`), kde ozn. pohlavia muž „m“ preznačíme na 1 a ozn. pohlavia žena „f“ preznačíme na 0. Pravdepodobnosť \hat{p}_1 je (a) pravdepodobnosť výskytu dievčat a (b) pravdepodobnosť výskytu chlapcov.

Príklad 107 hovorí o tom, že parameter p_1 dvojrozmerného multinomického rozdelenia je parametrom p binomického rozdelenia.

Príklad 108 (maximálne vierohodné odhady; multinomické rozdelenie) Majme dáta `more-samples-probabilities-pubis.txt`. Nakreslite logaritmus štandardizovanej $\mathcal{L}(\boldsymbol{\theta}|\mathbf{x})$, kde $\boldsymbol{\theta} = (p_1, p_2)^T$, Európskej populácie ($n_1 = 30$, $n_2 = 20$ a $n_3 = 10$) pomocou funkcie `contour()`. Dokreslite do obrázku jej maximum v bode $\hat{\boldsymbol{\theta}} = (\hat{p}_1, \hat{p}_2)^T$.

Riešenie (pozri obrázok 2.19)



Obr. 2.19: Logaritmus štandardizovanej funkcie vierohodnosti multinomického rozdelenia v parametroch p_1 a p_2 (Európska populácia) s maximom označeným •

Príklad 109 (overdispersion v Poissonovom modeli, pokrač.) *Majme početnosti úrazov n medzi m_n robotníkmi v továrni, pozri tabuľku 2.10 (Greenwood a Yule, 1920). Vypočítajte očakávané m_n za predpokladu, že početnosti úrazov na robotníka X majú negatívne binomické rozdelenie s parametrami α a π .*

Riešenie (pozri tabuľku 2.14)

Aby sme mohli fitovať negatívne binomické rozdelenie, potrebujeme funkciu vierohodnosti

$$L(\alpha, \pi | \mathbf{x}) = \prod_{n=0}^4 (\Pr(X = n))^{m_n} \left(1 - \sum_{n=0}^4 \Pr(X = n) \right)^{m_{\geq 5}}.$$

a jej logaritmus

$$l(\alpha, \pi | \mathbf{x}) = \sum_{n=0}^4 m_n \ln \Pr(X = n) + m_{\geq 5} \ln \left(1 - \sum_{n=0}^4 \Pr(X = n) \right).$$

Numerickou optimalizáciou dostaneme $\hat{\alpha} = 0.84$ a $\hat{\pi} = 0.64$. Pomer zlyhaní $\hat{\mu} = \frac{1-\hat{\pi}}{\hat{\pi}} \hat{\alpha} = 0.47$. Keď porovnáme pozorované m_n a vypočítané (teoretické) m_n zistíme, že početnosti sú veľmi podobné (pozri tabuľku 2.14).

Tabuľka 2.14: Očakávané početnosti robotníkov m_n (zaokrúhlené na nula desatinných miest) s n úrazmi v továrni (negatívne binomické rozdelenie)

n	0	1	2	3	4	≥ 5
očakávané m_n	446	134	44	15	5	3

2.5 Kritériá klasifikácie štatistických modelov

Kritériá delenia štatistických modelov (ako aj k nim prislúchajúcich testov) sú nasledovné:

- **množstvo výberov** – jeden, dva alebo viac ako dva výbery [jedno-, dvoj- a viacvýberový test/model];
- **závislosť výberov** – nezávislé a závislé výbery (opakované merania na subjekte v čase, merania na párových orgánoch) [test/model dvoch a viacerých nezávislých výberov, párový test];
- **množstvo premenných** – jedna, dve alebo viac premenných [jedno-, dvoj- a viac-premenný test/model];

- **typ premenných** – kvalitatívne alebo kvantitatívne premenné [binomický, Poissonov, multinomický, súčinný multinomický model, model normálneho rozdelenia, rôzne modely kauzality];
- **rozmer endpointov/závislých premenných** – jedna, dve alebo viac premenných [jedno-, dvoj- a viac-rozmerný test/model – lineárny regresný model (LRM) vs. mnohorozmerný LRM (MLRM), analýza rozptylu ANOVA vs. mnohorozmerná ANOVA (MANOVA), analýza kovariancie ANCOVA vs. mnohorozmerná ANCOVA (MANCOVA)];
- **typ náhodnosti efektov** – fixné, náhodné alebo zmiešané [(M)ANOVA, (M)ANCOVA model a test/testy v nich];
- **typ kauzálneho vzťahu** – lineárny (priamka) alebo nelineárny (polynóm ľubovoľného stupňa – kvadratický, kubický a iný, alebo ľubovoľná funkcia);
- **typ vzťahu parametrov modelu** – lineárny [LRM – priamka, polynóm ľubovoľného stupňa a pod.] a nelineárny [nelineárny regresný model (NLRM)]; toto kritérium sa často zamieňa s predchádzajúcim, ale tieto dve kritéria nie sú totožné;
- **prítomnosť odľahlých pozorovaní**;
- **typ hypotézy** – jednostranná, obojstranná, stochasticky usporiadaná.

2.6 Praktické dôsledky odchýlok od normality

Základným predpokladom mnohých modelov je normalita rozdelenie spojitých premenných, čo však nemusí byť v praxi splnené. Napr. hodnoty často používanej telesnej hmotnosti nemajú v západnej civilizácii normálne rozdelenie, ale negatívne zošikmené (pozri kapitolu 3.2 Charakteristiky variability). Odchýlky od normality môžu mať mnoho príčin, od **neošetrených metodických nezrovnalostí** až ku **skutočným biologickým procesom v populácii**, z ktorých (náhodný) výber (vzorka) pochádza. Predpoklad normality by nikdy nemal byť samozrejмый (ani u premenných, ktoré obvykle normálne rozdelenie majú), dáta by mali byť pred štatistickými analýzami vhodne zobrazené (pozri kapitolu 3.6 Štatistická grafika) a ich normalita by mala byť v každej vzorke testovaná (pozri kapitolu 5.2 Kolmogorov-Smirnovov test dobrej zhody). Normalita rozdelenia by mala byť starostlivo posudzovaná a v prípade zachytenia odchýlok od normality v nejakom znaku v mnohých nezávislých výberoch by príčiny odchýlky mali byť bližšie skúmané. Malo by sa zistiť, či ide o metodickú chybu (odľahlé hodnoty žiadajúce odstránenie, nenáhodný výber, atď.) alebo skutočný trend, ktorý má svoje biologické príčiny (*rozdielna regulácia hornej a dolnej medze intenzity nejakého metabolického procesu* alebo *smernová/direkcionálna selekcia* u zošikmeného rozdelenia, *sledovaným znakom obmedzené vzorkovanie* (nenáhodný výber) alebo *stabilizačná selekcia u leptokurtického rozdelenia* (pozri kapitolu 3.2 Charakteristiky variability), atď.). Zošikmené rozdelenie majú často *inkrementálne (prírastkové) dáta* merané v priebehu ontogenézy, keďže je ich dolná hranica prirodzene obmedzená (nulový prírastok), zatiaľ čo horná môže u každého jedinca dosiahnuť rôzne veľké hodnoty (Garn a Rohmann, 1963). Treba mať na pamäti, že našim hlavným a najdôležitejším cieľom je zistenie podstaty procesov, ktoré prebiehajú v populácii, z ktorej pochádza naša vzorka a ktorej je obrazom.

V bežnej praxi je však časté, že sú používané relatívne malé vzorky, v ktorých sa odchýlky od normality ľahko prejavajú. Môžu však nastať aj *kontroverzné situácie*, že rozdelenie dát (pri relatívne malej vzorke) sa nepodobá na normálne, ale test dobrej zhody s normálnym rozdelením hypotézu o zhode zamietne. Rovnako sa často stáva, že meranie alebo experiment nie sú dopredu naplánované z hľadiska náhodného výberu, použitia nejakého modelu, z hľadiska minimalizácie variability a odhadu minimálneho rozsahu súboru. Dôležitosť takéhoto postupu je bežne aplikovanými výskumníkmi ignorovaná, čo môže viesť až do situácie nemožnosti použitia dát samotných alebo nemožnosti použitia akejkoľvek štatistickej metódy.

Súčasne sa utvrdzuje predstava o ideálnej podstate normality v prírode a tiež všeobecnej normalite rozdelenia často testovaných znakov, takže akékoľvek ďalšie, novozískané odchýlky od normality sa považujú za chybu. Skutočnosť ale často ukazuje, že so zvyšujúcim sa počtom prípadov vo vzorke (virtuálne až k celkovej veľkosti populácie) celý rad (empirických) veličín v skutočnosti nesmeruje ku stále dokonalejšej Gausovej krivke, ale má rozdelenie od normálneho viac či menej sa vzdalujúce alebo nejakým spôsobom vychýlené. V týchto prípadoch sa odporúča

1. použitie nejakej **transformácie dát** (v prípade zošikmenia; logaritmická, odmocninová, Box-Coxova a pod.), ktorá závisí na samotných dátach a nedá sa použiť univerzálne;
2. použitie **urezávania alebo winsorizácie dát** na jednom alebo oboch koncoch rozdelenia (v prípade prítomnosti odľahlých pozorovaní alebo zošikmenia; pozri kapitolu 3.1 Charakteristiky polohy, 3.2 Charakteristiky variability a 3.3 Detekcia odľahlých pozorovaní);
3. **nahradenie asymptotického rozdelenia testovacej štatistiky bootstrapovým alebo permutačným** (v prípade nedostatočného alebo relatívne malého rozsahu vzorky alebo pochybností o asymptotickom rozdelení testovacej štatistiky aj pri väčších rozsahoch).

Po aplikovaní prvých dvoch metód je možné použiť asymptotické testy v nezmenenej podobe a v treťom prípade sa použijú len samotné testovacie štatistiky.

3 Charakteristiky polohy a variability a štatistická grafika

Každé rozdelenie pravdepodobnosti býva charakterizované parametrami, ktoré sa odhadujú z realizácií (dát). Tieto parametre označujeme ako **číselné charakteristiky rozdelenia (štatistiky)**. Patria medzi ne **charakteristiky polohy a variability** ako napr. stredná hodnota, medián a ostatné kvantily, rozptyl, rozpätie a pod.

Stredná (očakávaná) hodnota (prvý začiatočný moment) rozdelenia náhodnej veličiny X , ozn. $E[X]$, vypočítame ako (Casella a Berger, 2002)

$$E[X] = \begin{cases} \sum_{i=1}^n x_i \Pr(X = x_i), & \text{ak } X \text{ je diskrétna náhodná premenná s realizáciami } x_1, x_2, \dots, x_n, \\ \int_{-\infty}^{\infty} x f_X(x) dx, & \text{ak } X \text{ je spojitá náhodná premenná s hustotou } f_X(x). \end{cases}$$

Rozptyl (druhý centrálny moment) $Var[X] = E[(X - E[X])^2]$, ktorého kladnú odmocninu $SD[X]$, vyjadrujúcu „rozptýlenie“ X okolo $E[X]$, nazývame **smerodajná odchýlka**.

Príklad 110 (charakteristiky normálneho rozdelenia) *Nech X_i sú iid z normálneho rozdelenia $N(\mu, \sigma^2)$, t.j. $X_i \sim N(\mu, \sigma^2)$. Potom $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ nazývame **výberová stredná hodnota** a $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ **výberový rozptyl***

Keďže X je náhodná premenná, \bar{X} nie je aritmetický priemer, ale tzv. výberový priemer; aritmetický priemer \bar{x} je realizácia výberového priemeru. Podobne S^2 je tzv. výberový rozptyl; $\hat{\sigma}^2 = s^2$ je jeho realizácia. Tiež $SD[X] = S$ je výberová smerodajná odchýlka a nie smerodajná odchýlka; smerodajná odchýlka $\hat{\sigma} = s$. Podiel $V_k = S^2/\bar{X}$ nazývame **výberový koeficient variácie**.

Príklad 111 (charakteristiky binomického rozdelenia) *Ak X pochádza z binomického rozdelenia, ozn. $Bin(N, p)$, potom $E[X] = Np$ je **stredná hodnota** a $Var[X] = Np(1-p)$ **rozptyl** náhodnej veličiny X .*

Nech X_1, X_2, \dots, X_n je náhodný výber z nejakého rozdelenia a $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ **usporiadaný náhodný výber** (vo vzrastajúcom poradí) s rozsahom n , kde $X_{(i)}$ nazývame **poriadkové štatistiky**. Sú to náhodné premenné, pre ktoré platí $X_{(1)} < X_{(2)} < \dots < X_{(n)}$. Potom (Casella a Berger, 2002)

$$X_{(1)} = \min_{1 \leq i \leq n} X_i,$$

$$X_{(2)} = \text{druhé najmenšie } X_i \text{ (} X_i \text{ v poradí druhé)}$$

$$\vdots$$

$$X_{(n-1)} = X_i \text{ v poradí } (n-1)\text{-vé,}$$

$$X_{(n)} = \max_{1 \leq i \leq n} X_i.$$

Výberový medián je charakterizovaný číslom $Q_2 = \tilde{X}$, ktoré rozdeľuje náhodný výber tak, že približne polovica X_i je menšia ako táto hodnota a polovica je väčšia ako táto hodnota. Definujeme ho ako¹

$$\tilde{X} = \begin{cases} X_{(\frac{n+1}{2})} & \text{ak } n \text{ je nepárne,} \\ \frac{1}{2} \left(X_{(\frac{n}{2})} + X_{(\frac{n}{2}+1)} \right) & \text{ak } n \text{ je párne.} \end{cases}$$

¹Ak n je nepárne, potom medián je prostredná hodnota, t.j. hodnota nachádzajúca sa v poradí ako prostredná alebo na mieste X , ktoré zodpovedá poradiu $(n+1)/2$. Ak n je párne, potom medián je uprostred zoradených hodnôt, t.j. hodnota na mieste X , ktoré zodpovedá priemeru X s poradiami $n/2$ a $n/2+1$.

Majme číslo $p \in (0, 1)$. Potom **výberovým 100 p -tym percentilom náhodného výberu** $X_{(\{np\})}$ bude také X_i , kde približne np hodnôt X_i bude menších ako $X_{(\{np\})}$ a $n(1-p)$ väčších ako $X_{(\{np\})}$. Ak $p = 0.5$, ide o 50. percentil alebo medián. Označenie $\{x\}$ v indexe znamená *najbližšie celé číslo*, kde $i - 0.5 \leq x < i + 0.5$, kde $\{x\} = i$. Potom

$$\tilde{X}_p = X_{(\{np\})} = \begin{cases} X_{(\{np\})}, & \text{ak } \frac{1}{2n} < p \leq 0.5, \\ X_{(n+1-\{n(1-p)\})}, & \text{ak } 0.5 < p < 1 - \frac{1}{2n}. \end{cases}$$

Príklad 112 (výberový 100 p -ty percentil) Ak $n = 12$, potom výberovým 65. percentilom je $X_{(9)}$, pretože $n(1-p) = 12 \times (1 - 0.65) = 4.2$ a $n + 1 - \{n(1-p)\} = 12 + 1 - 4 = 9$.

Často používanými percentilmi² sú **výberový dolný kvartil** (25. percentil) $Q_1 = \tilde{X}_{0.25}$ a **výberový horný kvartil** (75. percentil) $Q_3 = \tilde{X}_{0.75}$.

Na výpočet rozptylu nejakého percentilu musíme poznať pravdepodobnostnú funkciu poriadkovej štatistiky, jej hustotu a distribučnú funkciu. Výpočet môžeme výhodne zjednodušiť, keď vieme, aké je asymptotické rozdelenie poriadkovej štatistiky.

Definícia 27 (pravdepodobnostná funkcia poriadkovej štatistiky) Majme náhodný výber X_1, X_2, \dots, X_n z nejakého diskrétného rozdelenia s pravdepodobnostnou funkciou $f_X(x_i) = p_i$, kde $x_1 < x_2 < \dots < x_n$. Nech $P_0 = 0$, $P_1 = p_1$, $P_2 = p_1 + p_2$, \dots , $P_i = p_1 + p_2 + \dots + p_i$. Nech $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ sú poriadkové štatistiky. Potom (Bickel a Doksum, 2006)

$$\Pr(X_{(j)} \leq x_i) = \Pr(Y \geq j) = \sum_{k=j}^n \binom{n}{k} P_i^k (1 - P_i)^{n-k}$$

a

$$\Pr(X_{(j)} = x_i) = \Pr(X_{(j)} \leq x_i) - \Pr(X_{(j)} \leq x_{i-1}) = \sum_{k=j}^n \binom{n}{k} [P_i^k (1 - P_i)^{n-k} - P_{i-1}^k (1 - P_{i-1})^{n-k}],$$

kde Y je náhodná premenná počtu hodnôt z X_1, X_2, \dots, X_n , ktoré sú menšie alebo rovné ako x_i . Nech $\{X_j \leq x_i\}$ je priaznivá udalosť a $\{X_j > x_i\}$ je nepriaznivá udalosť. Ak $i = 1$, potom $\Pr(X_j = x_i) = \Pr(X_j \leq x_i)$, pretože $\Pr_0 = 0$. Teda Y je počet priaznivých udalostí v n pokusoch, t.j. $Y = \text{card}\{X_j \leq x_i\}$. Pravdepodobnosť úspechu je potom $\Pr(X_j \leq x_i)$ pre každý pokus, pretože pokusy sú rovnako rozdelené. Priaznivá a nepriaznivá udalosť j -teho pokusu je nezávislá od výsledku iného pokusu, pretože X_j sú nezávislé od ostatných X_i . Teda $Y \sim \text{Bin}(n, P_i)$.

Ozn. $\text{card}\{\cdot\}$ znamená veľkosť (kardinalitu) množiny.

Ak X_1, X_2, \dots, X_n je náhodný výber zo spojitého rozdelenia, zhody neprichádzajú do úvahy a pravdepodobnosť, že nejaké dve alebo viaceré X_j sú rovnaké, je nula. Teda $\Pr(X_{(1)} < X_{(2)} < \dots < X_{(n)}) = 1$ a výberový priestor pre $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ je $\mathcal{X} = \{(x_1, x_2, \dots, x_n) : x_1 < x_2 < \dots < x_n\}$.

Definícia 28 (hustota a distribučná funkcia poriadkovej štatistiky) Nech $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ sú poriadkové štatistiky náhodného výberu X_1, X_2, \dots, X_n s distribučnou funkciou $F_X(x)$ a hustotou $f_X(x)$. Potom hustota poriadkovej štatistiky $X_{(j)}$ je rovná (Bickel a Doksum, 2006)

$$f_{X_{(j)}}(x) = \frac{n!}{(j-1)!(n-j)!} f_X(x) [F_X(x)]^{j-1} [1 - F_X(x)]^{n-j}$$

a distribučná funkcia

$$F_{X_{(j)}}(x) = \Pr(X_{(j)} \leq x) = \Pr(Y \geq j) = \sum_{k=j}^n \binom{n}{k} [F_X(x)]^k [1 - F_X(x)]^{n-k}.$$

²Všeobecne definujeme **kvantil** ako hodnotu skúmanej veličiny, ktorá delí náhodný výber na dve časti pod a nad kvantom; číslo v dolnom indexe hovorí o časti náhodného výberu pod kvantom. Podľa toho rozlišujeme aj jeho typ, napr. kvartil, decil, percentil a pod.

Definícia 29 (asymptotické rozdelenie poriadkovej štatistiky) *Nech $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ sú poriadkové štatistiky náhodného výberu X_1, X_2, \dots, X_n . Majme pravdepodobnosť α , kde $F(t_\alpha) = \alpha$. Asymptoticky platí, že $\sqrt{n}(\frac{1}{n} - \alpha)$ konverguje k 0. Potom je poriadková štatistika $X_{(j)}$ normálne rozdelená so strednou hodnotou $E[X_{(j)}] = t_\alpha$ a rozptylom $\sigma_{X_{(j)}}^2 = \frac{\alpha(1-\alpha)}{f^2(t_\alpha)n}$. Ak $X \sim N(\mu, \sigma^2)$, potom $\sigma_{X_{(j)}}^2 = \sigma^2 \frac{\pi^2}{24 \ln n}$ (Casella a Berger, 2002).*

Príklad 113 (rozptyl poriadkovej štatistiky) *Pomocou delta metódy odvod'te rozptyl poriadkovej štatistiky v definícii 29.*

Príklad 114 (rozptyl poriadkovej štatistiky, $X \sim N(\mu, \sigma^2)$) *Pomocou definície 29 odvod'te rozptyl poriadkovej štatistiky, ak $X \sim N(\mu, \sigma^2)$.*

Definícia 30 (stredná hodnota a rozptyl mediánu) *Stredná hodnota mediánu $X_{(\frac{n+1}{2})}$ je rovná $E[X_{(\frac{n+1}{2})}] = \tilde{\mu}$ a rozptyl mediánu $\sigma_{X_{(\frac{n+1}{2})}}^2 = \frac{1}{4f^2(\tilde{\mu})n}$, kde n je nepárne. Ak $X \sim N(\mu, \sigma^2)$, potom $\sigma_{X_{(\frac{n+1}{2})}}^2 = \sigma^2 \frac{\pi}{2n}$ (Casella a Berger, 2002).*

Príklad 115 (rozptyl mediánu) *Pomocou delta metódy odvod'te rozptyl poriadkovej štatistiky v definícii 30.*

Príklad 116 (rozptyl mediánu, $X \sim N(\mu, \sigma^2)$) *Pomocou definície 30 odvod'te rozptyl poriadkovej štatistiky, ak $X \sim N(\mu, \sigma^2)$.*

Ak má náhodná premenná X normálne rozdelenie, výpočet rozptylu mediánu sa zjednoduší, t.j. stačí poznať σ a n . Znalosť rozptylu mediánu je potrebná na výpočet $100 \times (1 - \alpha)\%$ intervalu spoľahlivosti pre medián (pozri kapitolu 4 Testovanie hypotéz). Popis rozdelenia mediánu, ak n je párne, je nad rámec tejto knihy.

Rozpätie náhodného výberu je vzdialenosť medzi najmenšou a najväčšou poriadkovou štatistikou, t.j. $R = X_{(n)} - X_{(1)}$.

Definícia 31 (hodnoty distribučnej funkcie v kvantiloch) *Empirická distribučná funkcia $F_n(x)$ je definovaná nasledovne*

$$F_n(x) = \begin{cases} 0, & \text{ak } x < X_{(1)}, \\ \frac{i}{n}, & \text{ak } X_{(i)} \leq x < X_{(i+1)}, \\ 1, & \text{ak } x \geq X_{(n)}. \end{cases}$$

*Majme transformáciu $T_{(1)} = F_n(X_{(1)})$, $T_{(2)} = F_n(X_{(2)})$, \dots , $T_{(n)} = F_n(X_{(n)})$. Potom $T_{(1)}, T_{(2)}, \dots, T_{(n)}$ sú **poriadkové štatistiky**. Potom platí*

$$\lim_{n \rightarrow \infty} \Pr(\sup_{\forall x \in \mathcal{X}} [F_n(x) - F(x)] n^{1/2} \leq \lambda) = \Phi(\lambda),$$

kde $F(X)$ je teoretická distribučná funkcia a $\Phi(\lambda) = \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2 \lambda^2}$. Potom $100 \times (1 - \alpha)\%$ pás spoľahlivosti pre $F(x)$ definujeme ako $F_n(x) \pm \lambda_\alpha 1/n^{1/2}$, kde $\Phi(\lambda_\alpha) = 1 - \alpha$ a $\text{Var}[F_n(x)] = 1/n$ (Kolmogorov, 1933; Smirnov, 1933; Wilks, 1948). Potom môžeme tvrdiť, že $F(X)$ patrí do $100 \times (1 - \alpha)\%$ pásu spoľahlivosti a zároveň je medzi nulou a jednotkou s pravdepodobnosťou $1 - \alpha$.

Príklad 117 (graf distribučnej funkcie a jej IS) *Nakreslite graf distribučnej funkcie $N(\mu, \sigma^2)$, kde $\mu = 0$ a $\sigma^2 = 1$. Do grafu dokreslite 95% pás spoľahlivosti pre $F(x)$. Jeho hranice vypočítajte pomocou simulácie pseudonáhodných čísel z $N(0, 1)$ pri $n = 50$, kde $F_n(x)$ je odhadnutá z dát. Teoretickú distribučnú funkciu $\Phi(\lambda)$ naprogramujte v \mathbb{R} použitím definície 31 alebo knižnice kolmim a funkciu $\text{pkolm}()$.*

3.1 Charakteristiky polohy

Realizácie budeme označovať ako x_1, x_2, \dots, x_n , **usporiadané realizácie** budú $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$. Potom môžeme definovať nasledovné odhady charakteristík polohy (výberové charakteristiky polohy) spolu s ich anglickými ekvivalentami:

- **výberové minimum** X_{\min} , ktorého realizácia $x_{\min} = x_{(1)}$;
- **výberové maximum** X_{\max} , ktorého realizácia $x_{\max} = x_{(n)}$;
- **výberový aritmetický priemer** \bar{X} , ktorého realizácia $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{j=1}^{n_j} x_j f_j$, $n_j \leq n$, kde f_j sú frekvencie (počty) prislúchajúcich x_j a $n = \sum_j f_j$;
- **výberový modus** X_{mod} , ktorého realizácia x_{mod} je najčastejšie sa vyskytujúca hodnota (pri diskretnej premennej ide o hodnotu x , v ktorej má pravdepodobnostná funkcia svoje maximum; pri spojitých premennej ide o hodnotu x , v ktorej má hustota svoje maximum);
- **výberový medián** \tilde{X} (robustný odhad polohy), ktorého realizácia

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & \text{ak } n \text{ je nepárne,} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & \text{ak } n \text{ je párne;} \end{cases}$$

rozdelenie je *symetrické*, ak $\bar{x} = \tilde{x} = x_{\text{mod}}$, rozdelenie je *pozitívne zošikmené* (pravostranne), ak $\bar{x} > \tilde{x} > x_{\text{mod}}$ a rozdelenie je *negatívne zošikmené* (ľavostranne), ak $\bar{x} < \tilde{x} < x_{\text{mod}}$;

- **výberové kvartily** poznáme tri
 - **výberový prvý (dolný) kvartil** Q_1 , ktorého realizácia $\tilde{x}_{0.25}$ predstavuje hodnotu, od ktorej je 1/4 dát menšia a 3/4 dát sú väčšie,

$$\Pr[x_{\min}, \tilde{x}_{0.25}] = \Pr[X \leq \tilde{x}_{0.25}] = \frac{1}{4}, \Pr[\tilde{x}_{0.25}, x_{\max}] = \Pr[X \geq \tilde{x}_{0.25}] = \frac{3}{4};$$

- **výberový druhý kvartil** (medián) Q_2 , ktorého realizácia $\tilde{x}_{0.5} = \tilde{x}$ je hodnota, od ktorej je 1/2 dát menšia a 1/2 dát je väčšia,

$$\Pr[x_{\min}, \tilde{x}_{0.5}] = \Pr[X \leq \tilde{x}_{0.5}] = \frac{1}{2}, \Pr[\tilde{x}_{0.5}, x_{\max}] = \Pr[X \geq \tilde{x}_{0.5}] = \frac{1}{2};$$

- **výberový tretí (horný) kvartil** Q_3 , ktorého realizácia $\tilde{x}_{0.75}$ predstavuje hodnotu, od ktorej je 1/4 dát väčšia a 3/4 dát sú menšie,

$$\Pr[x_{\min}, \tilde{x}_{0.75}] = \Pr[X \leq \tilde{x}_{0.75}] = \frac{3}{4}, \Pr[\tilde{x}_{0.75}, x_{\max}] = \Pr[X \geq \tilde{x}_{0.75}] = \frac{1}{4};$$

- **výberové decily** \tilde{X}_k , ktorých realizácie \tilde{x}_k delia súbor na desatiny, t.j. $k/10$ dát je pod decilom a $(10 - k)/10$ nad decilom, kde $k \in \{0, 1, \dots, 10\}$;
- **výberové percentily** \tilde{X}_p (čítame ako 100p-percentil³), ktorých realizácie \tilde{x}_p definujeme ako

$$\tilde{x}_p = \begin{cases} x_{(k+1)} & \text{pre } k \neq np, \\ \frac{1}{2} (x_{(k)} + x_{(k+1)}) & \text{pre } k = np, \end{cases}$$

kde $k = \lfloor np \rfloor$, čo je celá časť čísla np (niekedy sa používa definícia cez $\{x\}$ v indexe, čo znamená najbližšie celé číslo);

- **výberový päťčíselný súhrn** $(X_{\min}, Q_1, Q_2, Q_3, X_{\max})^T$, ktorého realizáciu označujeme $(x_{\min}, \tilde{x}_{0.25}, \tilde{x}_{0.50}, \tilde{x}_{0.75}, x_{\max})^T$.

³Výraz „100p-percentil“ čítame ako „stokrát p-ty percentil“. Ak $p = 0.75$, potom $100 \times 0.75 = 75$, čo čítame ako „75. percentil“.

Príklad 118 (výšky 10-ročných dievčat) Majme výšky $n = 12$ náhodne vybraných 10-ročných dievčat v cm usporiadaných podľa veľkosti (**poradia** ozn. ako r_i pre $x_{(i)}$; pri rovnakých pozorovaniach hovoríme o **strednoporadiach**; strednoporadie sa vypočíta ako priemer poradí realizácií s rovnakou hodnotou).

Riešenie (pozri tabuľku 3.1)

Tabuľka 3.1: Zoradené realizácie x_i a ich poradia r_i pre výšky 10-ročných dievčat

i	1	2	3	4	5	6	7	8	9	10	11	12
$x_{(i)}$	131	132	135	141	141	141	141	142	143	146	146	151
r_i	1	2	3	5.5	5.5	5.5	5.5	8	9	10.5	10.5	12

$\bar{x} \doteq 140.83$, $\tilde{x} = \frac{1}{2}(x_{(6)} + x_{(7)}) = 141$, $\tilde{x}_{0.25} = \frac{1}{2}(x_{(3)} + x_{(4)}) = 138$, kde $k = \lfloor 12 \times 0.25 \rfloor = 3$, $Q_3 = \tilde{x}_{0.75} = \frac{1}{2}(x_{(9)} + x_{(10)}) = 144.5$, kde $k = \lfloor 12 \times 0.75 \rfloor = 9$.

Čo sa stane so spomínanými charakteristikami polohy, keď zmeníme mierku (škálu), napr. gramy na kilogramy alebo namiesto hmotností použijeme logaritmus hmotností?

Nech $a, b \in \mathbb{R}$ sú nejaké dané konštanty, a je posunutie a b škála. Potom $y_i = a + bx_i$ a pre priemer⁴

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n (a + bx_i) = \frac{1}{n} \left(na + b \sum_{i=1}^n x_i \right) = a + b\bar{x} = \overline{a + bx}.$$

Pokiaľ $b \in \mathbb{R}^+$, usporiadanie hodnôt x_i sa pri transformácii na $y_i = a + bx_i$ nezmení, teda

$$a + bx_{(1)} \leq a + bx_{(2)} \leq \dots \leq a + bx_{(n)}.$$

Pre medián v tomto prípade platí⁵

$$\tilde{y} = a + b\tilde{x} = \widetilde{a + bx}.$$

Ľahko sa dá nahliadnuť, že usporiadanie zachová každá rastúca funkcia $g(x)$, teda platí

$$g(x_{(1)}) \leq g(x_{(2)}) \leq \dots \leq g(x_{(n)})$$

a pre medián bude platiť $g(\tilde{x}) \doteq \tilde{g}(x)$. Pre nepárne n platí predchádzajúci vzťah presne, označenie „približnosti“ potrebujeme pre párne n , kde $x_{(\frac{n}{2})} < x_{(\frac{n}{2}+1)}$. V tomto prípade je však $1/2$ hodnôt $g(x_i)$ menšia ako $\tilde{g}(x)$. Teda špeciálne môžeme medián logaritmu (napr. hmotnosti) spočítať ako logaritmus mediánu (napr. hmotnosti). Pokiaľ dôjde v pozorovaniach k posunutiu, dôjde k rovnakému posunutiu aj v charakteristike polohy. Ak zmeníme mierku, potom stačí urobiť rovnakú úpravu aj u charakteristiky polohy.

Robustnou charakteristikou strednej hodnoty (odolnejšou na odľahlé pozorovania) je (Tukey, 1962)

- **výberový γ -urezaný aritmetický priemer \bar{X}_g** , ktorého realizáciou je \bar{x}_g a vypočíta sa ako

$$\bar{x}_g = \frac{1}{n - 2g} (x_{(g+1)} + x_{(g+2)} + \dots + x_{(n-g)}),$$

kde $g = \{\gamma n\}$, $g = \lfloor \gamma n \rfloor$, $\gamma = 0.1, 0.2$. Viac ako $\gamma 100\%$ pozorovaní⁶ musí byť nahradených, aby sa tento priemer zmenil na malý alebo veľký v porovnaní s pôvodným [⁷breakdown point \bar{x}_g je teda γ],

⁴Rovnosť znamená, že priemer posunutej a preškálovanej veličiny y je rovný posunutému a preškálovanému priemeru pôvodnej veličiny x .

⁵Rovnosť znamená, že medián posunutej a preškálovanej veličiny y je rovný posunutému a preškálovanému mediánu pôvodnej veličiny x .

⁶Výraz „ $\gamma 100\%$ pozorovaní“ čítame ako „ γ krát sto percent pozorovaní“.

⁷Breakdown point hovorí o počte pozorovaní, ktoré potrebujeme na to, aby sme výrazne zmenili hodnotu charakteristiky polohy. Pre γ -urezaný a γ -winsorizovaný aritmetický priemer ide o γn pozorovaní, pre medián ide o $n/2$ pozorovaní a pre aritmetický priemer stačí iba jedno pozorovanie (preto hovoríme, že aritmetický priemer je veľmi citlivý na odľahlé pozorovania).

- **výberový γ -winsorizovaný priemer \bar{X}_w** , ktorého realizácia \bar{x}_w je definovaná ako

$$\bar{x}_w = \frac{1}{n} \left((g+1)x_{(g+1)} + x_{(g+2)} + \dots + (g+1)x_{(n-g)} \right).$$

Viac ako $\gamma 100\%$ pozorovaní musí byť nahradených, aby sa tento priemer zmenil na malý alebo veľký v porovnaní s pôvodným [*breakdown point* \bar{x}_w je teda γ].

3.2 Charakteristiky variability

Definujeme nasledovné základné odhady charakteristík variability (výberové charakteristiky variability) spolu s ich anglickými ekvivalentami:

- **výberový rozptyl S^2** , ktorého realizáciou je

$$s^2 = s_{n-1}^2 = s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2;$$

pri lineárnej transformácii sa rozptyl mení nasledovne⁸

$$s_y^2 = s_{a+bx}^2 = b^2 s_x^2,$$

t.j.

$$\begin{aligned} s_y^2 &= s_{a+bx}^2 = \frac{1}{n-1} \sum_{i=1}^n (a + bx_i - a - b\bar{x})^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (a + bx_i - (a + b\bar{x}))^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (b(x_i - \bar{x}))^2 = b^2 s_x^2; \end{aligned}$$

výpočtová podoba rozptylu

$$s_x^2 = \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = \frac{1}{n-1} \left(\sum_{j=1}^{n_j} x_j^2 f_j - n\bar{x}^2 \right), n_j \leq n,$$

kde f_j sú frekvencie (počty) prislúchajúcich x_j a $n = \sum_j f_j$;

- **výberová smerodajná odchýlka S** , ktorej realizáciou je

$$s = s_{n-1} = s_x = \sqrt{s_x^2};$$

pri lineárnej transformácii sa smerodajná odchýlka mení nasledovne⁹

$$s_y = s_{a+bx} = |b| s_x,$$

teda, ak pripočítame ku všetkým pozorovaniam rovnakú konštantu, miera variability sa nezmení; zmena mierky (u pomerovej mierky zmena jednotiek) má za následok rovnakú úpravu jednotlivých pozorovaní i miery variability v podobe smerodajnej odchýlky;

- **výberový koeficient variácie V_k** , ktorého realizácia v_k predstavuje normalizovanú podobu výberového rozptylu (inverzia *signal-to-noise ratio*; podiel variability na priemere)

$$v_k = \frac{s_x}{\bar{x}};$$

⁸Rovnosť znamená, že rozptyl posunutej a preškálovanej veličiny y je rovný násobku druhej mocniny škály a rozptylu pôvodnej veličiny x .

⁹Rovnosť znamená, že smerodajná odchýlka posunutej a preškálovanej veličiny y je rovná násobku absolútnej hodnoty škály a smerodajnej odchýlky pôvodnej veličiny x .

bezrozmerná veličina, zvyčajne vyjadrovaná v percentách, t.j. $100 \times (s_x/\bar{x})$ % a môže sa používať len pre realizácie, ktorých rozsah nadobúda kladné hodnoty; používa sa pri porovnávaní variability súborov s nerovnakými priemermi (napr. pri porovnaní variability výšky detí určitého veku s výškou dospelých určitého veku alebo pri porovnaní variability premenných meraných v rôznych jednotkách);

- **výberový rozptyl aritmetického priemeru** $S_{\bar{X}}^2$, ktorého realizáciou je

$$s_{\bar{x}}^2 = \frac{s_x^2}{n};$$

- **výberová stredná chyba priemeru (štandardná chyba)** $S_{\bar{X}}$, ktorej realizáciou je

$$s_{\bar{x}} = \frac{s_x}{\sqrt{n}};$$

- **výberový koeficient šikmosti** B_1 , ktorého realizáciou je

$$b_1 = \frac{n^{-1} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[n^{-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{3/2}} = \frac{\sqrt{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right]^{3/2}},$$

kde rozdelenie je *symetrické*, ak $b_1 = 0$, *pozitívne zošikmené* (hustota na ľavej strane stúpa strmšie ako na pravej), ak $b_1 > 0$ a *negatívne zošikmené* (hustota na pravej strane stúpa strmšie ako na ľavej), ak $b_1 < 0$;

- **výberový koeficient špicatosti** B_2 , ktorého realizáciou je

$$b_2 = \frac{n^{-1} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[n^{-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^2} - 3 = \frac{n \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right]^2} - 3,$$

kde rozdelenie je normálne (*mezokurtické*), ak $b_2 = 0$, *špicaté (leptokurtické)*, ak $b_2 > 0$ a *ploché (platykurtické)*, ak $b_2 < 0$;

- **výberová suma štvorcov** $SS = \sum_{i=1}^n (X_i - \bar{X})^2$, ktorej realizácia je

$$SS_{\text{obs}} = \sum_{i=1}^n (x_i - \bar{x})^2,$$

kde sa tento čitateľ rozptylu používa napr. v lineárnom regresnom modeli, v modeli ANOVA a pod.;

- **výberová suma absolútnych odchýlok** $SAD = \sum_{i=1}^n |X_i - \tilde{X}_{0.5}|$, ktorej realizácia je

$$SAD_{\text{obs}} = \sum_{i=1}^n |x_i - \tilde{x}_{0.5}|;$$

- **výberový priemer absolútnych odchýlok** $MAD = \frac{1}{n} \sum_{i=1}^n |X_i - \tilde{X}_{0.5}|$, ktorého realizácia je

$$MAD_{\text{obs}} = SAD_{\text{obs}}/n;$$

- **výberové rozpätie** $D = X_{\max} - X_{\min}$, ktorého realizáciou je

$$d_{\text{obs}} = x_{\max} - x_{\min};$$

- **výberové medzikvartilové rozpätie** $D_Q = Q_3 - Q_1$, ktorého realizáciou je

$$d_Q = \tilde{x}_{0.75} - \tilde{x}_{0.25};$$

kde rozdelenie je (medzi kvartilmi) *symetrické*, ak $\tilde{x}_{0.75} - \tilde{x}_{0.50} = \tilde{x}_{0.50} - \tilde{x}_{0.25}$, *pozitívne zošikmené*, ak $\tilde{x}_{0.75} - \tilde{x}_{0.50} > \tilde{x}_{0.50} - \tilde{x}_{0.25}$ a *negatívne zošikmené*, ak $\tilde{x}_{0.75} - \tilde{x}_{0.50} < \tilde{x}_{0.50} - \tilde{x}_{0.25}$;

- **výberové decilové rozpätie** $D_D = \tilde{X}_{0.9} - \tilde{X}_{0.1}$, ktorého realizáciou je

$$d_D = \tilde{x}_{0.9} - \tilde{x}_{0.1};$$

- **výberové percentilové rozpätie** $D_P = \tilde{X}_{0.99} - \tilde{X}_{0.01}$, ktorého realizáciou je

$$d_P = \tilde{x}_{0.99} - \tilde{x}_{0.01}.$$

Robustnými charakteristikami variability sú (Tukey, 1962)

- **výberový γ -urezaný rozptyl** S_g^2 , ktorého realizácia s_g^2 sa vypočíta ako

$$s_g^2 = \frac{1}{n - 2g - 1} \sum_{i=g+1}^{n-g} x_{(i)};$$

viac ako $\gamma 100\%$ pozorovaní musí byť nahradených, aby sa tento rozptyl zmenil na veľký v porovnaní s pôvodným s^2 [*breakdown point* s_g^2 je γ]; platí $s_g^2 < s^2$ pretože urezanie odstráni odľahlé hodnoty;

- **výberový γ -winsorizovaný rozptyl** S_w^2 , ktorého realizáciu označujeme ako s_w^2 ; viac ako $\gamma 100\%$ pozorovaní musí byť nahradených, aby sa tento rozptyl zmenil na veľký v porovnaní s pôvodným s^2 [*breakdown point* s_w^2 je γ]; platí $s_w^2 < s^2$ pretože winsorizovanie priťahuje extrémne hodnoty bližšie k priemeru;

- **výberový kvartilový koeficient variácie** $V_{k,Q} = (Q_3 - Q_1)/Q_2$, ktorého realizáciu $v_{k,Q}$ vypočítame ako

$$v_{k,Q} = \frac{\tilde{x}_{0.75} - \tilde{x}_{0.25}}{\tilde{x}}.$$

Ďalšie robustné charakteristiky variability (výberové rozpätie) charakterizované pomocou upravených hraníc sú

- **výberové robustné minimum a maximum** („vnútorné hradby“) $X_{\min}^* = B_D = Q_1 - 1.5D_Q$ a $X_{\max}^* = B_H = Q_1 + 1.5D_Q$, ktorých realizácie sú definované ako

$$x_{\min}^* = b_D = \tilde{x}_{0.25} - 1.5(\tilde{x}_{0.75} - \tilde{x}_{0.25}),$$

$$x_{\max}^* = b_H = \tilde{x}_{0.75} + 1.5(\tilde{x}_{0.75} - \tilde{x}_{0.25}),$$

kde prvky vybočujúce z hradieb sa považujú za *podozrivé, potencionálne odľahlé pozorovania*;

- **výberové robustné minimum a maximum** („vonkajšie hradby“) definované ako $B_H^* = Q_1 - 3(Q_3 - Q_1)$, $B_H^* = Q_3 + 3(Q_3 - Q_1)$, ktorých realizácie sú $b_D^* = \tilde{x}_{0.25} - 3d_Q$, $b_H^* = \tilde{x}_{0.75} + 3d_Q$;

– pokiaľ sú nejaké $x_i < b_D^* \vee x_i > b_H^*$, hovoríme, že ide o *vzdialené body*¹⁰,

– ak $x_i \in (b_D^*, b_D) \vee (b_H, b_H^*)$, ide o *body vonkajšie*,

– ak $x_i \in (b_D, b_H)$, ide o *body vnútorné* alebo *body priľahlé mediánu*;

– pre normálne rozdelenie platí $B_H - B_D = Q_3 + 1.5D_Q - Q_1 + 1.5D_Q = 4D_Q \doteq 4.2$; pravdepodobnosť, že $x_i \notin (B_D, B_H)$ je potom 0.04;

- **výberové robustné miery šikmosti** B_{1Q} a B_{1O} a ich rozptyly za podmienky asymptotickej normality B_1 , kde $\cdot = Q$ alebo O , ktorých realizácie sú definované nasledovne

– kvartilový koeficient šikmosti

$$b_{1Q} = \frac{(\tilde{x}_{0.75} - \tilde{x}_{0.50}) - (\tilde{x}_{0.50} - \tilde{x}_{0.25})}{\tilde{x}_{0.75} - \tilde{x}_{0.25}}, \text{Var}_{as}(b_{1Q}) = 1.84,$$

¹⁰Ozn. \vee znamená „alebo“ a ozn. \wedge znamená „a súčasne“.

– oktilový koeficient šikmosti

$$b_{1O} = \frac{(\tilde{x}_{0.875} - \tilde{x}_{0.50}) - (\tilde{x}_{0.50} - \tilde{x}_{0.125})}{\tilde{x}_{0.875} - \tilde{x}_{0.125}}, \text{Var}_{as}(b_{1O}) = 1.15.$$

3.3 Detekcia odľahlých pozorovaní

Homogénny náhodný výber je taký výber, v ktorom všetky $x_i, i = 1, 2, \dots, n$, sú realizácie rovnakého rozdelenia pravdepodobnosti s konštantným rozptylom σ^2 . K **nehomogenitám výberu** dochádza všade tam, kde sa vyskytujú výrazné nerovnomernosti v realizáciách, náhle sa menia podmienky experimentu a pod. Nehomogenita môže byť spôsobená aj nevhodne zvoleným výberom subjektov.

Špeciálnym prípadom ovplyvňujúcim homogenitu výberu sú **odľahlé pozorovania** (outliers). Takéto pozorovania skresľujú odhady polohy (špeciálne aritmetického priemeru) a variability (hlavne rozptylu), takže môžu znehodnotiť ďalšiu štatistickú analýzu. Pri ich overovaní sa používa mnoho idealizovaných predpokladov. Musíme poznať ich predpokladaný počet, ich rozdelenie a tiež rozdelenie ostatných prvkov náhodného výberu. Navyše je nutné zostrojiť štatistický alebo pravdepodobnostný model, podľa ktorého sa odľahlé pozorovania chovajú. Testovanie odľahlých pozorovaní bez doplnkových informácií je teda málo spoľahlivé.

Jednoduchou technikou, kedy sa predpokladá, že dáta majú normálne rozdelenie, je **modifikácia vnútorných hradieb** b_D a b_H na

$$b_D^{mod} = \tilde{x}_{0.25} - kd_Q, b_H^{mod} = \tilde{x}_{0.75} + kd_Q,$$

kde sa parameter k volí tak, aby pravdepodobnosť $\Pr(n, k)$ bola dostatočne vysoká, napr. 0.95. $\Pr(n, k)$ je pravdepodobnosť, že žiaden prvok z náhodného výberu z normálneho rozdelenia s rozsahom n nebude mimo intervalu $I = \langle b_D^{mod}, b_H^{mod} \rangle$. Ak $\Pr(n, k) = 0.95$ a $n \in \langle 8, 100 \rangle$ použijeme aproximáciu $k \approx 2.25 - 3.6/n$. Teda prvky mimo I sa považujú za odľahlé. Postup spomenutý vyššie je dostatočne robustný.

Definujme mieru rozptylu ako **kvantilovú odchýlku** $d_{Q^*} = 2d_Q$. Ak urobíme štandardizáciu, dostaneme $d_{Q^*_{st}} = 1$ a **štandardizovaný medián** bude $\tilde{x}_{st} = 0$ a **štandardizovaná kvantilová funkcia** indikujúca tvar bude (Meloun a Militký, 2004)

$$q_{st}(p) = \frac{\tilde{x}_p - \tilde{x}_{0.5}}{d_{Q^*}}.$$

Hodnoty kvantilov, pre ktoré platí $|q_{st}(p)| \geq 1$, sú považované za vybočujúce (pre normálne rozdelenie) a hovoríme potom o **identifikátoroch dlhých „chvostov“** (koncov). Hodnoty $q_{st}(p)$ môžeme použiť na

– identifikáciu miery šikmosti $SQ_{\text{obs}} = q_{st}(0.25) + q_{st}(0.75)$, kedy je rozdelenie pravdepodobnosti symetrické medzi kvartilmi, ak SQ_{obs} je rovné nule,

– identifikáciu dĺžky koncov, kedy

- $q_{st}(0.95) < 0.5$ hovorí o krátkych koncoch,
- $q_{st}(0.95) > 1$ hovorí o dlhých koncoch a
- pre stredne dlhé konce bude platiť $q_{st}(0.95) \in \langle 0.5, 1.0 \rangle$.

Okrem vonkajších a vnútorných hradieb, môžeme odľahlé pozorovania jednoducho detegovať aj nasledovne (Rousseeuw a van Zomeren, 1990)

- $|x - \bar{x}| > 2s$,
- $\hat{\sigma} = MAD_{\text{obs}}/0.6745, |x - \tilde{x}_{0.5}| > k \frac{MAD_{\text{obs}}}{0.6745}$ (ako k sa najčastejšie používa 2 alebo 2.24).

Príklad 119 (odľahlé pozorovania; dĺžka kľúčnej kosti) *Nech náhodná premenná X najväčšia dĺžka kosti kľúčnej z pravej strany (cla.L; dáta: more-samples-variances-clavicle.txt) má asymptoticky normálne rozdelenie, t.j. $X \sim N(\mu, \sigma^2)$. Potom identifikujte odľahlé pozorovania pomocou (a) vnútorných hradieb b_D a b_H , (b) modifikovaných vnútorných hradieb b_D^{mod} a b_H^{mod} , (c) identifikujte dlhé „chvosty“ rozdelenia tejto premennej na základe štandardizovanej kvantilovej funkcie.*

3.4 Z-skóre

V antropológii nás veľmi často zaujímajú normované realizácie, nazývané tiež normované veličiny, a to **z-skóre**, ktoré definujeme ako

$$z_i = \frac{x_i - \bar{x}}{s_x}.$$

Dostaneme ich ako špeciálny prípad lineárnej transformácie $y = a + bx$, kde voľbou $b = 1/s_x$ a $a = -\bar{x}/s_x$. Potom aritmetický priemer z-skóre

$$\bar{z} = -\frac{\bar{x}}{s_x} + \frac{1}{s_x}\bar{x} = 0$$

a rozptyl z-skóre

$$s_z^2 = \left(\frac{1}{s_x}\right)^2 s_x^2 = 1,$$

Pomocou z-skóre môžeme vyjadriť aj koeficient šikmosti a špicatosti, kde

$$b_1 = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x}\right)^3 = \frac{1}{n} \sum_{i=1}^n z_i^3,$$

a za podmienky asymptotickej normality

$$E[b_1] = 0, \text{Var}[b_1] = \frac{n-2}{(n+1)(n+3)};$$

$$b_2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x}\right)^4 = \frac{1}{n} \sum_{i=1}^n z_i^4$$

a za podmienky asymptotickej normality

$$E[b_2] = 3 - \frac{6}{n+1}, \text{Var}[b_2] = \frac{24n(n-2)(n-3)}{(n+1)^2(n+3)(n+5)}.$$

Pokiaľ dáta pochádzajú z normálneho rozdelenia, budú mať oba koeficienty hodnoty približne nulové (pri b_2 po odčítaní konštanty 3).

Musíme si uvedomiť, že prítomnosť odľahlých pozorovaní v realizáciách ovplyvňuje výpočet priemeru a rozptylu, ktoré sú potrebné na výpočet z-skóre, a následne tak ovplyvňuje tiež hodnotu vlastného z-skóre. Ak je rozdelenie dát zošikmenené alebo je normalita porušená inak, nebude z-skóre odrážať situáciu vierohodne a jeho ďalšie použitie je problematické. Ak predpokladáme, že je rozdelenie znaku v populácii normálne, obmedzuje sa použie z-skóre napr. na zistenie, či nejaké pozorovanie (pacient) patrí svojimi charakteristikami do zdravej populácie.

Príklad 120 (z-skóre; šírka lebky) *Majme náhodnú premennú X šírka lebky (skull.B; mm; dáta: one-sample-mean-skull-mf.txt) u mužov. Za predpokladu asymptotickej normality X , t.j. $X \sim N(\mu, \sigma^2)$, vypočítajte z-skóre tejto premennej pomocou funkcie `mean()` a `sd()`. Výsledok skontrolujte pomocou funkcie `scale()`.*

3.5 Príklady na charakteristiky polohy a variability

Príklad 121 (argument minima) Vygenerujte pseudonáhodné čísla $X \sim N(\mu, \sigma^2)$, kde $\mu = 0, \sigma^2 = 1$ a $n = 1000$. Vygenerované čísla ozn. $x_i, i = 1, 2, \dots, 1000$. Nájdite numericky také c , ktoré minimalizuje (a) sumu štvorcov odchýlok $\sum_{i=1}^{1000} (x_i - c)^2$, t.j. $c_1 = \arg \min_{c \in \mathbb{R}} \sum_{i=1}^{1000} (x_i - c)^2$ a (b) sumu absolútnych odchýlok $\sum_{i=1}^{1000} |x_i - c|$, t.j. $c_2 = \arg \min_{c \in \mathbb{R}} \sum_{i=1}^{1000} |x_i - c|$. Za c dosadzujte postupne (1) všetky $x_{(j)}$ ($x_{(j)}$ sú usporiadané x_i podľa veľkosti od najmenšieho po najväčšie) a vybrané charakteristiky polohy ako (2) aritmetický priemer, (3) nejaké kvantily \tilde{x}_p , kde $p \in (0, 1)$ a pod. Nakreslite obrázok závislosti (a) sumy štvorcov odchýlok na $x_{(j)}$, t.j. body $[x_j, y_j]$, kde $y_j = \sum_{i=1}^{1000} (x_i - x_{(j)})^2$ a (b) sumy absolútnych odchýlok na $x_{(j)}$, t.j. body $[x_{(j)}, y_j]$, kde $y_j = \sum_{i=1}^{1000} |x_i - x_{(j)}|$. Podobné obrázky nakreslite aj pre \tilde{x}_p namiesto $x_{(j)}$.

Príklad 122 (výšky 10-ročných dievčat, pokrač.) Vypočítajte základné charakteristiky polohy a variability.

Riešenie v \mathbb{R} (pozri tabuľku 3.2 a 3.3)

Dáta:

```
72 | x <- c(131, 132, 135, 141, 141, 141, 141, 142, 143, 146, 146, 151)
```

Minimum, maximum, medián, aritmetický priemer, prvý kvartil, druhý kvartil, tretí kvartil, kvantily (pomocou jednej funkcie), päťčíselný súhrn, rozptyl a smerodajná odchýlka:

```
73 | min(x) # 131
74 | max(x) # 151
75 | median(x) # 141
76 | mean(x) # 140.8333
77 | priemer <- sum(x)/length(x) # 140.8333
78 | q1 <- quantile(x, 0.25, type=2) # 138
79 | q2 <- quantile(x, 0.50, type=2) # 141
80 | q3 <- quantile(x, 0.75, type=2) # 144.5
81 | quantile(x, c(0.25, 0.5, 0.75), type=2) # 138.0 141.0 144.5
82 | quantile(x, c(0.25, 0.5, 0.75, 1), type=2) # 131.0 138.0 141.0 144.5 151.0
83 | var(x) # 33.78788
84 | sd(x) # 5.812734
```

Funkcie na výpočet rozptylu, smerodajnej odchýlky, štandardnej chyby, šikmosti a špicatosti:

```
85 | "rozptyl" <- function(x) sum((x-mean(x))^2)/(length(x)-1)
86 | "smerodch" <- function(x) sqrt(var(x))
87 | "SE" <- function(x) sqrt(var(x) / length(x))
88 | SE(x) # 1.677992
89 | "sikmost" <- function(x) {(1/length(x))*sum(((x-mean(x))/(sqrt(var(x))))^3)}
90 | sikmost(x) # -0.2121993
91 | "spicatost" <- function(x) {(1/length(x))*sum(((x-mean(x))/(sqrt(var(x))))^4) - 3)}
92 | spicatost(x) # -0.9029347
```

Suma štvorcov, priemerná absolútna odchýlka (priemer absolútnych odchýlok), suma absolútnych odchýlok, rozpätie, medzikvartilové rozpätie, zisťovanie symetrie, robustný výpočet minima a maxima („vnútorné hradby“), robustné rozpätie:

```
94 | var(x)*(length(x)-1) # 371.6667
95 | mad(x) # 5.1891
96 | mad(x)*length(x) # 62.2692
97 | c(min(x), max(x)) # 131 151
98 | range(x) # 131 151
99 | Dq <- quantile(x, 0.75, type=2) - quantile(x, 0.25, type=2) # 6.5
100 | c(q3 - q2, q2 - q1) # 3.5 3.0
101 | Bd <- q1 - 1.5*Dq; Bh <- q3 + 1.5*Dq
102 | c(Bd, Bh) # 128.25 154.25
```

Funkcia na výpočet kvartilovej šikmosti:

```
103 | "kvart.sikmost" <- function(x) {
104 |     q1 <- quantile(x, 0.25, type=2)
105 |     q2 <- quantile(x, 0.5, type=2)
106 |     q3 <- quantile(x, 0.75, type=2)
107 |     ((q3 - q2) - (q2 - q1))/(q3 - q1)
108 | }
109 | kvart.sikmost(x) # 0.07692308
```

Funkcia na výpočet oktilovej šikmosti:

```
110 "oktil.sikmost" <- function(x) {
111   q125 <- quantile(x,0.125,type=2)
112   q2 <- quantile(x,0.5,type=2)
113   q875 <- quantile(x,0.875,type=2)
114   ((q875 - q2) - (q2 - q125))/(q875 - q125)
115 }
116 oktil.sikmost(x) # -0.2857143
```

Funkcia na výpočet výberového γ -urezaného aritmetického priemeru a rozptylu (vytvorenie dátového vektora na ich výpočet):

```
117 "urezanie" <- function(x, gama = 0.1){
118 x <- na.omit(x) # odstranenie NA, ak sa v datach nachadzaju
119 n <- length(x)
120 g.min <- floor(gama*n) # najvacsie cele cislo mensie ako gama*n
121 g.max <- floor((1-gama)*n) # najvacsie cele cislo mensie ako (1-gama)*n
122 x.sort <- sort(x) # zoradenie podla velkosti
123 x.min <- x.sort[g.min] # vybratie dolnej hranice
124 x.max <- x.sort[g.max] # vybratie hornej hranice
125 xg <- x[x > x.min & x < x.max]
126 return(xg)
127 }
```

Funkcia na výpočet výberového aritmetického priemeru a rozptylu winsorizovaného pomocou „vnútorých hradieb“ (vytvorenie dátového vektora na ich výpočet):

```
128 "winsorizacia" <- function(x){
129 x <- na.omit(x) # odstranenie NA
130 q1 <- quantile(x,0.25)
131 q3 <- quantile(x,0.75)
132 Dq <- q3 - q1
133 min.x <- q1 - 1.5*Dq
134 max.x <- q3 + 1.5*Dq
135 xw <- x
136 for (i in 1:length(x)) if (x[i] >= max.x) xw[i] <- max.x
137 for (i in 1:length(x)) if (x[i] <= min.x) xw[i] <- min.x
138 return(xw)
139 }
```

Porovnanie troch typov aritmetických priemerov a rozptylov:

```
140 xg <- urezanie(x)
141 xw <- winsorizacia(x)
142 TAB <- rbind(c(length(x), mean(x), sd(x)),c(length(xg), mean(xg), sd(xg)),c(length(xw), mean(xw), sd(xw)))
143 dimnames(TAB)[[1]] <- c("surove_data","urezane_data","winsorizovane_data")
144 dimnames(TAB)[[2]] <- c("rozsah","priemer","sd")
145 TAB <- round(TAB,2)
```

Tabuľka 3.2: Rozsah, aritmetický priemer a smerodajná odchýlka pre surové, urezané a winsorizované dáta (výšky 10-ročných dievčat)

	rozsah	aritmetický priemer	smerodajná odchýlka
surové dáta	$n = 12$	$\bar{x} = 140.83$	$s^2 = 5.81$
urezané dáta	$n_g = 8$	$\bar{x}_g = 139.50$	$s_g^2 = 3.85$
winsorizované dáta	$n_w = 12$	$\bar{x}_w = 141.03$	$s_w^2 = 5.21$

Funkcia na výpočet niektorých základných charakteristík:

```
146 "zakl.char" <- function(x, type = 7){
147 # odstranenie chybajucich pozorovani
148 x <- x[!is.na(x)]
149 n <- length(x) # rozsah
150 # kvantily p = 0,0.25,0.5,0.75 a 1
151 kvantily <- quantile(x,c(0,0.25,0.5,0.75,1),type=type)
152 priemer <- mean(x) # priemer
153 SD <- sd(x) # smerodajna odchylka
154 StEr <- SE(x) # standardna chyba
155 sikm <- sikmost(x) # sikmost
156 spic <- spicatost(x) # spicatost
157 # vsetky vysledky spolu
158 vysledky <- c(n, priemer, kvantily, sikm, spic, SD, StEr)
159 # priradenie nazvov vysledkom
160 names(vysledky) <- c("n","priem",names(kvantily),"sik","spic","sd","se")
161 # zaokruhlenie na dve desatinne miesta
162 vysledky <- round(vysledky,2)
163 return(vysledky)
164 }
165 zakl.char(x, type = 2)
```

Tabuľka 3.3: Vybrané charakteristiky polohy a variability pre surové dáta (výšky 10-ročných dievčat)

charakteristika	n	\bar{x}	\tilde{x}_{\min}	$\tilde{x}_{0.25}$	$\tilde{x}_{0.50}$	$\tilde{x}_{0.75}$	\tilde{x}_{\max}	b_1	b_2	s_x	$s_{\bar{x}}$
hodnota	12	140.8	131.0	138.0	141.0	144.5	151.0	-0.21	-0.90	5.81	1.68

Príklad 123 (základné charakteristiky polohy a variability) Vypočítajte základné charakteristiky polohy a variability pre premennú najväčšia dĺžka lebky (*skull.L*) a najväčšia šírka lebky (*skull.B*) u mužov; dáta: *one-sample-mean-skull-mf.txt*. Výsledok uložte pomocou funkcie *write.table()*.

Riešenie v \mathbb{R} (pozri tabuľku 3.4)

```

166 DATA <- read.table("one-sample-mean-skull-mf.txt", header=TRUE)
167 names(DATA) ## "id" "pop" "sex" "skull.L" "skull.B"
168 attach(DATA)
169 ZCH1 <- zakl.char(skull.L[sex=="m"])
170 ZCH2 <- zakl.char(skull.B[sex=="m"])
171 ZCH <- rbind(ZCH1, ZCH2)
172 dimnames(ZCH)[[1]] <- c("skull.L", "skull.B")
173 ZCH
174 write.table(ZCH, "skull-tab-01.txt")

```

Tabuľka 3.4: Vybrané charakteristiky polohy a variability pre najväčšiu dĺžku lebky

	n	\bar{x}	\tilde{x}_{\min}	$\tilde{x}_{0.25}$	$\tilde{x}_{0.50}$	$\tilde{x}_{0.75}$	\tilde{x}_{\max}	b_1	b_2	s_x	$s_{\bar{x}}$
skull.L	217	182.04	164.00	177.00	182.00	187.00	199.00	-0.06	-0.48	6.37	0.43
skull.B	216	137.19	124.00	134.00	137.00	140.00	149.00	0.08	-0.30	4.82	0.33

Príklad 124 (šikmosť a špicatosť) Naprogramujte funkcie na výpočet rozptylu šikmosti a špicatosťi.

Príklad 125 (základné charakteristiky polohy a variability) Vypočítajte základné charakteristiky polohy a variability pre nasledujúce premenné:

- širko-dĺžkový index lebky vypočítaný ako podiel premenných šírka lebky (*skull.B*; v mm) a dĺžka lebky (*skull.L*; v mm; dáta: *one-sample-mean-skull-mf.txt*) u mužov;
- stranový rozdiel vertikálneho priemeru diaľžky kľúčnej kosti (*simd.R* a *simd.L*; v mm) na pravej aj ľavej strane tela (dáta: *paired-means-clavicle2.txt*);
- najväčšia výška mozgovne (*skull.pH*; mm) a morfológická výška tváre (*face.H*; mm; dáta: *one-sample-correlation-skull-mf.txt*).

3.6 Štatistická grafika

Pokiaľ chceme zobraziť základné a relevantné grafy (spolu s výpočtom základných charakteristík polohy a variability), hovoríme o **exploratórnej analýze dát (EDA)**; pozri Murrell (2011) a Kabacoff (2011). Grafická interpretácia výberového súboru je možná pomocou stĺpcového diagramu, spojnicového grafu (polygónu početnosti, frekvenčnej krivky a polygónu kumulatívnych početností), bodového grafu, kruhového diagramu, histogramu, empirickej distribučnej funkcie, krabicového diagramu a kvantilového diagramu.

3.6.1 Stĺpcový diagram

Stĺpcový diagram – vyjadruje číselné hodnoty pomocou obdĺžnikovými stĺpcov, obyčajne v zvislej, no niekedy aj vo vodorovnej polohe; môže byť neškálovaný, t.j. v *absolútnej škále*, alebo škálovaný, t.j. v *relatívnej škále* (lepšie porovnanie v prípade sledovania viacerých súborov); špeciálnymi variantmi sú **veková pyramída** (strom života, znázorňuje vekové zloženie obyvateľstva) a **histogram**. Stĺpcový diagram nakreslíme pomocou funkcie *barplot(x)*.

Kombinácii stĺpcových diagramov usporiadaných nad sebou pre škálované kategoriálne dáta, t.j. dáta v podobe pravdepodobností, ktorých suma je rovná jednej, sa hovorí aj **spinogram**. Spinogram nakreslíme pomocou funkcií

```
175 | library(vcd)
176 | spine(x)
```

Príklad 126 (stĺpcový diagram; oči vs. vlasy) Kontingenčná tabuľka predstavuje pravdepodobnosti výskytu rôznych farieb vlasov a očí v populácii. Ide o model multinomického rozdelenia, ozn. $Mult(\mathbf{p}, N)$, pretože všetky pravdepodobnosti dávajú v sume jednotku. Vypočítajte početnosti všetkých buniek tabuľky, ak máme v populácii 1000 jedincov. Prepočítajte pravdepodobnosti na model súčinnového multinomického rozdelenia (pravdepodobnosti výskytu pre dve farby očí a tri farby vlasov pozri v tabuľke 3.5). Použite základné funkcie (pozri Spector, 2008; Venables a kol., 2013; Verzani, 2005) a skontrolujte pomocou funkcií `margin.table(oci)` a `prop.table(oci)`. Nakreslite stĺpcové diagramy pre oba typy súčinných multinomických rozdelení – pre početnosti, ako aj pre pravdepodobnosti. [Marginálne súčty možno pridať pomocou funkcie `addmargins(oci)`; keby sme mali surové dáta (hodnoty 0 a 1 pre každý subjekt), kontingenčnú tabuľku vytvoríme pomocou funkcie `fable(data)`.]

Tabuľka 3.5: Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov

oči/vlasy	blond	hnede	ryšavé
modré	0.12	0.22	0.06
hnede	0.15	0.34	0.11

Riešenie v \mathbb{R} (pozri tabuľky 3.6 až 3.9 a obrázok 3.1)

```
177 | modre.oci <- c(0.12,0.22,0.06) # vektor pravdepodobnosti
178 | hnede.oci <- c(0.15,0.34,0.11) # vektor pravdepodobnosti
179 | oci <- rbind(modre.oci,hnede.oci) # dva vektory spojené do matice
180 | sum(oci) # celkova (totalna) suma = 1
181 | # nazvy riadkov a stlpcov
182 | dimnames(oci)[[1]] <- c("modre","hnede")
183 | dimnames(oci)[[2]] <- c("blond","hnede","rysave")
184 | round(addmargins(oci),2) # marginalne pravdepodobnosti
185 | oci.pocty <- oci*1000 # fiktivne pocetnosti
186 | addmargins(oci.pocty) # marginalne pocetnosti
187 | sumy <- apply(oci.pocty,2,sum) # sumy po stlpcoch
188 | oci.prav <- oci.pocty
189 | oci.prav[1,] <- oci.pocty[1,]/sumy
190 | oci.prav[2,] <- oci.pocty[2,]/sumy
191 | apply(oci.prav,2,sum) # suma po stlpcoch = 1
192 | round(addmargins(oci.prav,1),2) # marginalne pocetnosti po riadkoch
193 | sumy1 <- apply(oci.pocty,1,sum) # sumy po riadkoch
194 | oci.prav1 <- oci.pocty
195 | oci.prav1[,1] <- oci.pocty[,1]/sumy1
196 | oci.prav1[,2] <- oci.pocty[,2]/sumy1
197 | oci.prav1[,3] <- oci.pocty[,3]/sumy1
198 | apply(oci.prav1,1,sum) # suma po riadkoch = 1
199 | round(addmargins(oci.prav1,2),4) # marginalne pocetnosti po stlpcoch
200 | par(mfrow=c(2,2))
201 | par(mar=c(4,2,1,1))
202 | barplot(oci.pocty,space=0,cex.names=1.5)
203 | barplot(t(oci.pocty),space=0,cex.names=1.5)
204 | par(mar=c(4,2,0,0))
205 | barplot(oci.prav,space=0,cex.names=1.5)
206 | barplot(t(oci.prav1),space=0,cex.names=1.5)
207 | # legend("topright",c("modre oci","hnede oci"),fill=c("black","grey")) # mozne pridanie legendy (nezobrazena)
```

Tabuľka 3.6: Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi pravdepodobnosťami (multinomické rozdelenie)

oči/vlasy	blond	hnede	ryšavé	suma
modré	0.12	0.22	0.06	0.40
hnede	0.15	0.34	0.11	0.60
suma	0.27	0.56	0.17	1.00

Tabuľka 3.7: Kontingenčná tabuľka 2×3 početností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi početnosťami (multinomické rozdelenie)

oči/vlasy	blond	hnedé	ryšavé	suma
modré	120	220	60	400
hnedé	150	340	110	600
suma	270	560	170	1000

Tabuľka 3.8: Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi stĺpcovými početnosťami (súčinové multinomické rozdelenie; po stĺpcoch)

oči/vlasy	blond	hnedé	ryšavé
modré	0.4444	0.3929	0.3529
hnedé	0.5556	0.6071	0.6471
suma	1.0000	1.0000	1.0000

Tabuľka 3.9: Kontingenčná tabuľka 2×3 pravdepodobností výskytu pre dve farby očí a tri farby vlasov spolu s marginálnymi riadkovými početnosťami (súčinové multinomické rozdelenie; po riadkoch)

oči/vlasy	blond	hnedé	ryšavé	suma
modré	0.3000	0.5500	0.1500	1.0000
hnedé	0.2500	0.5667	0.1833	1.0000

3.6.2 Spojnicový graf, polygón početnosti a frekvenčná krivka

Spojnicový graf – znázorňuje priebeh časového radu a jeho špeciálnymi prípadmi sú **polygón početnosti**, **frekvenčná krivka**, **polygón kumulatívnych početností**.

Polygón početnosti – spojnicový diagram, v ktorom nad stredmi triednych intervalov I_i vztýčime kolmice, s výškou úmernou príslušným triednym početnostiam a koncové body kolmíc pospájame. Ich súradnice sú $[x_i^*, n_i]$. Ide o zobrazenie priebehu početností vnútri každého intervalu, ale plocha uzavretá spojnicou polygónu nie je presne (len približne) úmerná počtu pozorovaní v intervale.

Frekvenčná krivka – vznikne, keď koncové body polygónu početnosti pospájame hladkou krivkou; vystihuje celkom presne priebeh rozdelenia početnosti a plocha v každom mieste ohraničená krivkou je priamo úmerná počtu pozorovaní.


3.6.3 Bodový graf

Bodový (rozptyľový) graf – zobrazuje namerané hodnoty v pravouhlej súradnicovej sústave (dvojdimenziálnej, 2D; trojdimenziálnej, 3D), pričom jednotlivé kategórie sa odlišujú pomocou rôznych značiek, farieb a pod.; často sa používa na zobrazenie závislosti dvoch znakov. Dvojdimenziálny a trojdimenziálny rozptyľový graf nakreslíme pomocou funkcií

```
208 | plot(x,y) # 2D
209 | library(scatterplot3d)
210 | scatterplot3d(x,y,z) # 3D
```

Argumenty funkcie **plot(x)**:

- **type**= argument kontrolujúci typ grafu
 - **type="p"** – body (prednastavená hodnota; *default*),
 - **type="l"** – čiary,
 - **type="b"** – body pospájané čiarami,
 - **type="s"** – schodovitá funkcia,
 - **type="n"** – prázdny obrázok;
- argumenty popisu osí a grafu
 - **xlab="retazec"** – popis osi x ,
 - **ylab="retazec"** – popis osi y ,



Obr. 3.1: Stĺpcové diagramy – početnosti (prvý riadok) pre vlasy (vľavo), pre oči (vpravo); pravdepodobnosti (druhý riadok) pre vlasy (vľavo), pre oči (vpravo)

- `main="retazec"` – hlavný nadpis,
- `sub="retazec"` – podnadpis pod osou x ;

- farba `col="anglicky.nazov"` alebo kódovanie v RGB-škále (`rgb(cislo1,cislo2,cislo3)` vytvorí RGB-vektor z hodnôt intenzity); transformácia `col2rgb(anglicky.nazov)` vytvorí RGB-vektor z anglického názvu farby, kde RGB-vektor je textový vektor so 7 alebo 9 elementmi, kde za `"#"` nasleduje *red*, *blue* a *green* farebný kanál a voliteľne aj koeficient transparentie α v hexadecimálnej sústave (po preškáľovaní na hodnoty $0, \dots, 255$; default je "black");
- veľkosť `cex=k`, $k \in \mathbb{R}$, prednastavená hodnota je 1;
- typ bodov `pch=k`, číslo $k = 1, 2, \dots, 20$, prednastavená hodnota je 1 (prázdny krúžok);
- typ čiar `lty=k`, číslo $k = 1, 2, \dots, 20$, prednastavená hodnota je 1 (plná čiara).

Ďalšie funkcie súvisiace s bodovým grafom:

- `points(x,y)` – pridávanie bodov do obrázka;
- `lines(x,y)` – pridávanie čiar do obrázka;
- `text(x, y, labels)` – pridanie textu v bodoch špecifikovaných súradnicami x a y , kde popis `labels[i]` sa zobrazuje v bodoch `(x[i],y[i])`, prednastavené hodnoty sú `1:length(x)`;
`plot(x,y, type="n"); text(x, y, names);`
- `title(main,sub,xlab,ylab)` – dodatočné pridanie nadpisov a popisov osí;
- `legend(x,y,legend)` – dodatočné pridanie legendy, špecificky umiestnenej v súradniciach x a y , kde sú prednastavené nasledovné polohy "bottomright", "bottom", "bottomleft", "left", "topleft", "top", "topright", "right" a "center"; argumenty funkcie
 - `fill="retazec"` – farba výplne (ne)orámovanej legendy,
 - `col="retazec"` – farba nakreslených bodov alebo čiar,
 - `lty=k` – typ čiar, $k = 1, 2, \dots, 20$,
 - `lwd=k` – šírka čiar, $k \in \mathbb{N}$, prednastavená hodnota je 1 (plná čiara),

- `pch=k` – typ bodov, $k = 1, 2, \dots, 20$, prednastavená hodnota je 1 (prázdny krúžok);
- `locator(n,type)` – určenie polohy konkrétneho bodu v grafe (napr. odľahlé pozorovanie) pomocou jedného bodového kliknutia myšou v jeho blízkosti, pričom funkcia bod nielen označí, ale aj vypočíta jeho súradnice `text(locator(1),"retazec")`; použitie v legende `legend(locator(1),...)`;
- `identify(x,y,labels)` identifikácia bodov, ak poznáme ich súradnice.


Príklad 127 (typy bodov a základné farby) *Nakreslite obrázok (a) základných dvadsiatich typov bodov a (b) ôsmich typov farieb a dvanástich odtieňov sivej.*

Riešenie v \mathbb{R} (pozri obrázok 3.2)

```

211 | windows(14,2.5)
212 | par(mar=c(3,0.1,0.1,0.1))
213 | plot(1:20,rep(0:1,10),type="n",sub="",xlab="",ylab="",bty="n",axes=FALSE)
214 | points(1:20,rep(0.5,20),pch=1:20,cex=4)
215 | axis(1,at=1:20,labels=1:20,cex.axis=1.5)
216 | box()
217 | windows(14,2.5)
218 | par(mar=c(3,0.1,0.1,0.1))
219 | plot(1:8,rep(0:1,10),type="n",sub="",xlab="",ylab="",bty="n",axes=FALSE)
220 | points(1:8,rep(0.5,8),pch=16,col=1:8,cex=4)
221 | siva <- paste("gray",rev(seq(25,80,by=5)),sep="")
222 | points(9:20,rep(0.5,12),pch=16,col=siva,cex=4)
223 | axis(1,at=1:20,labels=c(1:8,siva),cex.axis=1.5)
224 | box()

```



Obr. 3.2: Základné typy bodov (dolný riadok) a farieb (horný riadok)

Príklad 128 (typy bodov a základné farby) *Nakreslite obrázok zpiatich základných typov čiar, ktoré (a) smerujú zvislo, (b) smerujú vodorovne, (c) zvierajú s osou x uhol 45° .*


Riešenie v \mathbb{R} (pozri obrázok 3.3)

```


225 | windows(12,4)
226 | par(mfcol=c(1,3))
227 | plot(1,1,type="n",xlab="",ylab="",bty="n",axes=FALSE,xlim=c(-3,3),ylim=c(-3,3))
228 | abline(v=-2,lt=1:5)
229 | plot(1,1,type="n",xlab="",ylab="",bty="n",axes=FALSE,xlim=c(-3,3),ylim=c(-3,3))
230 | abline(h=-2,lt=1:5)
231 | plot(1,1,type="n",xlab="",ylab="",bty="n",axes=FALSE,xlim=c(-3,3),ylim=c(-3,3))
232 | abline(a=-2,b=tan(pi/4),lt=1)
233 | abline(a=-1,b=tan(pi/4),lt=2)
234 | abline(a=0,b=tan(pi/4),lt=3)
235 | abline(a=1,b=tan(pi/4),lt=4)
236 | abline(a=2,b=tan(pi/4),lt=5)

```

Príklad 129 (základy grafiky; dáta iris) *Nakreslite rozptylový graf dĺžky a šírky kališných lístkov pre všetky tri taxóny kosatcov pomocou (a) rôznych typov bodov a (b) rôznych farieb. Dokreslite do obrázku (c) regresné priamky pre každý taxón použitím rôzneho typu čiary. Pozri `help(iris)` ohľadom popisu premenných a ďalších detailov o dátach (Fisher, 1936/1971).*




Obr. 3.3: Základné typy čiar – zvislo, vodorovne a v uhle 45° (zľava doprava)

Riešenie v  (riešenie (a) pozri na obrázku 3.4)

```

237 irisDATA <- as.matrix(iris[,1:4]) # zmena datoveho ramca na maticu
238 dimnames(irisDATA)[[2]]
239 # [1] "Sepal.Length" "Sepal.Width"
240 # [3] "Petal.Length" "Petal.Width"
241 irisLABELS <- iris[,5]
242 levels(irisLABELS) # "setosa" "versicolor" "virginica"
243 plot(irisDATA[, "Sepal.Length"], irisDATA[, "Sepal.Width"]) # rozptylový graf
244 x.rozs <- range(irisDATA[, "Sepal.Length"]) # rozsah
245 y.rozs <- range(irisDATA[, "Sepal.Width"]) # rozsah
246 # typy bodov podľa skupin
247 windows(5,5)
248 par(mar=c(5,5,1,1))
249 plot(irisDATA[, "Sepal.Length"], irisDATA[, "Sepal.Width"], type="n", xlab="", ylab="", asp=1)
250 points(irisDATA[irisLABELS=="setosa", "Sepal.Length"], irisDATA[irisLABELS=="setosa", "Sepal.Width"], pch=16)
251 points(irisDATA[irisLABELS=="versicolor", "Sepal.Length"], irisDATA[irisLABELS=="versicolor", "Sepal.Width"],
252       pch=1)
253 points(irisDATA[irisLABELS=="virginica", "Sepal.Length"], irisDATA[irisLABELS=="virginica", "Sepal.Width"], pch=4)
254 legend("topright", c("setosa", "versicolor", "virginica"), text.font=3, pch=c(16,1,4), cex=1.2)
255 title(xlab="dĺzka_(cm)", ylab="šírka_(cm)", sub="kalíšne listky", cex.lab=1.5, cex.sub=1.5)
  
```



Obr. 3.4: Rozptylový graf pre dĺžku a šírku kališných lístkov

3.6.4 Kruhový diagram

Kruhový (výsekový, koláčový) diagram – zachytáva štruktúru dát takým spôsobom, že celá plocha kruhu predstavuje celý súbor a kruhové výseky jej jednotlivé časti, pričom polomery zvierajúce

uhol 3.6° vymedzujú plochu odpovedajúcu 1 % celého obsahu. Kruhový diagram nakreslíme pomocou funkcie `pie(x)`.


Argumenty funkcie `pie(x)`:

- `x` vektor relatívnych hodnôt (pravdepodobností), ktoré v súčte dávajú 1, teda i -ta položka bude $x[i]/\text{sum}(x)$ kruhu (ale aj početnosti); graf začína horizontálnou čiarou doprava a pokračuje proti smeru hodinových ručičiek;
- `names` vektor mien prislúchajúcich jednotlivým položkám grafu;
- `col` vektor farieb, ktorými sú jednotlivé položky vyfarbené;
- `labels="retazec"` – pomenovania kruhových výsekov.

Príklad 130 (kruhový diagram) Vytvorte kruhový diagram znázorňujúci pravdepodobnosti výskytu rôznych farieb vlasov so súčasným výskytom modrých očí (dáta z príkladu 126, tabuľka 3.9). Vytvorte rovnaký diagram v odtieňoch sivej farby (`gray()`).

Riešenie v \mathbb{R} (pozri obrázok 3.5)

```
256 | windows(4,4)
257 | par(mar=c(0,0,0,0))
258 | pie(oci.pravi[1,]) # nezobrazene
259 | pie(oci.pravi[1,], col=gray(seq(0.4,1.0, length=3)))
```




Obr. 3.5: Kruhový diagram (dáta oči vs. vlasy)

Príklad 131 (kruhový diagram) Nakreslite tiež kruhový diagram 24 (1) odtieňov sivej (`gray(sekvencia)`, kde sekvencia sú čísla z intervalu $(0, 1)$), (2) odtieňov farieb dúhy (`rainbow(k)`), (3) teplých farieb (`heat.colors(k)`) a (4) topografických farieb (`topo.colors(k)` alebo `terrain.colors(k)`).

Riešenie v \mathbb{R} (pozri obrázok 3.6)

```
260 | windows(4,4)
261 | par(mar=c(0,0,0,0))
262 | pie(rep(1,24), col=gray(seq(0.4,1.0, length=24)), radius=0.9)
263 | pie(rep(1,24), col=rainbow(24), radius=0.9) # nezobrazene
264 | pie(rep(1,24), col=heat.colors(24), radius=0.9) # nezobrazene
265 | pie(rep(1,24), col=topo.colors(24), radius=0.9) # nezobrazene
```



Obr. 3.6: Kruhový diagram (odtíene sivej)

3.6.5 Histogram

Histogram – predstavuje stĺpcový diagram s k stĺpcami, ktorých základňa sa rovná šírke intervalu $I_i = (x_i, x_{i+1})$ a výška i -teho stĺpca jeho početnosti ($i = 1, 2, \dots, k$). Zobrazuje početnosti pozorovaní v jednotlivých intervaloch v *absolútnej škále* (na osi y sú zobrazené početnosti) a v *relatívnej škále* (obsah histogramu je rovný jednej). Histogram možno opísať pomocou *frekvenčnej tabuľky*, ktorá obsahuje početnosti a relatívne početnosti. Množstvo intervalov volí príslušný štatistický softvér alebo aj sám užívateľ. Potrebných je aspoň 12 triednych intervalov (ich počet nesmie klesnúť pod 6). Šírka jedného je minimálne $h_{\min} = 0.08(x_{\max} - x_{\min})$. Musí obsahovať minimálne 5 meraní. *Počet tried* histogramu je rovný $k = \log_2 n + 1 \doteq 2 + 3.3 \log_{10} n$ (**Sturgesova formula**; Becker a kol. (1988)), intervaly sú definované ako $\langle x_0, x_1 \rangle, \langle x_1, x_2 \rangle, \dots, \langle x_{n-1}, x_n \rangle$. Šírka intervalov je teda $h = d_{\text{obs}} / (\log_2 n + 1)$ pre realizácie z *normálneho rozdelenia*. Teraz už vlastne nepracujeme s realizáciami x_i , ale so stredmi intervalov $x_i^* = (x_i + x_{i+1}) / 2$. Počty hodnôt n_i , ktoré sa v intervale I_i nachádzajú, sa nazývajú *triedne početnosti*. Pokiaľ realizácie nemajú normálne rozdelenie, treba použiť robustné algoritmy. Taktiež odľahlé pozorovania môžu dramaticky nafúknuť rozpätie, čo môže spôsobiť nárast šírky intervalov. Preto sa využívajú dva algoritmy ako kompromis medzi výchylkou (bias) a rozptylom realizácií pochádzajúcich z normálneho rozdelenia. Potom šírky triednych intervalov budú $h_1 = 3.49\hat{\sigma}n^{-1/3}$, $\hat{\sigma} = s$ (**Scottova formula**; Becker a kol. (1988)), $h_2 = 2d_Qn^{-1/3}$ (robustnejšia, **Freedman-Diaconisova formula**, ktorá je nezávislá od odľahlých pozorovaní a vyberá menšie intervaly ako Scottova formula; Venables a Ripley (2002)). Pre symetrické rozdelenia platí $h_3 = \lfloor 2\sqrt{n} \rfloor$ alebo $h_4 = \lfloor 2.46 \times (n - 1)^{0.4} \rfloor$. Pokiaľ sa neočakáva príliš zošikmené rozdelenie, je šírka triednych intervalov h konštantná. V prípade komplikovanejších tvarov výberových rozdelení treba zväčšiť počet triednych intervalov alebo použiť špeciálne postupy na hľadanie nekonštantne dlhých triednych intervalov (Meloun a Militký, 2004). Histogram nakreslíme pomocou funkcie `hist(x)`.


Argumenty funkcie **hist(x)**:

- `prob=FALSE` (prednastavená hodnota) – v **absolútnej škále**, kde na osi y sú početnosti;
- `prob=TRUE` – v **relatívnej škále** – suma obsahov stĺpcov (obdĺžnikov) je rovná jednej;
- `breaks="Sturges"` (**Sturgesova formula**, prednastavená hodnota), ďalšie možnosti sú "Scott" (**Scottova formula**) a "FD" alebo "Freedman-Diaconis" (**Freedman-Diaconisova formula**);
- `nclass=k`, $k \in \mathbb{N}$ – počet triednych intervalov;
- `plot=FALSE` – ak chceme vypísať číselné detaily, ale nechceme obrázok.

Príklad 132 (histogram a hustota normálneho rozdelenia) *Nakreslite histogram najväčšej dĺžky lebky (v mm) skull.L u mužov (dáta one-sample-mean-skull-mf.txt) a superponujte ho s (a) krivkou hustoty normálneho rozdelenia (plná čiara) a (b) krivkou hustoty vypočítanej z dát (empirická hustota; čiarkovaná čiara). Pod bázu histogramu nakreľte tzv. „koberec“, ktorý charakterizuje polohu realizácií.*

Riešenie v \mathbb{R} (pozri obrázok 3.7)

```
266 DATA <- read.table("one-sample-mean-skull-mf.txt", header=TRUE)
267 attach(DATA)
268 x <- na.omit(skull.L[sex=="m"]) # odstranenie chybajúceho pozorovania NA
269 priemer <- mean(x)
270 SD <- sd(x)
271 # 100 kvantilov od minima po maximum x a hodnoty hustoty v nich
272 kvant <- seq(min(x), max(x), length=100)
273 # doplnenie hustoty normálneho rozdelenia
274 hust <- dnorm(kvant, mean = priemer, sd=SD)
275 hist(x, ylim=c(0, range(hust)[2]), prob=TRUE, main="", xlab="x", ylab="hustota")
276 lines(kvant, hust, col="red", lwd=2)
277 # alternativne cez MC simuláciu
278 x.seq <- rnorm(100000, mean=mean(x), sd=sd(x))
279 lines(density(x.seq), lwd=2)
280 # koberec
281 rug(x)
```

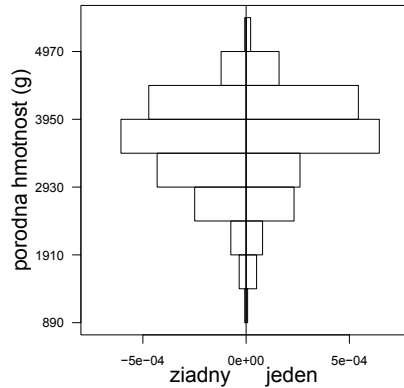


Obr. 3.7: Histogram so superponovanou krivkou hustoty normálneho rozdelenia (plná čiara) a hustoty vypočítanej z dát (empirická hustota; čiarkovaná čiara); pod histogramom je tzv. „koberec“

Príklad 133 (dva histogramy) *Nakreslite dva histogramy tak, aby sa svojimi bázami dotýkali. Aplikujte na dáta two-samples-means-birth.txt.*


Riešenie v \mathbb{R} (pozri obrázok 3.8; obe krivky hustoty sa prekrývajú)

```
282 DATA <- read.table("two-samples-means-birth.txt", header=TRUE)
283 names(DATA)
284 # [1] "o.sib.N" "birth.W"
285 attach(DATA) # zmena typu objektu na faktor
286 o.sib.N.faktor <- as.factor(o.sib.N) # hladiny faktora
287 # oznacenie hladin a ich zmena
288 levels(o.sib.N.faktor)
289 o.sib.N.faktor1 <- factor(o.sib.N.faktor, labels=c("ziadny", "jeden"))
290 rozsah <- range(birth.W)
291 library(Hmisc) # nactanie kniznice
292 windows(5,5)
293 par(mar=c(4.5, 4.5, 1, 1))
294 xx <- histbackback(split(birth.W, o.sib.N.faktor1), probability=TRUE, xlab="", ylab="", axes=FALSE)
295 title(ylab="porodna_hmotnost_(g)", cex.lab=1.5)
296 axis(1, cex.axis=0.9)
297 axis(2, at=seq(0.8, length=5), labels=seq(rozsah[1], rozsah[2], length=5), cex.axis=0.9, las=1)
298 mtext("ziadny", side=1, line=2, at=mean(xx$left), font=1, cex=1.5)
299 mtext("jeden", side=1, line=2, at=mean(xx$right), font=1, cex=1.5)
```



Obr. 3.8: Dva histogramy s priloženými bázami (základňami)

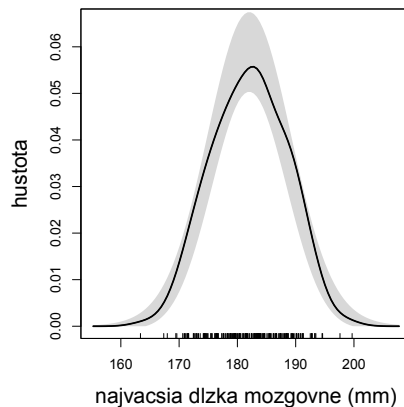
Príklad 134 (MC simulácia hustoty normálneho rozdelenia) Superponujte hustotu najväčšej dĺžky lebky (v mm) `skull.L` (dáta `one-sample-mean-skull-mf.txt`) s hustotou normálneho rozdelenia vypočítanou pomocou MC simulácie s 95% pásom spoľahlivosti normálneho rozdelenia so strednou hodnotou rovnou aritmetickému priemeru a rozptylom rovným výberovému rozptylu (Bowman a Azzalini, 1997).

Riešenie v  (pozri obrázok 3.9)

```

300 DATA <- read.table("one-sample-mean-skull-mf.txt", header=TRUE)
301 attach(DATA)
302 library(sm)
303 x <- na.omit(skull.L[sex=="m"])
304 yy <- sm.density(x, model="Normal")
305 windows(5,5)
306 par(mar=c(4.5,4.5,1,1))
307 sm.density(x, model="Normal", ylim=c(0,0.0655), xlab="", ylab="")
308 lines(yy$eval.points, yy$estimate, lwd=2)
309 title(xlab="najvacsia_dlzka_mozgovne_(mm)", ylab="hustota", cex.lab=1.5)

```



Obr. 3.9: Hustota so superponovanou hustotou normálneho rozdelenia v podobe 95% pásu spoľahlivosti

3.6.6 Empirická distribučná funkcia

Histogram kumulatívnych početností (súčtový histogram) – namiesto početností n_j budeme nad jednotlivými intervalmi I_i zakreslovať obdĺžniky s výškou rovnajúcou sa príslušným kumulatívnym početnostiam $N_i = \sum_{j=1}^i n_j$. Kumulatívne relatívne početnosti definujeme ako N_i/n , čomu zodpovedá **empirická distribučná funkcia**, definovaná pre zvolené číslo x ako relatívna početnosť v intervale $(-\infty, x)$, teda ako N_i -tina hodnôt x_i menších alebo rovných ako x , t.j. (Wasserman, 2006)

$$\hat{F}_n(x) = \frac{\#x_i \leq x}{n} = \sum_{i=1}^n I(x_i \leq x)/n,$$

kde $I(\cdot)$ je indikačná funkcia. Obrázok empirickej distribučnej funkcie nakreslíme pomocou funkcie `plot(ecdf(x), verticals = TRUE, do.points=FALSE)`.

Argumenty funkcie **plot(ecdf(x))**:

- `verticals=FALSE` je prednastavená hodnota; ak `verticals=TRUE`, je nakreslená schodovitá funkcia;
- `do.points=TRUE` je prednastavená hodnota; vkreslí do obrázka aj body, v ktorých je funkcia počítaná;
- `col.01line="gray70"` (prednastavená hodnota) – farba horizontálnych priamok v bodoch 0 a 1.

Príklad 135 (distribučná funkcia a hustota normálneho rozdelenia) *Nakreslite empirickú distribučnú funkciu najväčšej dĺžky lebky (v mm) skull.L u mužov (dáta one-sample-mean-skull-mf.txt) a superponujte ju s krivkou distribučnej funkcie normálneho rozdelenia červenou farbou.*

Riešenie v \mathbb{R} (pozri obrázok 3.10)

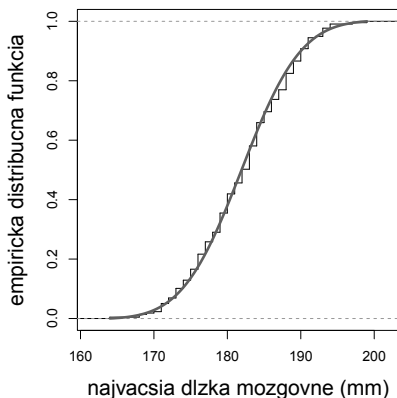
```
310 DATA <- read.table("one-sample-mean-skull-mf.txt", header=TRUE)
311 attach(DATA)
312 x <- na.omit(skull.L[sex=="m"])
313 priemer <- mean(x)
314 SD <- sd(x)
315 ROZP <- range(x)
316 # zoradených 200 hodnot (ekvidistantne) medzi min a max x
317 x1 <- seq(ROZP[1], ROZP[2], length=200)
318 # teoretická CDF (normálne rozdelenie)
319 y <- dnorm(x1, mean=priemer, sd=SD)
320 y <- cumsum(y)/sum(y)
321 # zobrazenie krivky distribučnej funkcie
322 # teoretického normálneho rozdelenia
323 windows(5, 5)
324 par(mar=c(5, 5, 1, 1))
325 plot(ecdf(x), verticals=TRUE, do.points=FALSE, xlab="najvacsia_dlzka_mozgovne_(mm)",
326      ylab="empiricka_distribucna_funkcia", main="", cex.lab=1.5)
327 lines(x1, y, col="red", lwd=3)
```

3.6.7 Krabicový diagram

Krabicový diagram – predstavuje grafické znázornenie päťčíselného súhrnu, t.j. zobrazuje v poradí zdola nahor hodnoty x_{\min}^* , $\tilde{x}_{0.25}$, $\tilde{x}_{0.50}$, $\tilde{x}_{0.75}$, x_{\max}^* . Umožňuje tiež doplnenie hodnoty aritmetického priemeru a tak zvýrazniť prípadné odchýlky od normality, identifikovať symetriu rozdelenia medzi kvartilmi, symetriu rozdelenia v koncoch rozdelenia, či odhaliť odľahlé pozorovania. Ak $\tilde{x}_{0.50} = \bar{x}$ ide o **symetrické rozdelenie**, ak $\tilde{x}_{0.50} < \bar{x}$, ide o **pravostranne zošikmené rozdelenie**, ak $\tilde{x}_{0.50} > \bar{x}$, ide o **ľavostranne zošikmené rozdelenie**. Často sa používa na grafické porovnanie dvoch a viacerých skupín. *Šírka krabíčiek* je proporčná k odmocnine z rozsahu výberového súboru \sqrt{n} . Ak hovoríme o **krabicových diagramoch so zárezom**, ide o zárez charakterizujúci 95% *empirický interval spoľahlivosti* (pozri kap. Testovanie hypotéz) mediánu $\tilde{\mu}$, ozn. (d, h) , kde

$$d = \tilde{x} - 1.57 \frac{d_Q}{\sqrt{n}}, h = \tilde{x} + 1.57 \frac{d_Q}{\sqrt{n}}.$$

Odhadom rozptylu mediánu je $\hat{\sigma}_{\tilde{x}}^2 = d_Q/1.349$, kde vo všeobecnosti platí (pre akékoľvek rozdelenie pravdepodobnosti), že $\sigma_{\tilde{x}}^2 = \frac{1}{4nf^2(\tilde{x})}$, kde f je hustota rozdelenia pravdepodobnosti (Casella a Berger,



Obr. 3.10: Emirická distribučná funkcia (schodovitá krivka) superponovaná krivkou distribučnej funkcie normálneho rozdelenia (hladká krivka)

2002). Pre normálne rozdelenie bude platiť $\sigma_{\tilde{x}}^2 = \sigma_x^2 \frac{\pi}{2n}$, kde $\tilde{X} \sim N(\tilde{\mu}, \sigma_{\tilde{x}}^2)$, pozri definíciu 30. Obrázok krabicového diagramu nakreslíme pomocou funkcie `boxplot(x)`.

Argumenty funkcie **boxplot(x)**:

- `varwidth` je argument relatívnej šírky jednotlivých krabičiek; prednastavená hodnota je `FALSE` s rovnakou šírkou všetkých krabičiek; ak ju zmeníme na `TRUE`, šírka krabičiek bude proporcionálna druhej odmocnine z počtu pozorovaní;
- `notch=TRUE` znamená zobrazenie zárezov krabičiek, ktoré odpovedajú 95% intervalom spoľahlivosti pre medián (prednastavená hodnota je `FALSE`);
- `col` určuje farbu vnútri krabičiek;
- `border` určuje farbu hraníc krabičiek;
- `names` je vektor pomenovaní pre jednotlivé zobrazované skupiny, ak ho vynecháme, použijú sa názvy z atribútu `names` z dátového rámca;
- `pch` typ bodu na zobrazenie odľahlých pozorovaní; prednastavená hodnota je 1;
- `horizontal=FALSE` je prednastavená hodnota;
- `plot=FALSE` – ak chceme iba vypísať číselné charakteristiky (prednastavená hodnota je `TRUE`).

Najčastejšie používanou kombináciou argumentov je `boxplot(x,varwidth=TRUE,notch=TRUE,otpch=16)`. Hodnoty aritmetického priemeru sa do krabicových diagramov dokresľujú pomocou príkazu `points(priemer, pch=16, col="red")`.

Príklad 136 (bodový graf a marginálne grafy) *Naprogramujte bodový graf dvoch premenných (1) s krabicovými diagramami a (2) histogramami pre marginálne dáta. Aplikujte na dáta `two-samples-correlations-trunk.txt`.*

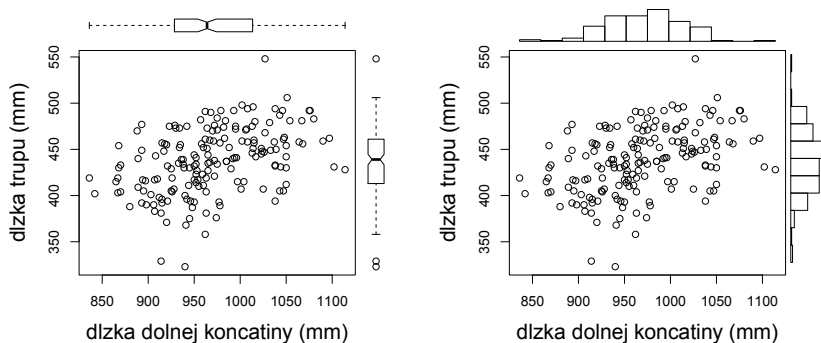
Riešenie v \mathbb{R} (pozri obrázok 3.11)

```
328 DATA <- read.table("two-samples-correlations-trunk.txt", header=TRUE)
329 names(DATA) # [1] "sex" "lowex.L" "tru.L"
330 attach(DATA)
331 windows(5,5)
332 par(fig=c(0,0.9,0,0.9))
333 plot(lowex.L, tru.L, xlab="dlzka_dolnej_koncatiny_(mm)", ylab="dlzka_trupu_(mm)")
334 par(fig=c(0,0.9,0.55,1), new=TRUE)
335 boxplot(lowex.L, horizontal=TRUE, axes=FALSE)
```

```

336 par(fig=c(0.65,1,0,0.9),new=TRUE)
337 boxplot(tru.L,axes=FALSE)
338
339 H <- hist(tru.L,plot=FALSE)
340 k1 <- 0
341 k2 <- 5
342 par(fig=c(0,0.9,0,0.9))
343 plot(lowex.L,tru.L,xlab="dĺzka_dolnej_koncatiny_(mm)",ylab="dĺzka_trupu_(mm)")
344 par(fig=c(0,0.9,0.55,1),new=TRUE)
345 plot(NULL,type="n",ylim=c(0,max(H$counts)+k1),xlim=c(range(H$breaks)),xlab="",ylab="",main="",bty="n",
346 axes=FALSE)
347 rect(H$breaks[1:(length(H$breaks)-1)]+k1,0+k1,H$breaks[2:length(H$breaks)]+k1,H$counts+k1)
348 par(fig=c(0.65,1,0,0.9),new=TRUE)
349 plot(NULL,type="n",xlim=c(0,max(H$counts)+k2),ylim=c(range(H$breaks)),xlab="",ylab="",main="",bty="n",
350 axes=FALSE)
351 rect(0+k2,H$breaks[1:(length(H$breaks)-1)]+k2,H$counts+k2,H$breaks[2:length(H$breaks)]+k2)

```



Obr. 3.11: Bodový graf s marginálnymi krabicovými diagramami (vľavo) a s histogramami (vpravo)

3.6.8 Kvantilový diagram


Kvantilový diagram (qq-diagram) – zobrazuje body so súradnicami $[\Phi^{-1}(i/(n+1)), x_{(i)}]$, kde $\Phi^{-1}(p)$ je kvantilová funkcia normovaného normálneho rozdelenia definovaná nasledovne

$$\Pr(Z \leq \Phi^{-1}(p)) = p.$$

Šikmosť $b_1 > 0$ sa prejaví v podobe **konvexného** usporiadania hodnôt, $b_1 < 0$ sa prejaví v podobe **konkávneho** usporiadania hodnôt. Taktiež zviditeľňuje **dĺžku „chvostov“** (ľavého a pravého konca krivky) rozdelenia, pričom **esovitým usporiadaním** bodov sa prejavujú krátke „chvosty“ a **inverzne esovitým usporiadaním** bodov dlhé „chvosty“. Zreteľná je tiež prípadná bimodalita rozdelenia. Štatisticky možno testovať normalitu rozdelenia pomocou simulácií z $N(0,1)$ a vytvorením 95% **Atkinsonovej obálky spoľahlivosti**. Pre normálne rozdelenie bude platiť $\sigma_{\tilde{x}_p}^2 = \sigma_x^2 \frac{\pi^2}{24 \ln n}$, kde $\tilde{X}_p \sim N(\tilde{\mu}_p, \sigma_{\tilde{x}_p}^2)$, pozri definíciu 29.

Kvantilový diagram vytvoríme pomocou funkcie `qqnorm(x)` a `qqline(x)`. Druhá funkcia dokreslí do grafu priamku prechádzajúcu bodmi charakterizujúcimi prvý a tretí kvartil teoretických a empirických kvantilov.


Príklad 137 (Atkinsonova obálka qq-diagramu) Nakreslite 95% Atkinsonovu obálku spoľahlivosti (Atkinson, 1981; Flack a Flores, 1989). Aplikujte na dáta výšky 10-ročných dievčat.

Riešenie v  (pozri obrázok 3.12)

```

353 library(car)
354 qqPlot(x, distribution="norm", xlab="kvantily_N(0,1)", ylab="kvantily_dat_",
355       main="", envelope=.95, col.lines="red", lwd=2, pch=16, cex=1, grid=FALSE)

```



Obr. 3.12: qq-diagram normovanej spojitej premennej výška 10-ročných dievčat (mm) so superponovanou obálkou normálneho rozdelenia

3.7 Príklady zo štatistickej grafiky

Príklad 138 (všetky základné grafy pre jeden výber ako funkcia) Do jedného obrázka 2×2 naprogramujte v \mathbb{R} štvoricu nasledovných grafov (1) histogram v relatívnej škále so superponovanou krivkou hustoty normálneho rozdelenia, (2) krabicový diagram so zakresleným priemerom, (3) empirickú (kumulatívnu) distribučnú funkciu superponovanú s teoretickou distribučnou funkciou normálneho rozdelenia a (4) qq-diagram so superponovanou qq-priamkou. Aplikujte na dáta výška 10-ročných dievčat.

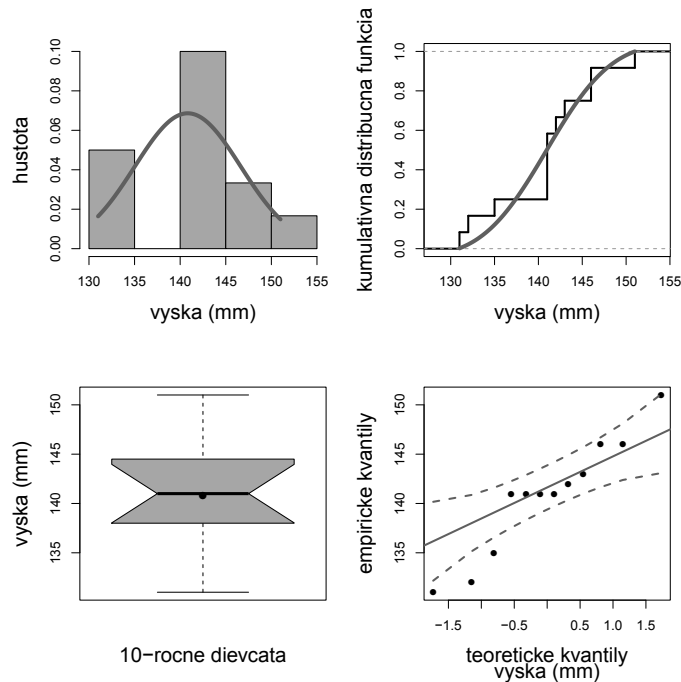
Riešenie v \mathbb{R} (pozri obrázok 3.13)

```

356 "grafy.jeden.vyber" <- function(x, name1="vyska_(mm)", name2="10-ročne_dievčata"){
357   require(car)
358   par(mfcol=c(2,2), mar=c(5,5,3,1)) # nastavenie typu okna a jeho okrajov
359   priemer <- mean(x)
360   SD <- sd(x)
361   kvant <- seq(min(x), max(x), length=100)
362   hust <- dnorm(kvant, priemer, SD)
363   ROZP <- range(x)
364   y1 <- seq(ROZP[1], ROZP[2], length=200)
365   y <- dnorm(y1, mean=mean(y1), sd=sd(y1))
366   y <- cumsum(y)/sum(y)
367   # histogram a teoretická hustota
368   hist(x, prob=TRUE, main="", xlab=name1, ylab="hustota", col="gray", cex.lab=1.5)
369   lines(kvant, hust, col="red", lwd=4)
370   # krabicový diagram
371   boxplot(x, varwidth=TRUE, notch=TRUE, outpch=16, xlab=name2, ylab=name1, col="gray", cex.lab=1.5)
372   points(priemer, pch=16, cex=1.2)
373   # empirická a teoretická CDF
374   plot(ecdf(x), verticals=TRUE, do.points=FALSE, lwd=2, main="", xlab=name1, ylab="kumulatívna_distribučna_funkcia",
375        cex.lab=1.5)
376   lines(y1, y, col="red", lwd=4)
377   # kvantilový diagram
378   qqPlot(x, distribution="norm", main="", xlab="", ylab="", envelope=.95, col.lines="red", lwd=2, pch=16, cex=1, grid=
379         FALSE)
380   title(sub=name1, xlab="teoreticke_kvantily", ylab="empiricke_kvantily", cex.lab=1.5, cex.sub=1.5)
381 }
382 # graf
383 windows(7,7)
384 par(mar=c(5,5,1,1))
385 grafy.jeden.vyber(x)

```

Príklad 139 (všetky základné grafy pre dva výbery ako funkcia) V \mathbb{R} naprogramujte do jedného obrázka 1×3 trojicu nasledovných grafov (1) superponované krivky hustôt, (2) superponované krivky empirických (kumulatívnych) distribučných funkcií, (3) krabicové diagramy so zakresleným priemerom. Aplikujte na dáta two-samples-means-birth.txt.




Obr. 3.13: Základná štvorica grafov pre spojitú premennú výška 10-ročných dievčat (mm) – hustota (vľavo hore), kumulatívna distribučná funkcia (vpravo hore), krabicový diagram (vľavo dole), kvantilový diagram s Atkinsonovou obálkou (vpravo dole)

Riešenie v (pozri obrázok 3.14)

```

384 | "grafy.dva.vybery" <- function(x1,x2,name1="ziadny",name2="jeden",name3="porodna_hmotnost_(g)") {
385 |   hust.1 <- density(x1)$y
386 |   x1.sekv <- density(x1)$x
387 |   CDF.1 <- cumsum(hust.1)/sum(hust.1)
388 |   hust.2 <- density(x2)$y
389 |   x2.sekv <- density(x2)$x
390 |   CDF.2 <- cumsum(hust.2)/sum(hust.2)
391 |   obe.sekv <- c(x1.sekv,x2.sekv)
392 |   obe.hust <- c(hust.1,hust.2)
393 |   obe.CDF <- c(CDF.1,CDF.2)
394 |   ## dve hustoty
395 |   par(mfcol=c(1,3),mar=c(5,5,1,1))
396 |   plot(obe.sekv,obe.hust,type="n",xlab=name3,ylab="hustota",cex.lab=1.5,cex.axis=1.2)
397 |   lines(x1.sekv,hust.1,lty=1,lwd=2)
398 |   lines(x2.sekv,hust.2,lty=2,lwd=2)
399 |   legend("topright",c(name1,name2),lty=c(1,2),lwd=2,cex=1.2)
400 |   ## dve CDF
401 |   plot(obe.sekv,obe.CDF,type="n",xlab=name3,ylab="kumulativna_distribucna_funkcia",cex.lab=1.5,cex.axis=1.2)
402 |   lines(x1.sekv,CDF.1,lty=1,lwd=2)
403 |   lines(x2.sekv,CDF.2,lty=2,lwd=2)
404 |   legend("bottomright",c(name1,name2),lty=c(1,2),lwd=2,cex=1.2)
405 |   x <- c(x1,x2)
406 |   kod <- factor(c(rep(name1,length(x1)),rep(name2,length(x2))),labels=c(name1,name2),levels=c(name1,name2))
407 |   ## dva krabicove diagramy
408 |   boxplot(x~kod,ylab=name3,varwidth=TRUE,notch=TRUE,pch=16,cex=1.2,cex.lab=1.5,cex.axis=1.5)
409 |   priem <- tapply(x,kod,mean)
410 |   points(priem,pch=16,cex=1.2)
411 | }
412 | # grafy
413 | DATA <- read.table("two-samples-means-birth.txt",header=TRUE)
414 | names(DATA) # [1] "o.sib.N" "birth.W"
415 | attach(DATA)
416 | o.sib.N.faktor <- as.factor(o.sib.N) # zamena typu objektu na faktor
417 | levels(o.sib.N.faktor) # kontrola hladin faktora
418 | windows(12,4)
419 | grafy.dva.vybery(birth.W[o.sib.N.faktor==0],birth.W[o.sib.N.faktor==1])

```



Obr. 3.14: Základná trojica grafov pre pôrodnú hmotnosť `birth.W` (dáta `two-samples-means-birth.txt`) – hustoty (vľavo), kumulatívne distribučné funkcie (uprostred), krabicové diagramy (vpravo)

Príklad 140 (stĺpcový diagram) (a) Vypočítajte podmienené pravdepodobnosti (pre každý riadok kontingenčnej tabuľky); t.j. za predpokladu súčinnového multinomického rozdelenia. Premennú v riadkoch budeme označovať X (prediktor) a premennú v stĺpcoch ako Y (závisle premenná).

- (1) Y : farba dúhovky, X : radiálne útvary v štruktúre dúhovky (dáta: `multinom-iris-color.txt`),
- (2) Y : zakončenie troch hlavných dlaňových línií, X : farba vlasov (dáta: `multinom-palmar-lines.txt`),
- (3) Y : príľahlosť ušného laloka, X : pohlavie (dáta: `multinom-earlobe.txt`),
- (4) Y : krvná skupina, X : mesto (dáta: `multinom-blood-groups.txt`).

(b) Nakreslite stĺpcové diagramy podmienených pravdepodobností pre (1) až (4).

Príklad 141 (štatistická grafika) Nakreslite (1) histogram v relatívnej škále so superponovanou krivkou hustoty normálneho rozdelenia, (2) krabicový diagram so zakresleným priemerom, (3) empirickú (kumulatívnu) distribučnú funkciu superponovanú s teoretickou distribučnou funkciou normálneho rozdelenia a (4) qq-diagram so superponovanou qq-priamkou pre nasledujúce premenné: (a) stranový rozdiel vertikálneho priemeru diaľfýzy kľúčnej kosti (`simd.R` a `simd.L`; v mm) na pravej a ľavej strane tela (dáta: `paired-means-clavicle2.txt`), (b) najväčšia výška mozgovne (`skull.pH`; v mm; dáta: `one-sample-correlation-skull-mf.txt`), (c) morfológická výška tváre (`face.H`; v mm; dáta: `one-sample-correlation-skull-mf.txt`).

Príklad 142 (bodový graf a krabicové diagramy) Nakreslite bodový graf spolu s krabicovými diagramami pre marginálne dáta pre premenné vertikálny priemer diaľfýzy kľúčnej kosti na pravej a ľavej strane tela (`simd.R` a `simd.L`; v mm; dáta: `paired-means-clavicle2.txt`).

Príklad 143 (bodový graf a krabicové diagramy) Nakreslite bodový graf spolu s krabicovými diagramami pre marginálne dáta pre (a) premenné najväčšia výška mozgovne (`skull.pH`; v mm) a morfológická výška tváre (`face.H`; v mm) a (b) ich z -skóre (dáta: `one-sample-correlation-skull-mf.txt`).

Príklad 144 (krabicové diagramy) Nakreslite krabicové diagramy pre obe pohlavia pre nasledovné premenné: (a) dĺžky lebky (`skull.H`; v mm; sex; dáta: `two-samples-means-skull.txt`), (b) dĺžka dolnej končatiny (`lowex.L`; v mm; sex; dáta: `two-samples-correlations-trunk.txt`), (c) dĺžka trupu (`tru.L`; v mm; sex; dáta: `two-samples-correlations-trunk.txt`), (d) najväčšia dĺžka kľúčnej kosti pravej strany (`cla.L`; v mm; population; dáta: `more-samples-variances-clavicle.txt`).

4 Testovanie hypotéz

Aby sme mohli z dát vyvodit' nejaké interpretovateľné závery, musíme najprv ciele (účely, biologicky formulované hypotézy) výskumu preformulovať do matematicko-štatistickej podoby. Takáto formulácia je dôležitá pri výbere správneho modelu na dáta. V prípade parametrického modelu máme jeho parametre θ , kde hypotézy sú o týchto parametroch. Jednou hypotézou je tzv. nulová hypotéza, čo je tvrdenie o θ , ktoré testujeme prostredníctvom nejakého **štatistického testu**. Ďalšou je alternatívna hypotéza, ktorá je doplnkom nulovej hypotézy v priestore, z ktorého pochádza θ . Na základe výsledku testu vyvodíme záver o θ . Proces testovania hypotéz nazývame aj **štatistická inferencia**, ktorej základom je **štatistická teória testovania hypotéz**.

Definícia 32 (štatistický test) Ak parametrický priestor Θ , do ktorého patrí parameter θ modelu \mathcal{F} , rozdelíme na dve podmnožiny Θ_0 a Θ_1 , kde $\Theta = \Theta_0 \cup \Theta_1$, potom **štatistický test** $T = T(X)$ predstavuje funkciu X z výberového priestoru \mathcal{Y} do priestoru $\Theta_0 \cup \Theta_1$. Štatistický test je teda pravidlo výberu jednej z dvoch možností, nulovej a alternatívnej, na základe dát. **Nulovú hypotézu** definujeme ako $H_0 : \theta \in \Theta_0$ a **alternatívnu hypotézu** ako $H_1 : \theta \in \Theta_1$. Prvky množiny \mathcal{Y} , pre ktoré nezamietame H_0 , predstavujú tzv. **oblasť (obor) nezamietania nulovej hypotézy**. Tieto prvky označujeme $\mathcal{Y}_0 = \mathcal{A}_T = \mathcal{A}$. V tomto prípade H_0 nezamietame. Prvky množiny \mathcal{Y} , pre ktoré zamietame H_0 , predstavujú tzv. **oblasť (obor) zamietania nulovej hypotézy** alebo **kritickú oblasť**. Tieto prvky označujeme $\mathcal{Y}_1 = \mathcal{W}_T = \mathcal{W}$. V tomto prípade H_0 zamietame. Rozdelenie priestoru Θ na obor zamietania \mathcal{W}_T a nezamietania \mathcal{A}_T prebieha na základe **testovacej štatistiky** $T(X)$.

Stretávame sa s nasledovnými štyrmi možnosťami:

- A) ak platí H_0 , tak naše rozhodnutie je nezamietnuť H_0 (správne);
- B) ak platí H_0 , tak naše rozhodnutie je zamietnuť H_0 (nesprávne);
- C) ak neplatí H_0 , tak naše rozhodnutie je nezamietnuť H_0 (nesprávne);
- D) ak neplatí H_0 , tak naše rozhodnutie je zamietnuť H_0 (správne).

V prípade B, C je naše rozhodnutie nesprávne, v prípade A, D správne. V prípade B sa dopúšťame **chyby prvého druhu** (CHPD), kde $\Pr(\text{CHPD}) \leq \alpha$ a α sa nazýva **hladina významnosti**. Doplnok ku α je pravdepodobnosť $1 - \alpha$ a nazýva sa **koeficient spoľahlivosti** (príp. A). V prípade C sa dopúšťame **chyby druhého druhu** (CHDD), kde $\Pr(\text{CHDD}) = \beta$. Doplnok ku $\Pr(\text{CHDD})$ je pravdepodobnosť $1 - \beta$ a nazýva sa **sila testu** (pri nejakej alternatívnej; príp. D). Sila testu závisí na zvolenej testovacej metóde a hlavne na tom, aké je skutočné rozdelenie náhodnej premennej X , aký je typ použitej testovacej štatistiky alebo aké sú skutočné hodnoty parametrov θ .

Teda

rozhodnutie/skutočnosť	H_0 platí	H_0 neplatí
H_0 nezamietnuť	správne rozhodnutie	chyba II. druhu
H_0 zamietnuť	chyba I. druhu	správne rozhodnutie

Vyššie uvedené pravdepodobnosti môžeme zosumarizovať nasledovne:

- A) $1 - \alpha \leq \Pr(\text{nezamietni } H_0 | H_0 \text{ platí}) = \Pr(\text{nezamietni } H_0 | H_1 \text{ neplatí});$
- B) $\alpha \geq \Pr(\text{CHPD}) = \Pr(\text{zamietni } H_0 | H_0 \text{ platí}) = \Pr(\text{zamietni } H_0 | H_1 \text{ neplatí});$
- C) $\beta = \Pr(\text{CHDD}) = \Pr(\text{nezamietni } H_0 | H_0 \text{ neplatí}) = \Pr(\text{nezamietni } H_0 | H_1 \text{ platí});$
- D) $1 - \beta = \Pr(\text{zamietni } H_0 | H_0 \text{ neplatí}) = \Pr(\text{zamietni } H_0 | H_1 \text{ platí}).$

V prípade (A) a (B) hovoríme o teste na hladine významnosti α (α -level test). Ak v (A) a (B) nahradíme znamienko nerovnosti rovnosťou, hovoríme o teste úrovne α (size α test). Test $T(\mathbf{x})$ charakterizujeme jeho **silofunkciou** $\beta^*(\theta) = 1 - \beta(\theta) = \Pr(\theta \in \Theta : T(\mathbf{x}) = \Theta_1)$. Táto je závislá na θ a niekoľkých iných argumentoch (vždy sú špecifikované pri konkrétnych testoch) ako aj na type alternatívnej hypotézy. **Hladinu významnosti** α je možné definovať tiež pomocou $\beta^*(\theta)$, kde $\alpha = \sup_{\theta \in \Theta_0} \beta^*(\theta)$, t.j. ide o najväčšiu možnú pravdepodobnosť chyby I. druhu.

Hladina významnosti α je daná (určená štatistikom, experimentátorom) vopred, testovacia štatistika $T(\mathbf{x})$ sa vypočíta na základe realizácií (odpovedí) x náhodnej premennej X , kritická hodnota (alebo kvantil) sa nájde v štatistických tabuľkách alebo ju vypočítame pomocou \mathbb{R} .

V praxi teda voľba \mathcal{W} závisí na požiadavke, aby pravdepodobnosť chyby I. druhu bola menšia alebo rovná zvolenému kladnému číslu α , kde $\alpha \in (0, 1/2)$, najčastejšie $\alpha = 0.05, 0.01$ alebo 0.001 . Súčasne volíme \mathcal{W} tak, aby pravdepodobnosť chyby I. druhu bola čo najmenšia. Optimálne by sme chceli mať $\beta^*(\theta)$ (pri nejakej hodnote θ) tak veľké číslo (bližšie sa jednotke) ako je možné, keď $\theta \in \Theta_1$ a také malé číslo, keď $\theta \in \Theta_0$. Tieto dve požiadavky sú v konflikte, t.j.

- zväčšovanie oboru nezamietania H_0 znižuje pravdepodobnosť chyby I. druhu, ale zväčšuje pravdepodobnosť chyby II. druhu;
- znižovanie oboru nezamietania H_0 zväčšuje pravdepodobnosť chyby I. druhu, ale znižuje pravdepodobnosť chyby II. druhu.

Extrémnymi prípadmi sú dve situácie, kde $\mathcal{T}_0(\mathbf{x}) = \Theta_0$ a $\mathcal{T}_1(\mathbf{x}) = \Theta_1$, t.j. každý z týchto dvoch testov je najlepší možný, keď θ patrí určitej podmnožine Θ , ale najhorší možný v opačnom prípade.


Klasickým prístupom k tejto dileme je **Neyman-Pearsonov prístup**, kde dopredu fixujeme α a vyberieme taký test, ktorý má pri danej alternatíve najväčšiu silu $1 - \beta$ pre $\theta \in \Theta_1$ medzi všetkými možnými na teoreticky stanovenej (danej, nominálnej) hladine významnosti α . Testy spomínané v kapitolách 5 až 8 sú najsilnejšími testami pri daných alternatívach za určitých predpokladov (bližšie pozri kap. 5 až 8). V reálnych situáciách (alebo často aj za porušenie predpokladov testov) sa nominálna hladina významnosti líši od aktuálnej (skutočnej) hladiny významnosti (pozri definíciu 42).

Definícia 33 (kvantil) *Nech F_X je distribučná funkcia náhodnej premennej X a $\alpha \in (0, 1)$, kde $F_X(x_{1-\alpha}) = 1 - \alpha$. Potom číslo $x_{1-\alpha} = x(1 - \alpha) = F_X^{-1}(1 - \alpha)$ sa nazýva α -kvantil príslušného rozdelenia. Pre vybrané rozdelenia platí*

- $\Pr(X < u_{1-\alpha}) = 1 - \alpha$, kde $x_{1-\alpha} = u_{1-\alpha}$ pre $X \sim N(0, 1)$ (**normálne rozdelenie s parametrami $\mu = 0$ a $\sigma^2 = 1$; hovorí sa mu aj normálne normované rozdelenie alebo štandardizované normálne rozdelenie**);
- $\Pr(X < \chi_{df}^2(1 - \alpha)) = 1 - \alpha$, kde $x_{1-\alpha} = \chi_{df}^2(1 - \alpha)$ pre $X \sim \chi_{df}^2$ (**chi-kvadrát rozdelenie s df stupňami voľnosti**);
- $\Pr(X < t_{df}(1 - \alpha)) = 1 - \alpha$, kde $x_{1-\alpha} = t_{df}(1 - \alpha)$ pre $X \sim t_{df}$ (**Studentovo t -rozdelenie s df stupňami voľnosti**);
- $\Pr(X < F_{df_1, df_2}(1 - \alpha)) = 1 - \alpha$, kde $x_{1-\alpha} = F_{df_1, df_2}(1 - \alpha)$ pre $X \sim F_{df_1, df_2}$ (**Fisherovo F -rozdelenie s df_1 a df_2 stupňami voľnosti**).

Hustoty vyššie spomenutých rozdelení pozri na obrázku 4.1. Tiež platí

- $\Pr(x_{\alpha/2} < X < x_{1-\alpha/2}) = F_X(x_{1-\alpha/2}) - F_X(x_{\alpha/2}) = 1 - \alpha$, kde $\alpha \in (0, 1)$;
- $\Pr(X < Q_1) = 1/4$, kde $Q_1 = F_X^{-1}(1/4)$ sa nazýva **výberový prvý kvartil (dolný kvartil)**;
- $\Pr(X < Q_2) = 1/2$, kde $Q_2 = F_X^{-1}(1/2)$ sa nazýva **výberový druhý kvartil (medián)**;
- $\Pr(X < Q_3) = 3/4$, kde $Q_3 = F_X^{-1}(3/4)$ sa nazýva **výberový tretí kvartil (horný kvartil)**;
- $Q_d = F_X^{-1}(k/10)$ sa nazýva **výberový k -ty decil**, $Q_p = F_X^{-1}(k/100)$ sa nazýva **výberový k -ty percentil**.



Obr. 4.1: Grafické znázornenie hustôt normálneho rozdelenia, t -rozdelenia, χ^2 -rozdelenia a F -rozdelenia pri rôznych stupňoch voľnosti

Definícia 34 (kritická hodnota) *Kritická hodnota príslušného rozdelenia je hodnota x_α^* , ktorú náhodná premenná X prekročí s pravdepodobnosťou α . Pre vybrané rozdelenia platí*

- $\Pr(X > u_\alpha) = \alpha$, kde $x_\alpha^* = u_\alpha$ pre $X \sim N(0,1)$; $u(\alpha)$ sa často zapisuje ako u_α ;
- $\Pr(X > \chi_{df}^2(\alpha)) = \alpha$, kde $x_\alpha^* = \chi_{df}^2(\alpha)$ pre $X \sim \chi_{df}^2$;
- $\Pr(X > t_{df}(\alpha)) = \alpha$, kde $x_\alpha^* = t_{df}(\alpha)$ pre $X \sim t_{df}$;
- $\Pr(X > F_{df_1, df_2}(\alpha)) = \alpha$, kde $x_\alpha^* = F_{df_1, df_2}(\alpha)$ pre $X \sim F_{df_1, df_2}$.

Z vyššie uvedeného je zreteľné, že $\alpha \times 100\%$ kritická hodnota je identická s $(1 - \alpha) \times 100\%$ kvantilom. Pri kritickvej hodnote počítame obsah pod krivkou hustoty príslušného rozdelenia nad týmto bodom a pri kvantile pod týmto bodom.


Stupne voľnosti df predstavujú množstvo nezávislej informácie, ktoré potrebujeme na charakterizáciu rozdelenia pravdepodobnosti nejakej náhodnej premennej. Používajú sa aj namiesto n ako prevencia pred nadhodnotením odhadu nejakého parametra (napr. rozptylu). Ide najčastejšie o rozsah náhodného výberu n zmenšený o jedna (napr. Studentovo t -rozdelenie, F -rozdelenie), kde jednotka odpočítaná od n znamená jeden voľne viazaný parameter (napr. jedna stredná hodnota, jeden rozptyl a pod.). Pri zložitejších modeloch s viacerými parametrami odpočítame od n počet voľne viazaných parametrov (napr. počet stredných hodnôt) alebo df môže tiež predstavovať počet hladín kategoriálnej premennej zmenšený o počet voľne viazaných parametrov.

Príklad 145 (štandardizované normálne rozdelenie) *Vypočítajte kritické hodnoty $u(\alpha)$ rozdelenia $N(0,1)$, kde $\alpha = 0.1, 0.05, 0.01, 0.025$ a 0.005 .*

Riešenie v \mathbb{R} (pozri obrázok 4.2 a 4.3)

```
420 | qnorm(1-0.1) # 1.281552
421 | qnorm(1-0.05) # 1.644854
422 | qnorm(1-0.01) # 2.326348
423 | qnorm(1-0.025) # 1.959964
424 | qnorm(1-0.005) # 2.575829
```

Na výpočet pravdepodobnosti pod kvantilom sa používa funkcia `pnorm(Q)`. Na výpočet pravdepodobnosti nad kritickou hodnotou sa používa funkcia `1-pnorm(Q)`. Keďže štandardizované normálne rozdelenie je symetrické okolo nuly, $u(\alpha) = u(1 - \alpha)$.



Obr. 4.2: Grafické znázornenie významu pravdepodobnosti pod krivkou rozdelenia medzi dvoma kvantilmi (normálne rozdelenie)

Príklad 146 (Studentove t -rozdelenie) Vypočítajte kritické hodnoty Studentovho t -rozdelenia so stupňami voľnosti $df = 10$, t.j. $t_{df}(\alpha)$, kde $\alpha = 0.1, 0.05, 0.01, 0.025$ a 0.005 .

Riešenie v \mathbb{R} (pozri obrázok 4.4)

```

425 | qt(1-0.1,10) # 1.372184
426 | qt(1-0.05,10) # 1.812461
427 | qt(1-0.01,10) # 2.763769
428 | qt(1-0.025,10) # 2.228139
429 | qt(1-0.005,10) # 3.169273

```

Na výpočet pravdepodobnosti pod kvantilom sa používa funkcia $\text{pt}(Q,df)$. Na výpočet pravdepodobnosti nad kritickou hodnotou sa používa funkcia $1-\text{pt}(Q,df)$. Keďže Studentovo t -rozdelenie je symetrické okolo nuly, $t_{df}(\alpha) = t_{df}(1 - \alpha)$. Nejaký kvantil t -rozdelenia je približne rovný kvantilu štandardizovaného normálneho rozdelenia až pre veľmi veľké stupne voľnosti (resp. pravdepodobnosti nad kritickými hodnotami sú približne rovnaké). Napr. $1-\text{pnorm}(1.644854) \approx 1-\text{pt}(1.644869,100000) = 0.05$. Avšak napr. $1-\text{pt}(1.644869,100) \doteq 0.052$.

Príklad 147 (χ^2 -rozdelenie) Vypočítajte kritické hodnoty χ^2 -rozdelenia so stupňami voľnosti $df = 10$, t.j. $\chi_{df}^2(\alpha)$, kde $\alpha = 0.1, 0.05, 0.01, 0.025$ a 0.005 .

Riešenie v \mathbb{R} (pozri obrázok 4.5)

```

430 | qchisq(1-0.1,10) # 15.98718
431 | qchisq(1-0.05,10) # 18.30704
432 | qchisq(1-0.01,10) # 23.20925
433 | qchisq(1-0.025,10) # 20.48318
434 | qchisq(1-0.005,10) # 25.18818

```

Na výpočet pravdepodobnosti pod kvantilom alebo nad kritickou hodnotou sa používa $\text{pchisq}(Q,df)$. Keďže χ^2 -rozdelenie nie je symetrické, $\chi_{df}^2(\alpha) \neq \chi_{df}^2(1 - \alpha)$.

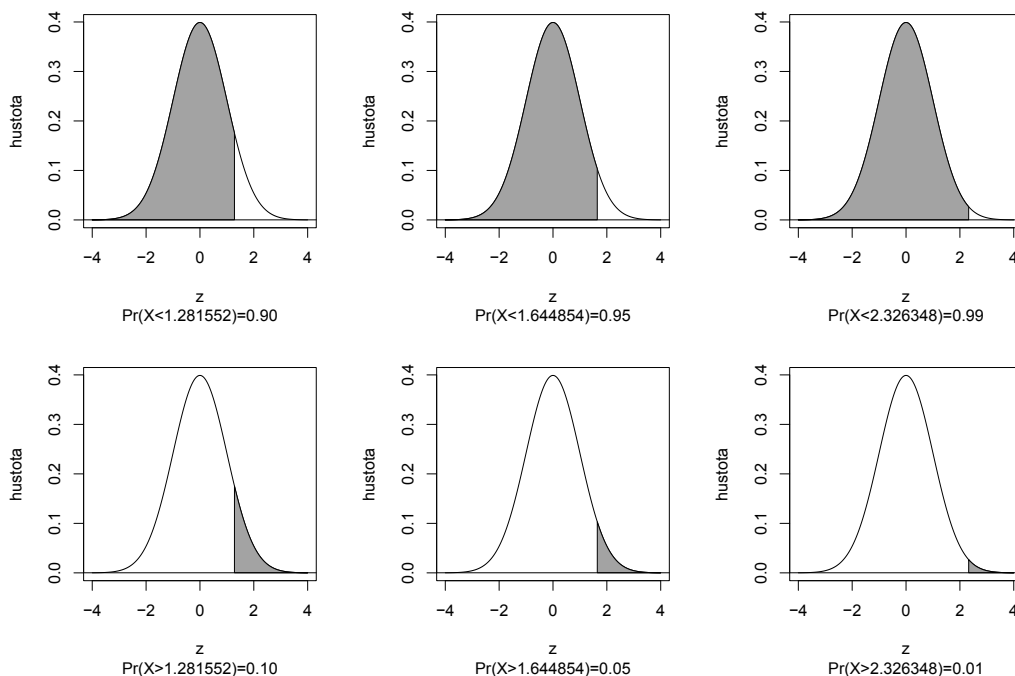
Príklad 148 (F -rozdelenie) Vypočítajte kritické hodnoty F -rozdelenia so stupňami voľnosti $df_1 = 20$ a $df_2 = 20$, t.j. $F_{df_1,df_2}(\alpha)$, kde $\alpha = 0.1, 0.05, 0.01, 0.025$ a 0.005 .

Riešenie v \mathbb{R} (pozri obrázok 4.6)

```

435 | qf(1-0.1,20,20) # 1.793843
436 | qf(1-0.05,20,20) # 2.124155
437 | qf(1-0.01,20,20) # 2.937735
438 | qf(1-0.025,20,20) # 2.464484
439 | qf(1-0.005,20,20) # 3.317786

```



Obr. 4.3: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou normálneho rozdelenia; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

Na výpočet pravdepodobnosti pod kvantilom sa používa funkcia $\text{pf}(Q, \text{df}_1, \text{df}_2)$. Na výpočet pravdepodobnosti nad kritickou hodnotou sa používa funkcia $1 - \text{pf}(Q, \text{df}_1, \text{df}_2)$. Keďže F -rozdelenie nie je symetrické, $F_{\text{df}_1, \text{df}_2}(\alpha) \neq F_{\text{df}_1, \text{df}_2}(1 - \alpha)$.

4.1 *Asymptotické vlastnosti odhadov

Štatistická inferencia o θ_* sa vykonáva na základe odhadu $\hat{\theta} = \hat{\theta}_n$, kde n v dolnom indexe zdôrazňuje pri akom rozsahu náhodného výberu je odhad θ počítaný (index n sa často vynecháva). Podobne štatistická inferencia o $g(\theta_*)$ sa vykonáva na základe odhadu $g(\hat{\theta}_n)$. **Bodový odhad** parametrickej funkcie $g(\theta)$ je štatistika $T_n = T(X_1, X_2, \dots, X_n)$ nadobúdajúca hodnoty blízko $g(\theta)$. Nech $T_n = g(\hat{\theta}_n)$ je nejaký odhad $g(\theta)$, podobne $T_n = \hat{\theta}_n$ je nejaký odhad θ . Potom môžeme definovať nasledovné typy konvergencií pre T_n (čo platí aj pre $g(\theta) = \theta$):

1. *Konvergencia skoro všade*

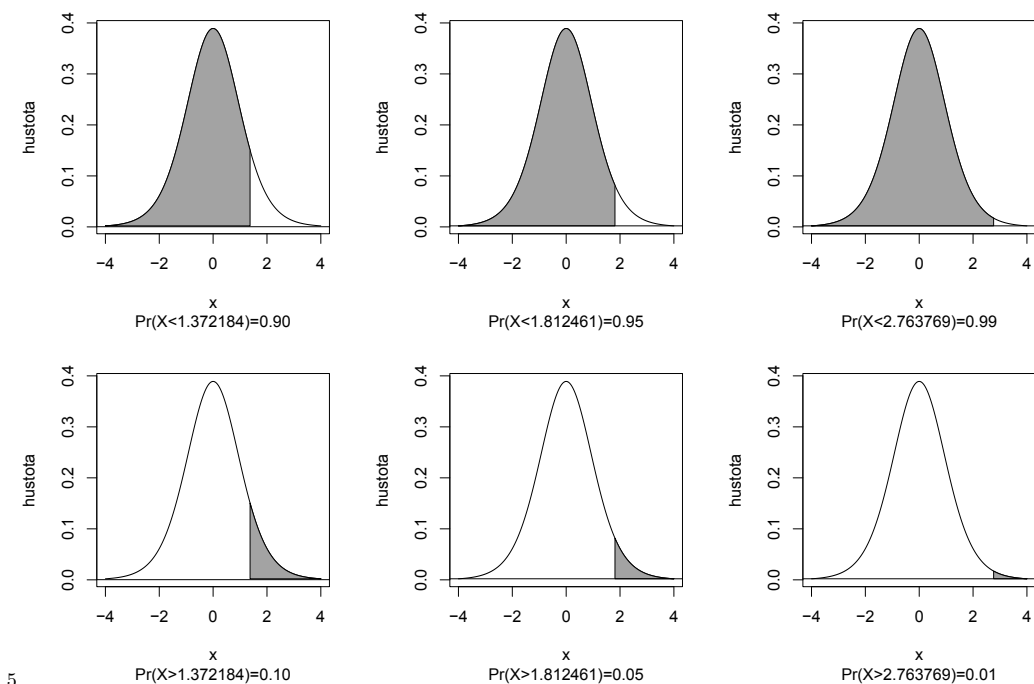
$$\Pr \left(\lim_{n \rightarrow \infty} T_n = g(\theta) \right) = 1, \text{ pre } \forall \theta \in \Theta,$$

2. *Konvergencia v kvadratickom strede*

$$T_n \xrightarrow{n \rightarrow \infty} g(\theta) \Leftrightarrow E_{\theta} \left[(T_n - g(\theta))^2 \right] \xrightarrow{n \rightarrow \infty} 0, \text{ pre } \forall \theta \in \Theta,$$

3. *Konvergencia podľa pravdepodobnosti* (ozn. „ $\xrightarrow{\mathbb{P}}$ “)

$$\lim_{n \rightarrow \infty} (\Pr (|T_n - g(\theta)| \geq \varepsilon)) = 0, \text{ pre } \varepsilon > 0, \text{ pre } \forall \theta \in \Theta,$$



Obr. 4.4: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou t -rozdelenia s $df = 10$; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

4. Konvergencia v distribúcii (ozn. „ $\overset{\mathcal{D}}{\sim}$ “)

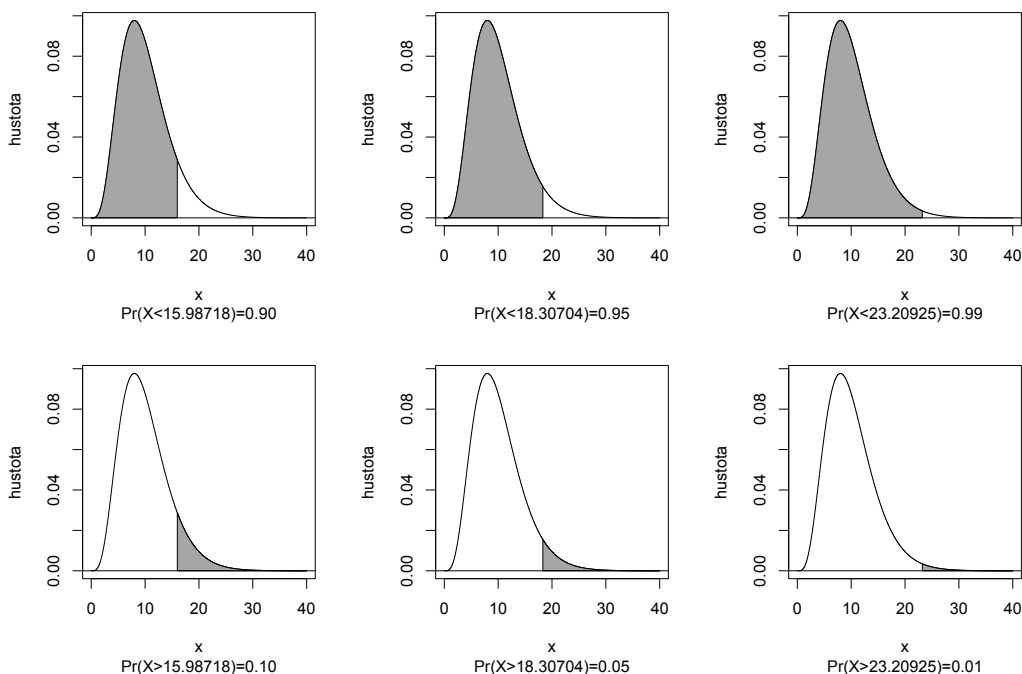
$$\lim_{n \rightarrow \infty} F_n(x) = F_X(x)$$

vo všetkých bodoch x , kde $F_n(x)$ je empirická distribučná funkcia a $F_X(x)$ je spojitá distribučná funkcia.

Pozn.: Z konvergencie skoro všade vyplýva konvergencia v kvadratickom strede, z konvergencie v kvadratickom strede vyplýva konvergencia podľa pravdepodobnosti.

Nech X_1, X_2, \dots, X_n je náhodný výber z rozdelenia F_* , $g(\theta)$ je parametrická funkcia a T_n , T_1 a T_2 sú štatistiky, $E[T_n]$ je stredná hodnota a $Var[T_n]$ rozptyl štatistiky T_n . Potom

1. hovoríme, že štatistika T_n je **nevychýlený odhad** parametrickej funkcie $g(\theta)$, ak $E[T_n] = g(\theta), \forall \theta \in \Theta$, t.j. odhad T_n nesmie parametrickú funkciu *systematicky nadhodnocovať* alebo *podhodnocovať* – ak táto podmienka nie je splnená, hovoríme o **vychýlenom odhade**;
2. ak T_1, T_2 sú dva nevychýlené odhady tej istej parametrickej funkcie $g(\theta)$, potom T_1 je **lepší odhad** $g(\theta)$ ako T_2 , ak $Var[T_1] < Var[T_2], \forall \theta \in \Theta$, t.j. ak existuje odhad s menším rozptylom, je potrebné ho v štatistickej inferencii použiť namiesto odhadu s väčším rozptylom (to môžeme docieľiť optimalizáciou dizajnu experimentu vhodnou voľbou bodov, v ktorých budeme merať);
3. T_n sa nazýva **asymptoticky nevychýlený odhad** $g(\theta)$, ak platí $\lim_{n \rightarrow \infty} E[T_n] = g(\theta)$, t.j. s rastúcim rozsahom náhodného výberu n , klesá vychylka odhadu (to môžeme docieľiť optimalizáciou dizajnu experimentu vhodnou voľbou n);
4. T_n sa nazýva **konzistentný odhad** $g(\theta)$, ak platí $\lim_{n \rightarrow \infty} \Pr(|T_n - g(\theta)| \geq \epsilon) = 0$, t.j. s rastúcim rozsahom náhodného výberu n klesá pravdepodobnosť, že odhad sa bude reali-



Obr. 4.5: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou χ^2 -rozdelenia s $df = 10$; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

zovať ďaleko od $g(\theta)$ (to môžeme doceliť optimalizáciou dizajnu experimentu vhodnou voľbou n);

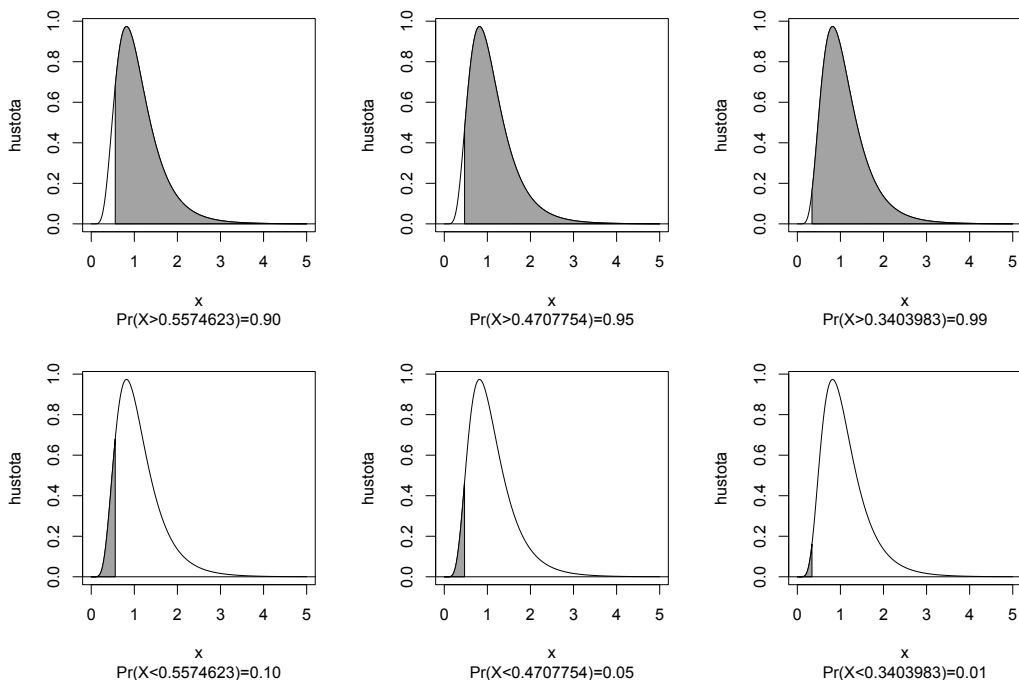
5. T_n sa nazýva **konzistentný a asymptoticky efektívny (eficientný, výdatný) odhad** $g(\theta)$, ak platí

$(T_n - g(\theta)) \stackrel{\mathcal{D}}{\sim} N(0, C(g(\theta)))$, kde \mathcal{D} znamená „v distribúcii“, $C(g(\theta))$ je Raova-Cramerova spodná hranica definovaná ako $C(g(\theta)) = -\frac{[g'(\theta)]^2}{E_{\theta}[\frac{\partial^2}{\partial \theta^2} \ln L(\theta|\mathbf{x})]} = \frac{[g'(\theta)]^2}{ni(\theta)}$, kde $i(\theta)$ je Fisherova miera informácie jedného pozorovania, $L(\theta|\mathbf{x})$ je funkcia vierohodnosti (táto vlastnosť sa používa pri testovaní hypotéz ako predpoklad asymptotického rozdelenia testovacej štatistiky za predpokladu normality rozdelenia X);

6. T_n sa nazýva **asymptoticky normálny odhad** $g(\theta)$, ak platí $\frac{T_n - g(\theta)}{\sqrt{C(g(\theta))}} \stackrel{\mathcal{D}}{\sim} N(0, 1)$ (táto vlastnosť sa tiež používa pri testovaní hypotéz ako predpoklad asymptotického rozdelenia testovacej štatistiky za predpokladu normality rozdelenia X).

Z nevyčýlenosti odhadu vyplýva jeho asymptotická nevyčýlenosť a z asymptotickej nevyčýlenosti vyplýva konzistencia, ak $\lim_{n \rightarrow \infty} Var[T_n] = 0$. Implikáciou bodu (6) je $T_n \stackrel{\mathcal{D}}{\sim} N(g(\theta), \frac{[g'(\theta)]^2}{ni(g(\theta))})$, kde $ni(g(\theta)) = \mathcal{I}(g(\theta))$. Ak $g(\theta) = \theta$, potom $T_n \stackrel{\mathcal{D}}{\sim} N(\theta, \frac{1}{ni(\theta)})$, kde $ni(\theta) = \mathcal{I}(\theta)$. Ak $k > 1$, potom je θ vektor a môžeme písať

$$\sqrt{n} \left(g(\hat{\theta}_n) - g(\theta) \right) \stackrel{\mathcal{D}}{\sim} N_k \left(\mathbf{0}, \Delta^T (i(\theta))^{-1} \Delta \right),$$



Obr. 4.6: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou F -rozdelenia s $df_1 = 20$ a $df_2 = 20$; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

kde $\Delta = \frac{\partial}{\partial \boldsymbol{\theta}} g(\boldsymbol{\theta})$. Ak $g(\boldsymbol{\theta}) = \boldsymbol{\theta}$, potom

$$\sqrt{n}(\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}) \stackrel{\mathcal{D}}{\sim} N_k(\mathbf{0}, (i(\boldsymbol{\theta}))^{-1}).$$

Veta 6 (vlastnosti odhadu) *Nech náhodná premenná X pochádza z normálneho rozdelenia s parametrami μ a σ^2 , $X \sim N(\mu, \sigma^2)$, kde $E[X] = \mu$ je stredná hodnota a $\text{Var}[X] = \sigma^2$ je rozptyl náhodnej premennej X . Potom výberový aritmetický priemer $\bar{X}_n = \bar{X}$ je nevychýleným odhadom μ a výberový rozptyl $S_{n-1}^2 = S^2$ je nevychýleným odhadom σ^2 ($n-1$ v dolnom indexe S_{n-1}^2 znamená počet stupňov voľnosti). Zároveň platí, že \bar{X} a S^2 sú asymptoticky nevychýlené, konzistentné, asymptoticky efektívne a asymptoticky normálne. Preto môžeme písať nasledovné*

$$\sqrt{n}(\bar{X}_n - \mu) \stackrel{\mathcal{D}}{\sim} N(0, \sigma^2), \text{ čo je ekvivalentné } \bar{X}_n \stackrel{\mathcal{D}}{\sim} N\left(\mu, \frac{\sigma^2}{n}\right).$$

a

$$\sqrt{n}(S_n^2 - \sigma^2) \stackrel{\mathcal{D}}{\sim} N(0, 2\sigma^4), \text{ kde } S_n^2 = \frac{n-1}{n} S_{n-1}^2.$$

Tiež môžeme písať

$$\sqrt{n}(S_{n-1}^2 - \sigma^2) \stackrel{\mathcal{D}}{\sim} \sqrt{n}\sigma^2 \left(\frac{\chi_{n-1}^2}{n-1} - 1\right) \text{ a } \sqrt{n}(S_n^2 - \sigma^2) \stackrel{\mathcal{D}}{\sim} \sqrt{n}\sigma^2 \left(\frac{\chi_{n-1}^2}{n} - 1\right),$$

čo je ekvivalentné $(n-1) \frac{S_{n-1}^2}{\sigma^2} \stackrel{\mathcal{D}}{\sim} \chi_{n-1}^2$ a $n \frac{S_n^2}{\sigma^2} \stackrel{\mathcal{D}}{\sim} \chi_{n-1}^2$. Potom môžeme písať nasledovné

$$\sqrt{n}(\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}) \stackrel{\mathcal{D}}{\sim} N_2(\mathbf{0}, \boldsymbol{\Sigma}),$$

kde $\hat{\theta}_n = (\bar{X}_n, S_n^2)^T$, $\theta = (\mu, \sigma^2)^T$, $\mathbf{0} = (0, 0)^T$ a $\Sigma = \text{diag}(\sigma^2, 2\sigma^4)$. Na tomto mieste ale treba zdôrazniť, že n použité pri odhadovaní musí byť dostatočne veľké, zvyčajne sa uvádza $n > 30$. Realizáciou \bar{X} je \bar{x} a realizáciou S^2 je s^2 .

S_{n-1}^2 je nevychýlený odhad σ^2 , S_n^2 (maximálne vierohodný odhad σ^2) je vychýlený odhad σ^2 a bude v priemere σ^2 podceňovať. Avšak priemerná kvadratická chyba (MSE) je pre S_n^2 menšia ako pre S_{n-1}^2 . MSE sa ale nemôže používať ako kritérium pre parameter škály (čo je σ^2), pretože MSE penalizuje odhad rovnako pre podcenenie ako aj precenenie odhadu (pre parameter polohy, ako je μ , je MSE vhodným kritériom).

Definícia 35 Nech dvojrozmerná náhodná premenná $(X_1, X_2)^T$ pochádza z dvojrozmerného normálneho rozdelenia s parametrami μ a Σ , $(X_1, X_2)^T \sim N_2(\mu, \Sigma)$, kde $\mu = (\mu_1, \mu_2)^T$, $\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{pmatrix}$, $\sigma_{12} = \sigma_{21} = \rho\sigma_1\sigma_2$, $E[X_1] = \mu_1$ je stredná hodnota a $\text{Var}[X_1] = \sigma_1^2$ je rozptyl náhodnej premennej X ; $E[X_2] = \mu_2$ je stredná hodnota a $\text{Var}[X_2] = \sigma_2^2$ je rozptyl náhodnej premennej Y . Potom aritmetické priemery \bar{X}_j ($j = 1, 2$) sú nevychýlené odhady μ_j a výberové rozptyly S_j^2 sú nevychýlenými odhadmi σ_j^2 . Zároveň platí, že \bar{X}_j a S_j^2 sú asymptoticky nevychýlené, konzistentné, asymptoticky efektívne a asymptoticky normálne. Ďalej platí, že výberová kovariancia S_{12} je nevychýleným odhadom σ_{12} , ako aj, že je asymptoticky nevychýlený, konzistentný, asymptoticky efektívny a asymptoticky normálny odhad. Na tomto mieste ale treba zdôrazniť, že n použité pri odhadovaní musí byť dostatočne veľké, zvyčajne sa uvádza $n > 30$. Avšak $E[R_{12}]$ sa rovná ρ len približne (zhoda nastane až pre $n > 30$). Navyše píšeme, že R_{12} je nevychýleným odhadom ρ . Zároveň platí, že R_{12} je asymptoticky nevychýlený a konzistentný. Realizáciou S_{12} je s_{12} a realizáciou R_{12} je r .

Veta 7 (koeficient variácie) Nech náhodná premenná X pochádza z normálneho rozdelenia s parametrami μ a σ^2 , $X \sim N(\mu, \sigma^2)$, kde $E[X] = \mu$ je stredná hodnota a $\text{Var}[X] = \sigma^2$ je rozptyl náhodnej premennej X . Nech $g(\theta) = \sigma/\mu$, kde $\theta = (\mu, \sigma^2)^T$, $g(\hat{\theta}_n) = \frac{S_n}{\bar{X}_n}$ a $\Delta = \frac{\partial}{\partial \theta} g(\theta) = \left(-\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu}\right)^T$. Potom

$$\sqrt{n} \left(\frac{S_n}{\bar{X}_n} - \frac{\sigma}{\mu} \right) \overset{\mathcal{D}}{\sim} N_k \left(0, \Delta^T (i(\theta))^{-1} \Delta \right),$$

$$\text{kde } \Delta^T (i(\theta))^{-1} \Delta = \left(-\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu}\right) \begin{pmatrix} \sigma^2 & 0 \\ 0 & 2\sigma^4 \end{pmatrix} \begin{pmatrix} -\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \end{pmatrix}^T = \frac{\sigma^2}{\mu^2} \left(\frac{\sigma^2}{\mu^2} + \frac{1}{2} \right).$$

4.2 Interval spoľahlivosti Waldovho typu

Intervalový odhad parametrickej funkcie $g(\theta)$ je interval (D, H) , ktorého hranice sú štatistiky $D(X_1, X_2, \dots, X_n)$ a $H(X_1, X_2, \dots, X_n)$. Tento intervalový odhad nazývame $100 \times (1 - \alpha)\%$ **interval spoľahlivosti** (IS), kde číslo $1 - \alpha$ je **koeficient spoľahlivosti**. O tomto intervale môžeme dosť spoľahlivo prehlásiť, že obsahuje skutočnú (neznámu) hodnotu parametra $g(\theta)$, čo tvrdíme s primeraným stupňom dôvery (s dostatočne veľkou pravdepodobnosťou).

Rozlišujeme nasledovné IS: **dvojstranné** (DIS), kde pre DIS sú dolná hranica D a horná hranica H vytvorené tak, aby platilo

$$\Pr(D \leq g(\theta) \leq H) = 1 - \alpha, \text{ pre } \forall \theta \in \Theta$$

a **jednostranné** (JIS), kde pre JIS volíme konkrétnu hranicu tak, aby mohlo dôjsť iba k podceneniu alebo preceneniu neznámeho parametra, tj. aby platilo

$$\Pr(D_* \leq g(\theta)) = 1 - \alpha, \text{ pre } \forall \theta \in \Theta,$$

$$\Pr(g(\theta) \leq H^*) = 1 - \alpha, \text{ pre } \forall \theta \in \Theta.$$


Empirický IS dostaneme použitím kritických hodnôt rozdelenia $g(\hat{\theta})$, parametra $g(\hat{\theta})$ a jeho štandardnej chyby $SE[g(\hat{\theta})]$. Postup pri jeho konštrukcii je nasledovný (postup je pre DIS, podobný je aj pre JIS; pozri napr. Budíková a kol. (2010)):

1. majme štatistiku T_n , ktorá je nevychýleným bodovým odhadom parametrickej funkcie $g(\theta)$;
2. vypočítame **pivotovú štatistiku (pivot)** T_{piv} , ktorá je transformáciou štatistiky T_n , je monotónnou funkciou $g(\theta)$, poznáme jej rozdelenie, ktoré je nezávislé na $g(\theta)$; pomocou známeho rozdelenia pivota T_{piv} , nájdeme kritické hodnoty¹ $t_{\alpha/2}$ a $t_{1-\alpha/2}$, potom $\Pr(t_{1-\alpha/2} < T_{\text{piv}} < t_{\alpha/2}) = 1 - \alpha$;
3. nerovnosť $t_{1-\alpha/2} < T_{\text{piv}} < t_{\alpha/2}$ transformujeme ekvivalentnými úpravami na $D < g(\theta) < H$;
4. štatistiky D a H nahradíme ich realizáciami d a h a získame tak $100 \times (1 - \alpha)\%$ **empirický IS**, o ktorom prehlásime, že pokrýva $g(\theta)$ s pravdepodobnosťou aspoň $1 - \alpha$, t.j. ak mnohonásobne nezávisle získame realizácie x_1, x_2, \dots, x_n náhodného výberu X_1, X_2, \dots, X_n z nejakého rozdelenia F_* a pomocou tejto realizácie zostrojíme $100 \times (1 - \alpha)\%$ empirické IS pre $g(\theta)$, potom podiel počtu týchto intervalov, ktoré pokrývajú $g(\theta)$ a počtu všetkých zostrojených intervalov (tých, čo pokrývajú a aj tých, čo nepokrývajú $g(\theta)$) bude približne $1 - \alpha$.

Príklad 149 *Nech náhodný výber X_1, X_2, \dots, X_n pochádza z normálneho rozdelenia s parametrami μ a σ^2 , t.j. $X \sim N(\mu, \sigma^2)$, potom štatistika $T_n = \bar{X}$, $T_{\text{piv}} = \frac{\bar{X} - \mu}{\sigma} \sqrt{n}$ (kde σ je známe), kritické hodnoty rozdelenia $N(0, 1)$ pivota sú rovné $t_{\alpha/2} = u_{\alpha/2}$, $t_{1-\alpha/2} = -u_{1-\alpha/2} = -u_{\alpha/2}$, Potom $100 \times (1 - \alpha)\%$ empirický IS je (D, H) , kde $D = \bar{X} - u_{\alpha/2}\sigma/\sqrt{n}$ a $H = \bar{X} + u_{\alpha/2}\sigma/\sqrt{n}$. Ak dosadíme za \bar{X} odhad \bar{x} , dostaneme $100 \times (1 - \alpha)\%$ empirický IS, kde $d = \bar{x} - u_{\alpha/2}\sigma/\sqrt{n}$ a $h = \bar{x} + u_{\alpha/2}\sigma/\sqrt{n}$.*

Príklad 150 (MC experiment pre IS) *Nech (a) $X \sim N(0, 1)$ a (b) $X \sim [pN(0, 1) + (1-p)N(0, 4)]$, kde $p = 0.9$, t.j. ide o zmes dvoch normálnych rozdelení $X \sim N(0, 1)$ a $X \sim N(0, 4)$ v pomere 9:1. Vygenerujte $M = 100$ náhodných výberov s rozsahom $n = 500$ a vypočítajte Waldove $100(1 - \alpha)\%$ empirický IS pre μ . Zistite, koľko IS obsahuje strednú hodnotu $\mu = 0$. Toto číslo podelené M predstavuje simulovanú hladinu významnosti α .*

Riešenie v \mathbb{R} (pozri obrázok 4.7)



Obr. 4.7: MC experiment pre IS (IS, ktoré neobsahujú $\mu = 0$, sú označené hrubou čiarou); vľavo $X \sim N(0, 1)$ a vpravo $X \sim [0.9N(0, 1) + (1 - 0.9)N(0, 4)]$

```

440 | M <- 100
441 | n <- 500
442 | var.mix <- priemery.mix <- priemery <- array(0,M)
443 | DH.mix <- DH <- array(0,M)
444 | HH.mix <- HH <- array(0,M)

```

¹ $t_{\alpha/2}$ nie sú kritické hodnoty Studentovho t -rozdelenia, ale kritické hodnoty rozdelenia T_{piv} .

```

445 prav <- 0.1
446 i <- 0
447 while (i < M) {
448   i <- i + 1
449   priemery[i] <- mean(rnorm(n))
450   simul.mix <- rnorm(n,0.1+rbinom(n,1,prav))
451   priemery.mix[i] <- mean(simul.mix)
452   var.mix[i] <- var(simul.mix)
453   DH[i] <- priemery[i] + qnorm(0.025)*sqrt(1/n)
454   HH[i] <- priemery[i] + qnorm(0.975)*sqrt(1/n)
455   DH.mix[i] <- priemery.mix[i] + qnorm(0.025)*sqrt(var.mix[i]/n)
456   HH.mix[i] <- priemery.mix[i] + qnorm(0.975)*sqrt(var.mix[i]/n)
457 }
458 "interval.plot" <- function(y1,y2,xlab){
459   n <- length(y1)
460   plot(y1,type="n",ylim=c(-.3,.3),xlab=xlab,ylab="intervaly spoľahlivosti")
461   podmienka <- (y1 <= 0 & y2 >= 0)
462   segments((1:n)[y1 < 0 & y2 > 0],y1[y1 < 0 & y2 > 0],(1:n)[y1 < 0 & y2 > 0],y2[y1 < 0 & y2 > 0])
463   segments((1:n)[y1 > 0],y1[y1 > 0],(1:n)[y1 > 0],y2[y1 > 0],lwd=4,col="black")
464   segments((1:n)[y2 < 0],y1[y2 < 0],(1:n)[y2 < 0],y2[y2 < 0],lwd=4,col="black")
465   SUM <- sum(podmienka)
466   title(sub=paste("pocet IS obsahujucich",SUM))
467   abline(h=0)
468 }
469 windows(8,4)
470 par(mfcol=c(1,2))
471 interval.plot(DH,HH,xlab="N(0,1)")
472 interval.plot(DH.mix,HH.mix,xlab="0.9_N(0,1)_+_(1-0.9)N(0,4)")

```

Všeobecne empirický IS pre θ zostrojíme na základe $\widehat{\theta}$ a $\widehat{SE}[\widehat{\theta}]$, ak je $\text{Var}[\widehat{\theta}]$ neznáme alebo $SE[\widehat{\theta}]$, ak je $\text{Var}[\widehat{\theta}]$ známe (v praxi je často neznáme). **Šírka empirického IS** pre θ (niekedy sa používa aj pojem **dĺžka empirického IS pre θ**) je definovaná ako $d(d, h)$, kde $d(\cdot, \cdot)$ je Euklidovská vzdialenosť. Potom platí

- ak sa spoľahlivosť $1 - \alpha$ zvyšuje (hladina významnosti α klesá), šírka IS rastie ($\widehat{SE}[\widehat{\theta}]$ resp. $SE[\widehat{\theta}]$ a n sú fixované, konštatné);
- ak sa spoľahlivosť $1 - \alpha$ znižuje (hladina významnosti α rastie), šírka IS klesá ($\widehat{SE}[\widehat{\theta}]$ resp. $SE[\widehat{\theta}]$ a n sú fixované, konštatné);
- ak rozsah n rastie, šírka IS klesá ($\widehat{SE}[\widehat{\theta}]$ resp. $SE[\widehat{\theta}]$ a α sú fixované);
- ak rozsah n klesá, šírka IS rastie ($\widehat{SE}[\widehat{\theta}]$ resp. $SE[\widehat{\theta}]$ a α sú fixované);
- ak $\widehat{SE}[\widehat{\theta}]$ resp. $SE[\widehat{\theta}]$ rastie, tak šírka IS rastie (α a n sú fixované);
- ak $\widehat{SE}[\widehat{\theta}]$ resp. $SE[\widehat{\theta}]$ klesá, tak šírka IS klesá (α a n sú fixované).

Ak sa šírka empirického IS zvyšuje, hovoríme, že neistota o parametri θ rastie. Ak sa šírka empirického IS znižuje, hovoríme, že neistota o θ klesá.

Podobne môžeme uvažovať aj o parametrickej funkcii $g(\theta)$ a jej empirickom IS.

4.3 Testovanie H_0 oproti H_1

Definícia 36 (Obor nezamietania H_0) *Nech X je náhodná premenná z nejakého rozdelenia, ktoré závisí na parametri $\theta \in \Theta$, $g(\theta)$ je parametrická funkcia. Testujme nulovú hypotézu $H_{01} : g(\theta) = g(\theta_0)$ oproti obojstrannej alternatíve $H_{11} : g(\theta) \neq g(\theta_0)$. Nech (D, H) je intervalový odhad parametrickej funkcie $g(\theta)$ so spoľahlivosťou $1 - \alpha$. Potom*

$$\mathcal{A}_{IS,1} = \{D, H; g(\theta_0) \in (D, H)\}$$

je obor nezamietania testu H_{01} oproti H_{11} na hladine významnosti α . Ak máme testovať $H_{02} : g(\theta) \leq g(\theta_0)$ oproti jednostrannej (pravostrannej) alternatíve $H_{12} : g(\theta) > g(\theta_0)$ a ak D_ je dolný odhad pre $g(\theta)$ so spoľahlivosťou $1 - \alpha$, potom*

$$\mathcal{A}_{IS,2} = \{D_*; D_* < g(\theta_0)\}$$

je **obor nezamietania testu** H_{02} **oproti** H_{12} **na hladine významnosti** α . Ak máme testovať $H_{03} : g(\theta) \geq g(\theta_0)$ **oproti jednostrannej (ľavostrannej) alternatíve** $H_{13} : g(\theta) < g(\theta_0)$ a ak H^* je horný odhad pre $g(\theta)$ so spoľahlivosťou $1 - \alpha$, potom

$$\mathcal{A}_{IS,3} = \{H^*; H^* > g(\theta_0)\}$$

je **obor nezamietania testu** H_{03} **oproti** H_{13} **na hladine významnosti** α .

Definícia 37 (Obor zamietania H_0 (kritický obor)) Nech X je náhodná premenná z nejakého rozdelenia, ktoré závisí na parametri $\theta \in \Theta$, $g(\theta)$ je parametrická funkcia. Testujme nulovú hypotézu $H_{01} : g(\theta) = g(\theta_0)$ **oproti obojstrannej alternatíve** $H_{11} : g(\theta) \neq g(\theta_0)$. Nech (D, H) je intervalový odhad parametrickej funkcie $g(\theta)$ so spoľahlivosťou $1 - \alpha$. Potom

$$\mathcal{W}_{IS,1} = \{D, H; g(\theta_0) \notin (D, H)\}$$

je **kritický obor testu** H_{01} **oproti** H_{11} **na hladine významnosti** α . Ak máme testovať $H_{02} : g(\theta) \leq g(\theta_0)$ **oproti jednostrannej (pravostrannej) alternatíve** $H_{12} : g(\theta) > g(\theta_0)$ a ak D_* je dolný odhad pre $g(\theta)$ so spoľahlivosťou $1 - \alpha$, potom

$$\mathcal{W}_{IS,2} = \{D_*; D_* \geq g(\theta_0)\}$$

je **kritický obor testu** H_{02} **oproti** H_{12} **na hladine významnosti** α . Ak máme testovať $H_{03} : g(\theta) \geq g(\theta_0)$ **oproti jednostrannej (ľavostrannej) alternatíve** $H_{13} : g(\theta) < g(\theta_0)$ a ak H^* je horný odhad pre $g(\theta)$ so spoľahlivosťou $1 - \alpha$, potom

$$\mathcal{W}_{IS,3} = \{H^*; H^* \leq g(\theta_0)\}$$

je **kritický obor testu** H_{03} **oproti** H_{13} **na hladine významnosti** α .

Definícia 38 (Testovacie kritérium) **Testovacím kritériom** nazveme testovaciu štatistiku $T = T_0 = T_0(X_1, X_2, \dots, X_n)$, ktorej asymptotické rozdelenie za platnosti H_0 poznáme. Množina hodnôt, ktoré môže T_0 nadobúdať sa delí na dve podmnožiny, a to **obor nezamietania** H_0 (ozn. \mathcal{A}) a **obor zamietania** H_0 (kritický obor, ozn. \mathcal{W}). Tieto dva obory sú oddelené **kritickými hodnotami** $t_{\alpha/2}$ a $t_{1-\alpha/2}$, resp. t_α a $t_{1-\alpha}$ (podľa typu H_0 a H_1) rozdelenia testovacej štatistiky T_0 (za platnosti H_0).

Testovanie H_0 oproti H_1 je rozhodovací postup založený na náhodnom výbere X_1, X_2, \dots, X_n , pomocou ktorého zamietame alebo nezamietame H_0 . Všeobecne zaužívaný postup je nasledovný:

1. stanovíme H_0 a H_1 ,
2. zvolíme hladinu významnosti α ,
3. zvolíme vhodné testovacie kritérium T_0 ,
4. zamietneme/nezamietneme H_0 jedným z troch ekvivalentných spôsobov
 - pomocou kritického oboru $\mathcal{W} = \mathcal{W}_T$ (a realizácie $t_0 = t_{\text{obs}}$),
 - pomocou kritického oboru \mathcal{W}_{IS} , t.j. empirického intervalu spoľahlivosti (a $g(\theta_0)$),
 - pomocou p-hodnoty.

Definícia 39 (Testovanie pomocou kritického oboru \mathcal{W}) **Zamietanie** H_0 . Ak realizácia t_0 testovacej štatistiky T_0 spadá do kritického oboru \mathcal{W} (ekvivalentne nespadá do oboru nezamietania \mathcal{A}), zamietame H_0 na hladine významnosti α a znamená to, že máme dostatok dôkazov na zamietnutie H_0 . **Nezamietanie** H_0 . Ak realizácia t_0 testovacej štatistiky T_0 spadá do oboru nezamietania \mathcal{A} (ekvivalentne nespadá do kritického oboru \mathcal{W}), nezamietame H_0 na hladine významnosti α a znamená to, že nemáme dostatok dôkazov na zamietnutie H_0 .

Stanovenie kritického oboru. Ak t_{\min} je najmenšia hodnota testovacieho kritéria T_0 a t_{\max} je najväčšia hodnota testovacieho kritéria T_0 , ktoré môže teoreticky nadobúdať, potom

1. **obojsstranná alternatíva** – kritický obor $\mathcal{W}_1 = (t_{\min}, t_{1-\alpha/2}) \cup (t_{\alpha/2}, t_{\max})$,
2. **jednostranná (pravostranná) alternatíva** – kritický obor $\mathcal{W}_2 = (t_{\alpha}, t_{\max})$,
3. **jednostranná (ľavostranná) alternatíva** – kritický obor $\mathcal{W}_3 = (t_{\min}, t_{1-\alpha})$.

Definícia 40 (Testovanie pomocou intervalu spoľahlivosti) *Zamietanie* H_0 : Ak IS neobsahuje $g(\theta) = g(\theta_0)$ (za platnosti H_0), zamietame H_0 na hladine významnosti α a znamená to, že máme dostatok dôkazov na zamietnutie H_0 . *Nezamietanie* H_0 : Ak IS obsahuje $g(\theta) = g(\theta_0)$ (za platnosti H_0), nezamietame H_0 na hladine významnosti α a znamená to, že nemáme dostatok dôkazov na zamietnutie H_0 .

Použitie $100(1 - \alpha)\%$ IS pre $g(\theta)$ je nasledovné

1. **obojsstranný IS**, ak ide o obojsstrannú hypotézu,
2. **jednostranný (ľavostranný, dolný) IS**, ak ide o jednostrannú (pravostrannú) alternatívu,
3. **jednostranný (pravostranný, horný) IS**, ak ide o jednostrannú (ľavostrannú) alternatívu.

Definícia 41 (Testovanie pomocou pozorovanej hladiny významnosti alebo p-hodnoty) Minimálnu hladinu významnosti α (pre nejakú vypočítanú testovaciu štatistiku T_0), na základe ktorej bude $H_{02} : g(\theta) \leq g(\theta_0)$ (testovaná proti $H_{12} : g(\theta) > g(\theta_0)$) zamietnutá, nazývame **pozorovaná hladina významnosti alebo p-hodnota**, t.j.

$$p\text{-hodnota} = \alpha_{\text{obs}} = \sup_{\theta \in \Theta_0} \Pr(T(X_1, X_2, \dots, X_n) \geq T(x_1, x_2, \dots, x_n); \theta),$$

čo môžeme písať aj nasledovne

$$p\text{-hodnota} = \Pr(\text{nejaká testovacia štatistika sa rovná pozorovanej alebo je väčšia} | H_0 \text{ platí}).$$

Podobne môžeme zdefinovať p-hodnotu aj pre zvyšné dve alternatívy. Pomocou p-hodnoty sa rozhodujeme, či rozdiel hodnoty pozorovanej testovacej štatistiky od jej hodnoty za platnosti H_0 je spôsobený náhodou alebo výberovým rozptylom. Čím je α_{obs} bližšie k nule, tým menšia je pravdepodobnosť, že nejaká testovacia štatistika $T(X_1, X_2, \dots, X_n)$ má p-hodnotu (za platnosti H_0) rovnú alebo menšiu než pozorovaná. Pravdepodobnosť tejto udalosti je väčšia za platnosti H_1 . V tomto zmysle chápeme p-hodnotu ako indikátor hodnovernosti H_0 . Ak $\alpha_{\text{obs}} < \alpha = 0.05$, máme dostatok dôkazov na zamietnutie H_0 a hovoríme, že výsledok testu je **štatisticky signifikantný**. Ak $\alpha_{\text{obs}} > \alpha = 0.1$, nemáme dostatok dôkazov na zamietnutie H_0 a hovoríme, že výsledok testu je **štatisticky nesignifikantný**. Hodnoty 0.05 a 0.1 chápeme ako referenčné hodnoty v širšom slova zmysle. Ak sa α_{obs} blíži k hraniciam intervalu (0.05, 0.1), chápeme to ako približovanie sa k jednej z vyššie spomínaných interpretácií. Situácia, keď $\alpha_{\text{obs}} \in (0.05, 0.1)$ sú ťažko interpretovateľné a niekedy sa označujú ako **hraničná štatistická signifikancia**. V aplikáciách vyjadrujeme zamietanie a nezamietanie H_0 nasledovne:

rozsah pre p-hodnotu	hviezdičky signifikancie	zvyčajný slovný popis výsledku testu
(0, 0.001)	***	extrémne vysoko štatisticky signifikantný
(0.001, 0.01)	**	vysoko štatisticky signifikantný
(0.01, 0.05)	*	štatisticky signifikantný
(0.05, 0.1)	.	hranične štatisticky signifikantný
(0.1, 1)		nesignifikantný

Príklady frekventistických interpretácií p-hodnôt

- p-hodnota < 0.001 : odhadnutý efekt sa vyskytne v menej ako jednom prípade z tisíc (šanca výskytu odhadnutého efektu je menej ako 1 : 999), ak efekt v populácii neexistuje (výskyt takéhoto efektu je vysoko nepravdepodobný, ak efekt v populácii v skutočnosti neexistuje a naopak – výskyt takéhoto efektu je vysoko pravdepodobný, ak efekt v populácii v skutočnosti existuje);

- p-hodnota < 0.01 : odhadnutý efekt sa vyskytne v menej ako jednom prípade zo sto (šanca výskytu odhadnutého efektu je menej ako 1 : 99), ak efekt v populácii neexistuje (výskyt takéhoto efektu je veľmi nepravdepodobný, ak efekt v populácii v skutočnosti neexistuje a naopak – výskyt takéhoto efektu je veľmi pravdepodobný, ak efekt v populácii v skutočnosti existuje);
- p-hodnota < 0.05 : odhadnutý efekt sa vyskytne v menej ako piatich prípadoch zo sto (šanca výskytu odhadnutého efektu je menej ako 5 : 95 alebo 1 : 19), ak efekt v populácii neexistuje (výskyt takéhoto efektu je dostatočne nepravdepodobný, ak efekt v populácii v skutočnosti neexistuje a naopak – výskyt takéhoto efektu je dostatočne pravdepodobný, ak efekt v populácii v skutočnosti existuje);
- p-hodnota ≥ 0.05 : odhadnutý efekt sa vyskytne v piatich alebo viacerých prípadoch zo sto (v 5 alebo viac ako 5 % prípadov);
- p-hodnota $= k, k \in (0.05, 1)$: odhadnutý efekt sa vyskytne v $100 \times k$ prípadoch zo sto (v $100 \times k$ % prípadov).

Spôsob výpočtu p-hodnoty

1. **obojsstranná alternatíva** – p-hodnota $= 2 \min(\Pr(T_0 \leq t_0|H_0), \Pr(T_0 \geq t_0|H_0))$, čo platí napr. pre normálne a Studentovo rozdelenie testovacej štatistiky (symetrické rozdelenia) a pre χ_{df}^2 rozdelenie a F_{df_1, df_2} rozdelenie testovacej štatistiky (nesymetrické rozdelenia), pozri kap. 6 a 7; alebo p-hodnota $= \min(\Pr(T_0 \leq t_0|H_0), \Pr(T_0 \geq t_0|H_0))$, čo platí napr. pre χ_{df}^2 rozdelenie a F_{df_1, df_2} rozdelenie testovacej štatistiky (nesymetrické rozdelenie), pozri kap. 5 a 8;
2. **jednostranná (pravostranná) alternatíva** – p-hodnota $= \Pr(T_0 \geq t_0|H_0)$, pozri kap. 6 a 7;
3. **jednostranná (ľavostranná) alternatíva** – p-hodnota $= \Pr(T_0 \leq t_0|H_0)$, pozri kap. 6 a 7.

Konzervatívny a liberálny test a IS

Definícia 42 (Konzervatívny a liberálny test) Test, ktorého **aktuálna/skutočná hladina významnosti** je menšia ako **nominálna hladina významnosti** α , sa nazýva **konzervatívny** (test by mal teoreticky „rýchlejšie“ zamietat H_0 , ale skutočnosť je opačná, t.j. test zamietá „pomalšie“). Test, ktorého **aktuálna hladina významnosti** je väčšia ako **nominálna hladina významnosti** α , sa nazýva **liberálny** (test by mal teoreticky „pomalšie“ zamietat H_0 , ale skutočnosť je opačná, t.j. test zamietá „rýchlejšie“).

Definícia 43 (Konzervatívny a liberálny IS) IS, ktorého **aktuálna/skutočná pravdepodobnosť pokrytia** je väčšia ako **nominálna pravdepodobnosť pokrytia** $1 - \alpha$, sa nazýva **konzervatívny** (IS má väčšiu pravdepodobnosť, že obsahuje θ_0 , ako by sme teoreticky predpokladali). IS, ktorého **aktuálna pravdepodobnosť pokrytia** je menšia ako **nominálna pravdepodobnosť pokrytia** $1 - \alpha$, sa nazýva **liberálny** (IS má menšiu pravdepodobnosť, že obsahuje θ_0 , ako by sme teoreticky predpokladali).

Praktické rady

1. Nikdy nehovoríme „ H_0 prijímame“, ale „nemáme dostatočné dôkazy na zamietnutie H_0 “. Nikdy nehovoríme „ H_1 prijímame/neprijímame“, keďže testujeme H_0 a nie H_1 .
2. Testovacia štatistika je vytvorená z charakteristík vierohodnostnej funkcie, ktorej tvar je ovplyvnený rozdelením F_* , z ktorého pochádza náhodná premenná X . Čím je rozdelenie F náhodnej premennej X odlišnejšie od skutočného (predpokladaného) rozdelenia F_* , tým viac sa líšia závery z testovania hypotéz od záverov, ktoré sú platné, ak X pochádza z F_* .
3. Voľba nulovej a alternatívnej hypotézy nie je ľubovoľná, ale je ovplyvnená konkrétnou praktickou situáciou.

Príklad 151 (neistota) Ak X nepochádza z predpokladaného rozdelenia $N(\mu, \sigma^2)$, rozdelenie testovacej štatistiky pre test o μ nie je normálne $N(0, 1)$, a teda závery (zamietame/nezamietame H_0) vytvorené použitím asymptotickej normality testovacej štatistiky nebudú platné, resp. neistota záveru sa zvyšuje so zväčšujúcim sa rozdielom rozdelenia X od $N(\mu, \sigma^2)$.

Príklad 152 (istota vs. neistota) Ak X pochádza z rozdelenia $N(\mu, \sigma^2)$, môžeme testovať nulové hypotézy o μ pomocou asymptotického testu, ktorého testovacia štatistika má normálne rozdelenie. Ak X nepochádza z rozdelenia $N(\mu, \sigma^2)$, ale napr. zo zmesi $(1-p)N(\mu, \sigma_1^2) + pN(\mu, \sigma_2^2)$, kde $\sigma_1 \ll \sigma_2$ (t.j. ide o prítomnosť odľahlých pozorovaní s pravdepodobnosťou p , kde p je nejaké malé číslo), nemôžeme testovať nulové hypotézy o μ pomocou asymptotického testu, ktorého testovacia štatistika má normálne rozdelenie.

Príklad 153 Majme model normálneho rozdelenia s neznámou strednou hodnotou μ a známym rozptylom $\sigma^2 = 2^2$. Jednovýberovým Z -testom testujte $H_{01} : \mu = 1$ oproti $H_{11} : \mu \neq 1$ na hladine významnosti $\alpha = 0.05$. Strednú hodnotu μ sme odhadli na základe náhodného výberu s rozsahom 30, kde $\bar{x} = 1.3$.

Riešenie (aj v \mathbb{R})

1. **Testovacia štatistika (testovacie kritérium)** – $T_0 = Z_W = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n}$ a jej realizácia $t_0 = z_W = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n} = \frac{1.3 - 1}{2} \sqrt{30} \doteq 0.822$.

```
473 | aritm.priem <- 1.3
474 | sigma <- 2
475 | n <- 30
476 | alfa <- 0.05
477 | test.stat <- (1.3-1)/2*sqrt(30) # 0.8215838
```

2. **Zamietacia oblasť** – kritická hodnota $u_{1-\alpha/2} \doteq -1.96$ a $u_\alpha \doteq 1.96$, potom kritický obor: $\mathcal{W}_1 = (t_{\min}, t_{1-\alpha/2}) \cup (t_{\alpha/2}, t_{\max}) = (-\infty, -1.96) \cup (1.96, \infty)$.

```
478 | krit.hodn <- qnorm(1-alfa/2) # 1.959964
```

3. $100 \times (1 - \alpha)\%$ **empirický DIS** – keďže $\alpha = 0.05$, ide o 95% empirický DIS pre μ_0 , kde $(d, h) = (\bar{x} - t_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{x} + t_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}) \doteq (1.3 - 1.96 \frac{2}{\sqrt{30}}, 1.3 + 1.96 \frac{2}{\sqrt{30}}) \doteq (0.584, 2.016)$.

```
479 | IS <- aritm.priem + c(-1,1)*krit.hodn*sigma/sqrt(30) # 0.5843223 2.0156777
```

4. **Štatistický záver** – p -hodnota = $2\Pr(T_0 \geq |t_0|) = 2\Pr(T_0 \geq 0.822) = 0.411$.

```
480 | p.hodn <- 2*(1-pnorm(abs(test.stat))) # 0.4113138
```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí do kritického oboru, (2) $\mu_0 = 1$ patrí DIS a nakoniec (3) p -hodnota je väčšia alebo rovná ako 0.05.

Použitie triády rozdelení pravdepodobnosti (fundamentálne predpoklady testovania hypotéz; príklad testovacej štatistiky Z_W):

- náhodná premenná X má **normálne rozdelenie** $X \sim N(\mu, \sigma^2)$;
- náhodná premenná \bar{X} má **normálne rozdelenie** $\bar{X} \sim N(\mu, \sigma^2/n)$;
- testovacia štatistika Z_W má **štandardizované normálne rozdelenie**, t.j. $Z_W \stackrel{\mathcal{D}}{\sim} N(0, 1)$.

Pri iných testoch môže mať náhodná premenná X iné rozdelenie; iné testovacie štatistiky môžu mať tiež iné rozdelenie. Rozdelenie X bude špecifikované v kapiolách 5 až 8 pri každom teste, rovnako aj rozdelenie testovacie štatistiky.

4.4 *Tri typy testovacích štatistík

Zmysluplným kritériom na zistenie odpovede na otázku, či θ dobre popisuje dáta \mathbf{x} sa javí tzv. **relatívna (štandardizovaná) vierohodnosť** $\mathcal{L}(\theta|\mathbf{x}) = L(\theta|\mathbf{x})/L(\hat{\theta}|\mathbf{x})$. Ignorujúc prípad, keď je $L(\theta|\mathbf{x})$ neohraničená, $\mathcal{L}(\theta|\mathbf{x}) \in \langle 0, 1 \rangle$. Nech θ_0 je θ špecifikovaná v hypotéze H_0 . Potom $\mathcal{L}(\theta_0|\mathbf{x})$ predstavuje kvantifikáciu zhody medzi dátami a touto hypotézou. Ak $\mathcal{L}(\theta_0|\mathbf{x}) = 1$, potom je zhoda maximálna (za predpokladu, že štatistický model je vhodný). Ak $\mathcal{L}(\theta_0|\mathbf{x}) = 0$, potom sa hypotéza H_0 ukazuje ako úplne nevyhovujúca. V realite však $\mathcal{L}(\theta_0|\mathbf{x})$ leží niekde medzi nulou a jednotkou. Jednou z možností je stanoviť **kritickú hodnotu** r . Potom ak $\mathcal{L}(\theta_0|\mathbf{x}) \leq r$, zhoda medzi H_0 a dátami je príliš malá, a teda θ_0 nie je adekvátne a H_0 zamietame. Ak $\mathcal{L}(\theta_0|\mathbf{x}) > r$, potom zhoda medzi H_0 a dátami je dostatočná, a teda θ_0 je adekvátne a H_0 nezamietame. Je dôležité si uvedomiť, že kľúčovou je voľba kritickej hodnoty a možná adaptácia vyššie spomenutého princípu na zložitejšie situácie.

Testujme $H_0 : \theta = \theta_0$ oproti $H_1 : \theta \neq \theta_0$. Potom zovšeobecnením relatívnej vierohodnosti za predpokladu spojitosti $L(\theta|\mathbf{x})$ je **jednoduchý pomer vierohodnosti** rovný

$$\lambda(\mathbf{x}) = \lambda = \frac{L(\theta_0|\mathbf{x})}{\sup_{\theta \in \Theta} L(\theta|\mathbf{x})} = \frac{L(\theta_0|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})},$$

kde $\lambda(\mathbf{x}) = \mathcal{L}(\theta_0|\mathbf{x})$ je testovacou štatistikou a $L(\theta|\mathbf{x})$ je spojitá pre všetky x .

Testujme $H_0 : \theta \in \Theta_0$ oproti $H_1 : \theta \in \Theta_1$. Potom je **zovšeobecnený pomer vierohodnosti** rovný

$$\lambda(\mathbf{x}) = \frac{\sup_{\theta \in \Theta_0} L(\theta|\mathbf{x})}{\sup_{\theta \in \Theta} L(\theta|\mathbf{x})}.$$

Monotónna transformácia $\lambda(\mathbf{x})$ spolu s korešpondujúcou transformáciou kritických hodnôt nezmení delenie Θ na Θ_0 a Θ_1 , a teda nezmení samotný štatistický test. Preto ekvivalentnou testovacou štatistikou bude

$$U_{LR} = -2 \ln \lambda(\mathbf{X}),$$

ktorá sa nazýva **testovacia štatistika pomerom vierohodnosti**. Jej realizácia $u_{LR} = -2 \ln \lambda(\mathbf{x})$. Interpretácia oproti $\lambda(\mathbf{x})$ bude obrátená z dôvodu vynásobenia $2 \ln \lambda(\mathbf{x})$ číslom -1 . Je zrejmé, že $u_{LR} \in (0, \infty)$.

Použitím Taylorovho rozvoja $l(\theta_0)$ okolo $\hat{\theta}$ dostaneme

$$U_{LR} = -2(l(\theta_0|\mathbf{X}) - l(\hat{\theta}|\mathbf{X})) \approx -2 \left((\theta_0 - \hat{\theta})S(\hat{\theta}) - \frac{1}{2}(\theta_0 - \hat{\theta})^2 \mathcal{I}(\hat{\theta}) \right),$$

kde $S(\hat{\theta}) = 0$. Dá sa ľahko ukázať, že $\frac{1}{n} \mathcal{I}(\hat{\theta}) \xrightarrow{P} i(\theta_0)$; pozri Anděl (2011). Keďže $\hat{\theta}$ je konzistentný odhad θ_0 za platnosti H_0 , potom je konzistentným odhadom θ_0 aj $\hat{\theta}$, z čoho potom vyplýva nasledovné

$$U_{LR} \approx n(\theta_0 - \hat{\theta})^2 \frac{\mathcal{I}(\theta_0)}{n} \approx n(\theta_0 - \hat{\theta})^2 i(\theta_0) \stackrel{H_0}{\approx} n(\theta_0 - \hat{\theta})^2 i(\hat{\theta}) = U_W,$$

kde U_W sa nazýva **Waldova testovacia štatistika** (aproximácia U_{LR}) a jej realizáciu ozn. u_W . Keďže

$$\sqrt{n}(\hat{\theta} - \theta_0) \stackrel{H_0}{\approx} S(\theta_0)/(\sqrt{n}i(\theta_0)),$$

potom

$$U_{LR} \approx n(\theta_0 - \hat{\theta})^2 i(\theta_0) \stackrel{H_0}{\approx} \frac{(S(\theta_0))^2}{n i(\theta_0)} = U_S,$$

kde U_S sa nazýva **skóre testovacia štatistika** (aproximácia U_{LR}) a jej realizáciu ozn. u_S .

Každá z troch vyššie spomenutých testovacích štatistík zachytáva iný aspekt logaritmu funkcie vierohodnosti:

1. U_{LR} meria vhodne normalizovaný rozdiel funkčných hodnôt logaritmu funkcie vierohodnosti v bodoch $\hat{\theta}$ a θ_0 (t.j. v smere osi y);
2. U_W meria vhodne normalizovaný rozdiel $\hat{\theta}$ a θ_0 v absolútnej hodnote (v smere osi x);

3. U_S meria vhodne normalizovaný sklon logaritmu funkcie vierohodnosti v bode θ_0 .

Príklad 154 Predpokladajme, že $X \sim N(\mu, \sigma^2)$, kde σ^2 je známa. Testujme $H_0 : \theta = \theta_0$ proti $H_1 : \theta \neq \theta_0$, kde $\theta = \mu$. Potom

$$1. U_{LR} = -2(l(\theta_0|\mathbf{X}) - l(\hat{\theta}|\mathbf{X})) = -\sum_{i=1}^n (X_i - \bar{X})^2/\sigma^2 + \sum_{i=1}^n (X_i - \mu_0)^2/\sigma^2 = n \frac{(\bar{X} - \mu_0)^2}{\sigma^2};$$

$$2. U_W = (\bar{X} - \mu_0)^2 \mathcal{I}(\bar{x}) = n \frac{(\bar{X} - \mu_0)^2}{\sigma^2};$$

$$3. U_S = \frac{(S(\mu_0))^2}{\mathcal{I}(\mu_0)} = \frac{(n(\bar{X} - \mu_0)/\sigma^2)^2}{n/\sigma^2} = n \frac{(\bar{X} - \mu_0)^2}{\sigma^2}.$$

Všetky tri testovacie štatistiky sú rovnaké, t.j. $U_{LR} = U_W = U_S$.

Veta 8 (tri typy testovacích štatistík) Za podmienok regularity platí:

$$1. U_{LR} = -2(l(\theta_0|\mathbf{X}) - l(\hat{\theta}|\mathbf{X})) \stackrel{\mathcal{D}}{\sim} \chi_1^2;$$

$$2. U_W = (\hat{\theta} - \theta_0)^T \mathcal{I}(\hat{\theta}) \stackrel{\mathcal{D}}{\sim} \chi_1^2, \text{ tiež môžeme písať } U_W^{1/2} = Z_W \stackrel{\mathcal{D}}{\sim} N(0, 1);$$

$$3. U_S = \frac{(S(\theta_0))^2}{\mathcal{I}(\theta_0)} \stackrel{\mathcal{D}}{\sim} \chi_1^2, \text{ tiež môžeme písať } U_S^{1/2} = Z_S \stackrel{\mathcal{D}}{\sim} N(0, 1).$$

Veta 9 (tri typy testovacích štatistík) Ak $k > 1$, potom je θ vektor a za podmienok regularity platí:

$$1. U_{LR} = -2(l(\theta_0|\mathbf{X}) - l(\hat{\theta}|\mathbf{X})) \stackrel{\mathcal{D}}{\sim} \chi_k^2;$$

$$2. U_W = (\hat{\theta} - \theta_0)^T \mathcal{I}(\hat{\theta}) (\hat{\theta} - \theta_0) \stackrel{\mathcal{D}}{\sim} \chi_k^2;$$

$$3. U_S = (S(\theta_0))^T (\mathcal{I}(\theta_0))^{-1} S(\theta_0) \stackrel{\mathcal{D}}{\sim} \chi_k^2.$$

Definícia 44 (tri typy testovacích štatistík a IS) Jednotlivým typom testovacích štatistík prislúchajú nasledovné IS:

1. Testovacej štatistike pomerom vierohodnosti U_{LR} zodpovedá vierohodnostný IS $CS_{1-\alpha}$ pre θ , kde $CS_{1-\alpha} = \{\theta : U_{LR}(\theta) < \chi_1^2(\alpha)\}$, kde $U_{LR}(\theta) = -2 \ln \frac{L(\theta|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})}$.

2. Waldovej testovacej štatistike U_W zodpovedá Waldov IS pre θ , kde pivot $T_{piv} = U_W(\theta)$.

3. Skóre testovacej štatistike U_S zodpovedá skóre IS pre θ kde pivot $T_{piv} = U_S(\theta)$.

Definícia 45 (elipsy a elipsoidy spoľahlivosti) $CS_{1-\alpha}$ vo všeobecnosti označuje konfidenčnú množinu, ktorá môže zahŕňať nielen IS pre θ , ale aj $100 \times (1 - \alpha)\%$ **elipsy spoľahlivosti** pre θ , kde $k = 2$ a $100 \times (1 - \alpha)\%$ **elipsoidy spoľahlivosti** pre θ , kde $k \geq 3$. Konfidenčná množina je potom taká množina θ_0 , ktoré patria do $CS_{1-\alpha}$ (podobne pre $g(\theta_0)$, θ_0 , $g(\theta_0)$).

Keď má X normálne rozdelenie, funkcia vierohodnosti má potom parabolický tvar (polynóm druhého stupňa). Pre malé rozsahy výberov n sa môže rozdelenie \bar{X} veľmi odlišovať od normality a funkcia vierohodnosti je ďaleko od symetrickosti, t.j. symetrického parabolického tvaru. To sa môže stať aj pri výberoch s veľkým rozsahom, kde máme veľa parametrov. V takýchto prípadoch inferencia na základe asymptotickej normality môže dávať neadekvátne výsledky.

Je praktickejšie vypočítať IS pre parametre θ ako testovať hypotézy (Agresti, 2002). Waldov IS bol v minulosti najčastejšie používaný v praxi, pretože je jednoduché ho vypočítať. Častejšie by sa mal však používať vierohodnostný IS, príp. skóre IS, ktorý je preferovaný napr. pre kategoriálne dáta s malým rozsahom.

Použitím U_{LR} testujeme $H_0 : \theta = \theta_0$ oproti $H_1 : \theta \neq \theta_0$, avšak U_W a U_S umožňujú testovať aj H_0 oproti jednostrannej alternatíve. Ak $n \rightarrow \infty$, sú všetky tri štatistiky asymptoticky ekvivalentné (Cox a Hinkley, 1974). Pre výbery s malým rozsahom je test pomerom vierohodnosti viac vhodný ako Waldov test.

Príklad 155 Predpokladajme, že $X \sim N(\mu, \sigma^2)$, kde σ^2 je známa. Nech $\theta = \mu$. Testujme tri typy hypotéz

1. $H_{01} : \mu = \mu_0$ oproti $H_{11} : \mu \neq \mu_0$;
2. $H_{02} : \mu \leq \mu_0$ oproti $H_{12} : \mu > \mu_0$;
3. $H_{03} : \mu \geq \mu_0$ oproti $H_{13} : \mu < \mu_0$;

(a) Vypočítajte pravdepodobnosti chýb druhého druhu $\Pr_\mu(\text{CHDD})$ pri danej alternatíve pre všetky tri typy hypotéz, t.j. β_{11} , β_{12} a β_{13} .

(b) Vypočítajte silofunkcie pre všetky tri typy hypotéz, t.j. $\beta_{11}^*(\mu)$, $\beta_{12}^*(\mu)$ a $\beta_{13}^*(\mu)$.

(c) Vypočítajte minimálny rozsah náhodného výberu n pri danej α , β , $\mu - \mu_0$ a σ^2 pre všetky tri typy hypotéz tak, aby $\mu - \mu_0$ bolo štatisticky signifikantne odlišné od 0.

(d) Zapište kritické obory \mathcal{W}_1 , \mathcal{W}_2 a \mathcal{W}_3 .

(e) Ako vyzerajú $100(1 - \alpha)\%$ empirické IS pre všetky tri typy hypotéz?

Riešenie

Predpokladajme, že $X \sim N(\mu, \sigma^2)$, kde μ je neznáma stredná hodnota a $\sigma^2 \in (0, \infty)$ je známa konštanta. $\frac{X - \mu}{\sigma} \stackrel{\mathcal{D}}{\sim} N(0, 1)$ a navyše $\bar{X} \stackrel{\mathcal{D}}{\sim} N(\mu, \sigma^2/n)$. Za platnosti nulovej hypotézy $Z_W = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \stackrel{\mathcal{D}}{\sim} N(0, 1)$. Z_W sa nazýva **Waldova testovacia štatistika** a test **jednovýberový Z-test o strednej hodnote** μ . Ak je skutočná hodnota parametra rovná μ , má náhodná veličina $\frac{\bar{X} - \mu}{\sigma} \sqrt{n}$ rozdelenie $N(0, 1)$. Distribučnú funkciu normálneho normovaného rozdelenia $N(0, 1)$ budeme označovať Φ .

Majme H_{02} oproti H_{12} . Kritický obor je \mathcal{W}_2 , čo predstavuje najsilnejší test pre danú situáciu. Vyšetříme $\Pr_\mu(\text{CHDD})$ ako funkcie μ , teda $\beta_{12}(\mu) = \Pr_\mu(X \notin \mathcal{W}_2)$, $\mu \in \mathbb{R}^1$. Platí

$$\begin{aligned} \beta_{12}(\mu) &= \Pr_\mu\left(\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} < u_\alpha\right) = \Pr_\mu\left(\frac{\bar{X} - \mu_0 \pm \mu}{\sigma} \sqrt{n} < u_\alpha\right) \\ &= \Pr_\mu\left(\frac{\bar{X} - \mu}{\sigma} \sqrt{n} < u_\alpha + \frac{\mu_0 - \mu}{\sigma} \sqrt{n}\right) = \Phi\left(u_\alpha + \frac{\mu_0 - \mu}{\sigma} \sqrt{n}\right) \\ &= \Phi\left(u_\alpha - \frac{\mu - \mu_0}{\sigma} \sqrt{n}\right) = \Phi\left(-u_{1-\alpha} - \frac{\mu - \mu_0}{\sigma} \sqrt{n}\right) \\ &= 1 - \Phi\left(u_{1-\alpha} + \frac{\mu - \mu_0}{\sigma} \sqrt{n}\right). \end{aligned}$$

Silofunkcia bude rovná $\beta_{12}^*(\mu) = 1 - \Phi\left(u_\alpha - \frac{\mu - \mu_0}{\sigma} \sqrt{n}\right)$. Z vlastností Φ vyplýva, že funkcia $\beta_{12}(\mu)$, $\mu \in \mathbb{R}^1$ je spojitá, klesajúca v μ s vlastnosťami

$$\beta_{12}(\mu) \begin{cases} \geq 1 - \alpha, & \text{ak } \mu < \mu_0 \\ = 1 - \alpha, & \text{ak } \mu = \mu_0 \\ \leq 1 - \alpha, & \text{ak } \mu > \mu_0 \end{cases},$$

kde $\lim_{\mu \rightarrow \infty} \beta_{12}(\mu) = 0$. Ak sa teraz pozrieme na pravdepodobnosť $\beta_{12}(\mu)$ ako funkciu n a $\mu > \mu_0$ fixované, tak je vidieť, že je to funkcia klesajúca v n .

Pokiaľ budeme uvažovať o voľbe rozsahu n , aby test mal hladinu významnosti α a $\Pr_\mu(\text{CHDD})$ bola v pevne zvolenom bode $\mu (> \mu_0)$ menšia alebo rovná $\beta \in (0, 1)$, teda $\beta_{12}(\mu) \leq \beta$ (β je fixované), dostaneme

$$\Phi\left(u_\alpha + \frac{\mu_0 - \mu}{\sigma} \sqrt{n}\right) \leq \beta,$$

čo vedie ku

$$u_\alpha + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \leq x_\beta = -x_{1-\beta} = -u_\beta,$$

kde x_β je kvantil $N(0, 1)$ a u_α kritická hodnota ($\Phi(u_\alpha) = 1 - \alpha$), potom

$$n \geq \left(\frac{u_\alpha + u_\beta}{\mu - \mu_0} \right)^2 \sigma^2.$$

Čím väčší rozdiel $\mu - \mu_0$ je pre nás kritický (chceme mať s dostatočnou pravdepodobnosťou zaručené, že ho odhalíme, ak je skutočnosťou), tým menej pozorovaní k tomu potrebujeme.

Majme H_{03} oproti H_{13} . Vyšetříme \Pr_μ (CHDD) ako funkcie μ , teda $\beta_{13}(\mu) = \Pr_\mu(X \notin \mathcal{W}_3)$, $\mu \in \mathbb{R}^1$. Platí

$$\begin{aligned} \beta_{13}(\mu) &= \Pr_\mu \left(\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \geq -u_\alpha \right) = \Pr_\mu \left(\frac{\bar{X} - \mu_0 \pm \mu}{\sigma} \sqrt{n} \geq -u_\alpha \right) \\ &= \Pr_\mu \left(\frac{\bar{X} - \mu}{\sigma} \sqrt{n} \geq -u_\alpha + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) = 1 - \Phi \left(-u_\alpha + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) \\ &= 1 - \Phi \left(u_{1-\alpha} + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) = \Phi \left(u_\alpha - \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) \\ &= \Phi \left(u_\alpha + \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right). \end{aligned}$$

Silofunkcia bude rovná $\beta_{13}^*(\mu) = 1 - \Phi \left(u_\alpha + \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right)$.

Minimálny rozsah n je identický ako v situácii H_{12} .

Majme H_{01} vs. H_{11} . Nech $\beta_{11}(\mu) = \beta_1(\mu) - \beta_2(\mu)$. Platí

$$\begin{aligned} \beta_1(\mu) &= \Pr_\mu \left(\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} < u_{\alpha/2} \right) = \Pr_\mu \left(\frac{\bar{X} - \mu_0 \pm \mu}{\sigma} \sqrt{n} < u_{\alpha/2} \right) \\ &= \Pr_\mu \left(\frac{\bar{X} - \mu}{\sigma} \sqrt{n} < u_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) = \Phi \left(u_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) \\ &= \Phi \left(u_{\alpha/2} - \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right), \end{aligned}$$

$$\begin{aligned} \beta_2(\mu) &= \Pr_\mu \left(\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} < -u_{\alpha/2} \right) = \Pr_\mu \left(\frac{\bar{X} - \mu_0 \pm \mu}{\sigma} \sqrt{n} < -u_{\alpha/2} \right) \\ &= \Pr_\mu \left(\frac{\bar{X} - \mu}{\sigma} \sqrt{n} < -u_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) = \Phi \left(-u_{\alpha/2} + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) \\ &= \Phi \left(u_{1-\alpha/2} + \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) = 1 - \Phi \left(u_{\alpha/2} - \frac{\mu_0 - \mu}{\sigma} \sqrt{n} \right) \\ &= 1 - \Phi \left(u_{\alpha/2} + \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right) \end{aligned}$$

a nakoniec

$$\begin{aligned} \beta_{11}(\mu) &= \beta_1(\mu) - \beta_2(\mu) \\ &= \Phi \left(u_{\alpha/2} - \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right) + \Phi \left(u_{\alpha/2} + \frac{\mu - \mu_0}{\sigma} \sqrt{n} \right) - 1. \end{aligned}$$

Silofunkcia bude rovná

$$\begin{aligned}\beta_{11}^*(\mu) &= 1 - \beta_{11}(\mu) = 2 - \Phi\left(u_{\alpha/2} - \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right) - \Phi\left(u_{\alpha/2} + \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right) \\ &= 2 - \left(1 - \Phi\left(u_{1-\alpha/2} + \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right)\right) + 1 - \Phi\left(u_{1-\alpha/2} - \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right) \\ &= \Phi\left(u_{1-\alpha/2} + \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right) + \Phi\left(u_{1-\alpha/2} - \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right).\end{aligned}$$

Z uvedeného vyplýva, že pre každé $\delta = \mu - \mu_0$ je silofunkcia

$$\beta_{11}^*(\mu_0 + \delta) = \beta_{11}^*(\mu_0 - \delta)$$

a teda silofunkcia je symetrická okolo bodu $\mu = \mu_0$. Pre každé $\alpha \in (0, 1)$ a $c = |\mu - \mu_0|/\sigma$ platí

$$\Pr(u_{1-\alpha/2} < u < u_{1-\alpha/2} + c) > \Pr(u_{1-\alpha/2} - c < u < u_{1-\alpha/2})$$

alebo

$$\Phi(u_{1-\alpha/2} + c) - \Phi(u_{1-\alpha/2}) > \Phi(u_{1-\alpha/2}) - \Phi(u_{1-\alpha/2} - c)$$

a pre každé $\mu \neq \mu_0$

$$\Phi(u_{1-\alpha/2} + c) + \Phi(u_{1-\alpha/2} - c) > 2\Phi(u_{1-\alpha/2}) = \alpha$$

Ak chceme vypočítať minimálne n pri daných α, β, σ a μ_0 ako funkciu μ , dostaneme

$$\begin{aligned}1 - \beta &= \beta^* \leq \Phi\left(u_{1-\alpha/2} + \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right) + \Phi\left(u_{1-\alpha/2} - \frac{\mu - \mu_0}{\sigma}\sqrt{n}\right) \\ &= \Phi\left(u_{1-\alpha/2} - \frac{\mu_0 - \mu}{\sigma}\sqrt{n}\right) + \Phi\left(u_{1-\alpha/2} + \frac{\mu_0 - \mu}{\sigma}\sqrt{n}\right)\end{aligned}$$

Ak $\mu > \mu_0$, potom pri rastúcom μ bude rásť aj $\Phi(u_{1-\alpha/2} - \frac{\mu_0 - \mu}{\sigma}\sqrt{n})$ a $\Phi(u_{1-\alpha/2} + \frac{\mu_0 - \mu}{\sigma}\sqrt{n})$ bude klesať (vždy bude $< \alpha/2$). Ak $\mu < \mu_0$, potom pri rastúcom μ bude rásť aj $\Phi(u_{1-\alpha/2} + \frac{\mu_0 - \mu}{\sigma}\sqrt{n})$ a $\Phi(u_{1-\alpha/2} - \frac{\mu_0 - \mu}{\sigma}\sqrt{n})$ bude klesať (vždy bude $< \alpha/2$). Potom môžeme napísať približnú silu $\tilde{\beta}^*$ ako

$$\begin{aligned}\beta^* &= \Phi\left(u_{1-\alpha/2} - \frac{\mu_0 - \mu}{\sigma}\sqrt{n}\right) + \Phi\left(u_{1-\alpha/2} + \frac{\mu_0 - \mu}{\sigma}\sqrt{n}\right) \\ &< \Phi\left(u_{1-\alpha/2} + \frac{|\mu_0 - \mu|}{\sigma}\sqrt{n}\right) = 1 - \Phi\left(u_{\alpha/2} - \frac{|\mu_0 - \mu|}{\sigma}\sqrt{n}\right) = \tilde{\beta}^*.\end{aligned}$$

Pozn:


$$\beta_{11}(\mu) \leq \Phi_{\delta,1}(u_{\alpha/2}) - \Phi_{\delta,1}(-u_{\alpha/2}),$$

kde $\Phi_{\delta,1}(\cdot)$ je distribučná funkcia $N(\delta, 1)$, $\delta = \frac{|\mu_0 - \mu|}{\sigma}\sqrt{n} \neq 0$. Potom **minimálny rozsah** n pre rozdiel $|\mu - \mu_0|$ (pri nejakom α a β) je daný nasledovne

$$n \geq \left(\frac{u_{\alpha/2} + u_{\beta}}{c}\right)^2 = \left(\frac{u_{\alpha/2} + u_{\beta}}{\frac{\mu - \mu_0}{\sigma}}\right)^2 = \left(\frac{u_{\alpha/2} + u_{\beta}}{\mu - \mu_0}\right)^2 \sigma^2.$$

Definícia 46 (Kritický obor a silofunkcia Z_W testu o μ) Kritický obor a silofunkcia sú definované nasledovne (pozri obrázok 4.8):

H_0	H_1	\mathcal{W}	$1 - \beta(\mu)$
$\mu = \mu_0$	$\mu \neq \mu_0$	$\mathcal{W}_1 = \{Z_W; Z_W \geq u_{\alpha/2}\}$	$1 - \Phi\left(u_{\alpha/2} - \frac{ \mu_0 - \mu }{\sigma}\sqrt{n}\right)$
$\mu \leq \mu_0$	$\mu > \mu_0$	$\mathcal{W}_2 = \{Z_W; Z_W \geq u_{\alpha}\}$	$1 - \Phi\left(u_{\alpha} + \frac{\mu_0 - \mu}{\sigma}\sqrt{n}\right)$
$\mu \geq \mu_0$	$\mu < \mu_0$	$\mathcal{W}_3 = \{Z_W; Z_W \leq -u_{\alpha}\}$	$1 - \Phi\left(u_{\alpha} - \frac{\mu_0 - \mu}{\sigma}\sqrt{n}\right)$



Obr. 4.8: Silofunkcie asymptotického testu o μ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 47 (p-hodnora Z_W testu o μ) *Nech Z_W je nejaká testovacia štatistika a z_W je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:*

$$p\text{-hodnota} = \begin{cases} 2\Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : \mu \neq \mu_0 \\ \Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : \mu > \mu_0 \\ \Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : \mu < \mu_0 \end{cases}$$

Definícia 48 (Waldove 100(1 - α)% empirické IS pre μ) *Waldove 100(1 - α)% empirické IS pre μ pre všetky tri typy hypotéz majú nasledovný tvar:*

$$\begin{array}{lll} H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1 - \alpha)\% \text{ empirický IS} \\ \mu = \mu_0 & \mu \neq \mu_0 & \mathcal{CS}_{1-\alpha} = \left\{ \mu_0 : \mu_0 \in \left(\bar{x} - u_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{x} + u_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right) \right\} \\ \mu \leq \mu_0 & \mu > \mu_0 & \mathcal{CS}_{1-\alpha} = \left\{ \mu_0 : \mu_0 \in \left(\bar{x} - u_{\alpha} \frac{\sigma}{\sqrt{n}}, \infty \right) \right\} \\ \mu \geq \mu_0 & \mu < \mu_0 & \mathcal{CS}_{1-\alpha} = \left\{ \mu_0 : \mu_0 \in \left(-\infty, \bar{x} + u_{\alpha} \frac{\sigma}{\sqrt{n}} \right) \right\} \end{array}$$

Príklad 156 (plánovanie experimentu pre μ) *Majme náhodnú premennú $X \sim N(\mu, \sigma^2)$, kde μ je neznáma stredná hodnota a $\sigma^2 = 2^2$ je známy rozptyl. Chceme testovať $H_0 : \mu = 1$ oproti $H_1 : \mu = 4$. Kritický obor \mathcal{W}_X je interval $(2, \infty)$, t.j. ak výberová hodnota μ je väčšia ako 2, H_0 zamietame. Ak výberová hodnota μ je menšia alebo rovná 2, H_0 nezamietame. Nájdite pravdepodobnosť chyby prvého druhu α a silu pri vyššie spomenutej alternatíve pre tento experiment.*

Riešenie (aj v \mathbb{R})

$$\alpha = \Pr(X > 2 | N(1, 2)) = 0.31$$

$$\beta = \Pr(X \leq 2 | N(4, 2)) = 0.16$$

```
481 | alfa.jeden.vyber <- 1-pnorm(2,1,2) # 0.3085375
482 | beta.jeden.vyber <- pnorm(2,4,2) # 0.15865532
```

Príklad 157 (plánovanie experimentu pre μ ; test úspešnosti) *Majme náhodnú premennú $X \sim N(\mu, \sigma^2)$, kde μ je neznáma stredná hodnota a $\sigma^2 = 6^2$ je známy rozptyl, ktorá predstavuje skóre úspešnosti pre istú vekovú skupinu. Testujme H_0 , že stredná hodnota skóre je rovná 40 oproti H_1 , že stredná hodnota skóre nie je rovná 40.*

1. Vypočítajte $\Pr(\text{CHPD})$ pre $n = 9$, ak H_0 zamietame, keď $\bar{x} < 36$ alebo alebo $\bar{x} > 44$.
2. Vypočítajte $\Pr(\text{CHPD})$ pre $n = 36$, ak H_0 zamietame, keď $\bar{x} < 38$ alebo alebo $\bar{x} > 42$.
3. Nakreslite silofunkciu pre $n = 9$ a $n = 36$ pre hodnoty μ medzi 30 a 50.

Riešenie (aj v \mathbb{R} ; pozri obrázok 4.9)

$$(a) \Pr(\text{CHPD}) = \Pr(\bar{X} < 36)N(40, 6^2/9) + \Pr(\bar{X} > 44)N(40, 6^2/9)$$

$$1 - \Pr(\text{CHDD}) = \Pr(\bar{X} < 36)N(\mu, 6^2/9) + \Pr(\bar{X} > 44)N(\mu, 6^2/9)$$


$$(b) \Pr(\text{CHPD}) = \Pr(\bar{X} < 38)N(40, 6^2/36) + \Pr(\bar{X} > 42)N(40, 6^2/36)$$

$$1 - \Pr(\text{CHDD}) = \Pr(\bar{X} < 38)N(\mu, 6^2/36) + \Pr(\bar{X} > 42)N(\mu, 6^2/36)$$

```

483 | alfa.jeden.vyber <- pnorm(36,40,6/sqrt(9))+1-pnorm(44,40,6/sqrt(9)) # 0.04550026
484 | alfa.jeden.vyber <- pnorm(38,40,6/sqrt(36))+1-pnorm(42,40,6/sqrt(36)) # 0.04550026
485 | mu <- seq(30,50,.01)
486 | sila9 <- 1-pnorm(44,mu,6/sqrt(9))+pnorm(36,mu,6/sqrt(9))
487 | sila36 <- 1-pnorm(42,mu,6/sqrt(36))+pnorm(38,mu,6/sqrt(36))
488 | plot(mu,sila9,type="l",ylab=expression(sila(mu)),xlab=expression(mu),ylim=c(0,1))
489 | lines(mu,sila36,type="l")
490 | arrows(32,0.6,34,2,0.78,lwd=2,length=0.05)
491 | arrows(32,0.35,37,0.78,lwd=2,length=0.05)
492 | arrows(40,0.4,40,0.06,lwd=2,length=0.05)
493 | text(32,0.58,expression(n==9))
494 | text(32,0.33,expression(n==36))
495 | text(40,0.45,expression(alpha==0.045))

```



Obr. 4.9: Schematický náčrt silofunkcií pre $n = 9$ a $n = 36$

Príklad 158 (jednovýberový Z-test o strednej hodnote μ) Nakreslite presnú silofunkciu pre test $H_0 : \mu = \mu_0$ (oproti $H_1 : \mu \neq \mu_0$, ak σ^2 je známe) do jedného obrázka pre $n = 10, 30, 50, 100, \mu_0 = 0$ a $\sigma = 1$.

Príklad 159 (jednovýberový Z-test o strednej hodnote μ) Porovnajzte presnú a približnú silofunkciu $\tilde{\beta}^*(\mu)$ pre test $H_0 : \mu = \mu_0$ (oproti $H_1 : \mu \neq \mu_0$, ak σ^2 je známe) nakreslením oboch do jedného obrázka pre $n = 20, \mu_0 = 0$ a $\sigma = 1$.

Príklad 160 (jednovýberový Z-test o strednej hodnote μ) Odvoďte test pomerom vierohodnosti a $100(1 - \alpha)\%$ interval spoľahlivosti pre hypotézu $H_0 : \mu = \mu_0$ oproti $H_0 : \mu \neq \mu_0$, ak σ^2 je známe.

4.5 Vierohodnostné intervaly spoľahlivosti

Definícia 49 (obojsstranný Waldov $100 \times (1 - \alpha)\%$ empirický IS pre θ) Obojsstranný Waldov $100 \times (1 - \alpha)\%$ empirický IS pre θ má tvar

$$(d, h) = \left(\hat{\theta} - t_{\alpha/2} \widehat{SE}[\hat{\theta}], \hat{\theta} + t_{\alpha/2} \widehat{SE}[\hat{\theta}] \right),$$

kde kritická hodnota $t_{\alpha/2}$ závisí na voľbe $\hat{\theta}$, pozri kapitole 6, 7 a 8. Definícia 49 nie je všeobecne platná. Výnimky pozri napr. v kap. 6.2 a 7.2. Jednostranné intervaly spoľahlivosti pre θ je možné zadefinovať podobne.

Transformácia $g(\theta)$ nás často zaujíma aj preto, že „vylepšuje“ funkciu vierohodnosti v zmysle regularity. Za platnosti regularity je náš stupeň dôvery v maximálne vierohodné odhady $g(\hat{\theta})$ a $Var[g(\hat{\theta})]$ väčší. Keďže maximálne vierohodný odhad $\hat{\theta}$ je invariantný, môžeme pre $\mathcal{I}(g(\hat{\theta}))$ písať

$$\mathcal{I}(g(\hat{\theta})) = \mathcal{I}(\hat{\theta}) \left[\frac{\partial}{\partial \theta} g(\theta) \Big|_{\theta=\hat{\theta}} \right]^{-2}$$

a pre štandardnú chybu

$$\widehat{SE}[g(\hat{\theta})] = \widehat{SE}(\hat{\theta}) \left| \frac{\partial}{\partial \theta} g(\theta) \Big|_{\theta=\hat{\theta}} \right|$$

Definícia 50 (obojsstranný Waldov $100 \times (1 - \alpha)\%$ empirický IS pre $g(\theta)$) *Obojsstranný Waldov $100 \times (1 - \alpha)\%$ empirický IS pre $g(\theta)$ bude mať tvar*

$$(d_g, h_g) = \left(g(\hat{\theta}) - t_{\alpha/2} \widehat{SE}[g(\hat{\theta})], g(\hat{\theta}) + t_{\alpha/2} \widehat{SE}[g(\hat{\theta})] \right),$$

kde kritická hodnota $t_{\alpha/2}$ závisí na voľbe $g(\hat{\theta})$, pozri napr. kapitole 6.3, 6.4, 7.3 a 7.4. Definícia 50 nie je všeobecne platná. Jednostranné intervaly spoľahlivosti pre $g(\theta)$ je možné zadefinovať podobne.

Definícia 51 (Vierohodnostný $100 \times (1 - \alpha)\%$ empirický IS pre θ) *Vierohodnostný $100 \times (1 - \alpha)\%$ empirický IS pre θ má tvar*

$$\mathcal{CS}_{1-\alpha} = \left\{ \theta : -2 \ln \frac{L(\theta|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})} < \chi_1^2(\alpha) \right\}.$$

Hranice vierohodnostného $100 \times (1 - \alpha)\%$ empirického IS pre θ odvodíme nasledovne

$$\Pr \left(\frac{L(\theta|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})} > c_\alpha \right) = \Pr \left(-2 \ln \frac{L(\theta|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})} < -2 \ln c_\alpha \right) = 1 - \alpha,$$

kde $c_\alpha = e^{-\frac{1}{2}\chi_1^2(\alpha)}$. Ak $1 - \alpha = 0.95$, potom $c_\alpha = 0.1465001 \doteq 0.15$ (15% cut-off štandardizovanej funkcie vierohodnosti $\mathcal{L}(\theta|\mathbf{x}) = L(\theta|\mathbf{x})/L(\hat{\theta}|\mathbf{x})$), ak $1 - \alpha = 0.90$, potom $c_\alpha = 0.2585227 \doteq 0.26$ (26% cut-off) a ak $1 - \alpha = 0.99$, potom $c_\alpha = 0.0362452 \doteq 0.04$ (4% cut-off).

Oba IS pre θ sú vytvorené na základe asymptotickej teórie, ale vierohodnostný interval má lepšie asymptotické vlastnosti ako Waldov IS. Waldov IS je správny, ak platí

$$\frac{\hat{\theta} - \theta}{\widehat{SE}[\hat{\theta}]} \mathcal{D} N(0, 1).$$

Na základe invariantnosti pomeru vierohodnosti je vierohodnostný IS správny, ak existuje transformácia $g(\cdot)$ (ktorá nemusí byť známa), pre ktorú platí

$$\frac{g(\hat{\theta}) - g(\theta)}{\widehat{SE}[g(\hat{\theta})]} \mathcal{D} N(0, 1).$$

Nech (D_g, H_g) je $100(1 - \alpha)\%$ IS pre $g(\theta)$, t.j. $D_g < g(\theta) < H_g$. Na základe asymptotickej normality $g(\hat{\theta})$ je IS (D_g, H_g) vierohodnostný IS pre $g(\theta)$ určený $c_\alpha\%$ cut-off štandardizovanej funkcie vierohodnosti $\mathcal{L}(\theta|\mathbf{x})$. Invariancia pomeru vierohodnosti implikuje tvrdenie, že vierohodnostný IS pre θ určený $c_\alpha\%$ cut-off štandardizovanej funkcie vierohodnosti je rovný

$$((g(D_g))^{-1}, (g(H_g))^{-1}), \text{ kde } (g(D_g))^{-1} < \theta < (g(H_g))^{-1},$$

ktorý má koeficient spoľahlivosti rovný $100 \times (1 - \alpha)\%$. Toto tvrdenie platí, aj keď $g(\cdot)$ neexistuje a navyše vierohodnostný IS je automaticky IS s najlepšou možnou (normalizujúcou) transformáciou. Najväčším problémom Waldovho IS je, že ak $\hat{\theta}$ nemá normálne rozdelenie a ak chceme θ transformovať kvôli „vylepšeniu“ normality, musíme túto transformáciu poznať. Vierohodnostný IS automaticky aplikuje túto najlepšiu transformáciu. Z toho vyplýva, že aplikovateľnosť vierohodnostného IS je oveľa širšia ako Waldovho IS. Okrem toho je použitie vierohodnostného IS bezpečnejšie vo vzťahu k asymptotickej normalite. Tento fakt zdôrazňuje aj to, že Waldova testovacia štatistika nie je invariantná na transformáciu $g(\cdot)$, kde dôvodom tejto neinvariantnosti je zvyšok v Taylorovom rozvoji. Jeho efekt môže byť o to väčší, o čo nelineárnejšie je $g(\cdot)$ v okolí $\hat{\theta}$.

Príklad 161 (vylepšená vierohodnosť pomocou $g(\theta)$) Nakreslite (a) logaritmus funkcie vierohodnosti parametra p binomického rozdelenia $\text{Bin}(N, p)$, kde $N = 10$ a $n = 8$, superponovaný jeho kvadratickou aproximáciou. Nakreslite (b) logaritmus funkcie vierohodnosti $g(p) = \text{logit}(p) = \ln \frac{p}{1-p}$ (pri rovnakom zadani N a n ako v (a)) superponovaný jeho kvadratickou aproximáciou. Je funkcia vierohodnosti $g(p)$ regulárnejšia ako funkcia vierohodnosti pre p ? (c) Vypočítajte Waldov a vierohodnostný $100 \times (1 - \alpha)\%$ empirický IS pre p . (d) Vypočítajte Waldov $100 \times (1 - \alpha)\%$ empirický IS pre $g(p)$ z (a) a (b) a transformujte ho späť do originálnej škály. (e) Ukážte, že vierohodnostný IS pre p v škále p je identický s vierohodnostným IS v škále $g(p)$ z (a) a (b) po jeho spätnej transformácii do originálnej škály.

Riešenie (aj v \mathbb{R} , pozri obrázok 4.10)

Waldov $100 \times (1 - \alpha)\%$ empirický IS pre p :

$$\hat{p} = \frac{8}{10} = 0.8; \widehat{SE}[\hat{p}] = \sqrt{\frac{\hat{p}(1-\hat{p})}{N}} = 0.13.$$

$$(d, h) = \left(\hat{p} - u_{\alpha/2} \widehat{SE}[\hat{p}], \hat{p} + u_{\alpha/2} \widehat{SE}[\hat{p}] \right) = (0.55, 1.05), \text{ kde je horná hranice väčšia ako jedna.}$$

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický IS pre p :

$$\mathcal{CS}_{1-\alpha} = \left\{ p : -2 \ln \frac{L(p|\mathbf{x})}{L(\hat{p}|\mathbf{x})} \leq 3.84 \right\}, \text{ kde } (d, h) = (0.50, 0.96),$$

Waldov $100 \times (1 - \alpha)\%$ empirický IS pre $g(p)$:

$$g(\hat{p}) = \ln \frac{\hat{p}}{1-\hat{p}} = \log \frac{0.8}{0.2} = 1.39.$$

$$\frac{\partial}{\partial p} g(p) = \frac{1}{p} + \frac{1}{1-p}; \widehat{SE}[g(\hat{p})] = \widehat{SE}[\hat{p}] \left(\frac{1}{\hat{p}} + \frac{1}{1-\hat{p}} \right) = \sqrt{\frac{\hat{p}(1-\hat{p})}{N}} \left(\frac{1}{\hat{p}} + \frac{1}{1-\hat{p}} \right) = \sqrt{\frac{1}{n} + \frac{1}{N-n}} = 0.79.$$

Potom $(d_g, h_g) = (-0.16, 2.94)$, ktorý transformujeme späť do originálnej škály, kde $(d, h) = (0.46, 0.95)$.

```


496 x <- 8; N <- 10
497 pcka <- seq(0.4, .99, length=100)
498 like <- dbinom(8, 10, pcka)
499 like1 <- like / max(like)
500 ll <- log(like1)
501 vier.is.p <- range(pcka[like1 > cutoff]) # 0.5013131 0.9602020
502
503 windows(8, 4)
504 par(mfcol=c(1, 2), mar=c(4.5, 4.5, 1, 1))
505 p.hat <- x/N
506 i.hat <- N/p.hat/(1-p.hat)
507 la <- -i.hat/2*(pcka-p.hat)^2
508 ra <- range(ll)
509 wald.is.p <- p.hat + c(-1, 1)*qnorm(0.975)*sqrt(1/i.hat)
510 wald.is.p # 0.552082 1.047918
511 cutoff <- exp(-1/2*qchisq(0.95, 1)) # 0.1465001
512
513 plot(pcka, ll, type="n", xlab="p", ylab="logaritmus_funkcie_vierohodnosti",
514      lwd=2, cex.lab=1.2)
515 lines(pcka, ll, lwd=1)
516 lines(pcka, la, lty=2, lwd=2)
517 abline(h=log(cutoff), col="gray")
518
519 gpcka <- log(pcka) - log(1-pcka)
520 gp.hat <- log(p.hat) - log(1-p.hat)
521 i.hat <- x*(N-x)/N
522 lgp <- -i.hat/2*(gpcka-gp.hat)^2
523 x <- (gp.hat + c(-1, 1)*qnorm(0.975)*sqrt(1/i.hat)) # -0.1631932 2.9357819
524 wald.is.gp <- exp(x)/(1+exp(x))
525 wald.is.gp # 0.4593 0.9496
526

```

```

527 plot(gpcka, ll, type="n", xlab="g(p)", ylab="logaritmus_funkcie_vierohodnosti",
528       lwd=2, cex.lab=1.2)
529 lines(gpcka, ll, lwd=1)
530 lines(gpcka, lgp, lty=2, lwd=2)
531 abline(h=log(cutoff), col="gray")
532
533 b <- range(gpcka[like1 > cutoff])
534 vier.is_gp <- exp(b)/(1+exp(b)) # 0.5013131 0.9602020

```



Obr. 4.10: Funkcia vierohodnosti (plnú čiarou) pre p (vľavo) a $g(p)$ vpravo spolu so superponovanými kvadratickými aproximáciami (čiarkovanou čiarou); horizontálna priamka predstavuje hodnotu *cut-off*

*Výpočet hraníc vierohodnostného intervalu spoľahlivosti

V príklade 161 sme hranice vierohodnostného empirického IS počítali pre θ patriace nejakému dopredu špecifikovanému intervalu s hranicami θ_D a θ_H , dosadením sekvencie hodnôt $\theta_i \in \langle \theta_D, \theta_H \rangle$, $i = 1, 2, \dots, M$ (pre napr. $M = 100$ tak, aby boli vzdialenosti θ_i čo najmenešie), do funkcie $-2 \ln \mathcal{L}(\theta_i | \mathbf{x})$. Hranice vierohodnostného $100 \times (1 - \alpha)\%$ empirického IS pre θ budú potom predstavovať dolnú a hornú hranicu intervalu definovanej pomocou nerovnosti $-2 \ln \mathcal{L}(\theta | \mathbf{x}) < \chi_1^2(\alpha)$, ktoré vypočítame pomocou funkcie `range(ll)`, kde `ll` je funkcia $-2 \ln \mathcal{L}(\theta | \mathbf{x})$. Alternatívnou možnosťou je použitie **metódy bisekcie**² (Givens a Hoeting, 2005).

Nech pre nejaké $\theta_{01}, \theta_{02} \in \langle \theta_D, \theta_H \rangle$ platí $f(\theta_{01})f(\theta_{02}) < 0$ (t.j. $f(\cdot)$ má na intervale $\langle \theta_{01}, \theta_{02} \rangle$ aspoň jeden koreň), kde $f(\theta) = -2 \ln \mathcal{L}(\theta | \mathbf{x}) - \chi_1^2(\alpha) = 0$. Ak má prvá derivácia $f(\cdot)$ konštantné znamienko, potom existuje práve jeden koreň $\theta^* \in \langle \theta_{01}, \theta_{02} \rangle$ funkcie $f(\theta)$. Metóda bisekcie hľadá koreň nasledovným iteračným algoritmom:

1. inicializácia metódy pomocou vhodne zvoleného štartovacieho parametra $\theta^{(0)}$, pre ktorý platí $\theta^{(0)} = (\theta_{01} + \theta_{02})/2$ a $i = 1$,
2. substitúcia hraníc θ_{01} a θ_{02} nasledovne

$$\langle \theta_{i1}, \theta_{i2} \rangle = \begin{cases} \langle \theta_{i-1,1}, \theta^{(i-1)} \rangle, & \text{ak } f(\theta_{i-1,1})f(\theta^{(i-1)}) < 0 \\ \langle \theta^{(i-1)}, \theta_{i-1,2} \rangle, & \text{ak } f(\theta_{i-1,1})f(\theta^{(i-1)}) > 0 \end{cases}$$

ak $f(\theta^{(i-1)}) = 0$, potom algoritmus skončí, ak nie, nasleduje

3. výpočet stredy intervalu $\theta^{(i)} = (\theta_{i1} + \theta_{i2})/2$,
4. iterácia (2) a (3) pomocou *relatívnej aproximačnej chyby* (hovoríme o *relatívnom konvergenčnom kritériu*) pokiaľ nebude platiť

$$\frac{|\theta^{(i)} - \theta^{(i-1)}|}{|\theta^{(i-1)}|} < \epsilon,$$

²Ak sú metóda bisekcie a jej modifikácie aplikované na skóre funkciu $S(\theta)$, kde $f(\theta) = l(\theta | \mathbf{x})$, hľadáme maximum logaritmu funkcie vierohodnosti, a preto sa značenie všade posunie o jednu deriváciu smerom doprava. Ak sa v metódach z kapitoly 2.4 *Maximalizácia funkcie vierohodnosti posunie značenie o jednu deriváciu smerom doľava, je možné tieto metódy použiť aj na hľadanie hraníc vierohodnostného IS.

kde ϵ je vhodne zvolené malé číslo (prahová hodnota), pomocou *absolútnej aproximačnej chyby* (hovoríme o *absolútnom konvergenčnom kritériu*) pokiaľ nebude platiť

$$\left| \theta^{(i)} - \theta^{(i-1)} \right| < \epsilon,$$

alebo pomocou

$$\left| f(\theta^{(i)}) \right| < \epsilon.$$

Metóda bisekcie konverguje lineárne (rád metódy je rovný jednej), t.j. chyba sa znižuje v každom kroku dvakrát. V i -tom kroku bude menšia alebo rovná ako $(\theta_{02} - \theta_{01})/2^{i+1}$. Pretože je konvergencia bisekčnej metódy pomalá (vyžaduje veľké množstvo iterácií na dosiahnutie stanovenej presnosti), bolo vytvorených niekoľko jej modifikácií, ktoré sa dajú zahrnúť pod anglický pojem *bracketing methods*, t.j. metód ktoré ohraničujú koreň vnútri sekvencie vnorených intervalov znižujúcej sa dĺžky. Z nich je najčastejšie používanou je **Brentova metóda** (Brent (1973); niekedy nazývaná aj **Brent-Dekkerova metóda**) pomenovaná podľa Richarda Peirce Brenta (1949–). Kombinuje metódu bisekcie s inverznou lineárnou alebo kvadratickou interpoláciou. Ak je použitá inverzná lineárna interpolácia, potom ide o metódu ekvivalentnú **metóde sečníc**, ktorá modifikuje krok (3) nasledovne

$$\theta^{(i)} = \begin{cases} \theta^{(i-1)} - \frac{\theta^{(i-1)} - \theta^{(i-2)}}{f(\theta^{(i-1)}) - f(\theta^{(i-2)})} f(\theta^{(i-1)}), & \text{ak } f(\theta^{(i-1)}) \neq f(\theta^{(i-2)}), \\ (\theta_{i1} + \theta_{i2})/2, & \text{inak} \end{cases},$$

kde aproximácia prvej derivácie $f'(\theta^{(i-1)}) \approx \frac{f(\theta^{(i-1)}) - f(\theta^{(i-2)})}{\theta^{(i-1)} - \theta^{(i-2)}}$. Metóda sečníc má jednoduchú geometrickú interpretáciu – bod $\theta^{(i)}$ je priesečník sečnice vedenej bodmi $[\theta^{(i-1)}, f(\theta^{(i-1)})]$ a $[\theta^{(i-2)}, f(\theta^{(i-2)})]$ s x -ovou osou. Ak je $f(\theta)$ dvakrát diferencovateľná, funkcia $f(\theta)$ má jednoduchý koreň ($f'(\theta) \neq 0$ pre každé $\theta \in (\theta_D, \theta_H)$), potom metóda konverguje, pokiaľ zvolíme θ_{01}, θ_{02} dostatočne blízko hľadaným hraniciam IS (rád metódy je rovný $(1 + \sqrt{5})/2 \doteq 1.618$).

Brentova metóda modifikuje metódu sečníc na zrýchlenie konvergence pridaním ďalších podmienok v kroku (3). Je implementovaná v \mathbb{R} vo funkcii `uniroot(f, interval, tol, ...)`, ktorá hľadá korene funkcie f v danom intervale špecifikovanom v argumente `interval`. Konvergencia metódy môže byť kontrolovaná argumentom `tol`, čo je prahová hodnota ϵ . Pri hľadaní hraníc vierohodnostného $100 \times (1 - \alpha)\%$ IS je potrebné funkcii `uniroot()` použiť dvakrát nasledovne:

1. pre dolnú hranicu IS definujeme štartovací interval ako $\langle \theta_D, \hat{\theta} \rangle$,
2. pre hornú hranicu IS definujeme štartovací interval ako $\langle \hat{\theta}, \theta_H \rangle$.

Vo výstupoch funkcie `uniroot()` bude pre (1) odhad dolnej hranice IS $\hat{\theta}_D$ a pre (2) odhad hornej hranice IS $\hat{\theta}_H$ (`root`), hodnota funkcie f v odhadnutých hraniciach, pre (1) $f(\hat{\theta}_D)$ a pre (2) $f(\hat{\theta}_H)$, ozn. `froot` a odhadnutá výchylka od skutočného koreňa `estim.perc`. Ak má funkcia $f(\theta)$ viac ako jeden argument, argument θ musí byť ako prvý.

Príklad 162 (vylepšená vierohodnosť pomocou $g(\theta)$; pokrač.) *Vypočítajte vierohodnostný 95% empirický IS pre p pomocou Brentovej metódy pre dáta z príkladu 161. Porovnajme tento IS s IS vypočítaným v príklade 161.*

Riešenie (aj v \mathbb{R})

Vierohodnostný 95% empirický IS pre p :

$\mathcal{CS}_{1-\alpha} = \left\{ p : -2 \ln \frac{L(p|\mathbf{x})}{L(\hat{p}|\mathbf{x})} \leq 3.84 \right\}$, kde $(d, h) = (0.50, 0.96)$.

Hranice IS vypočítané oboma metódami sa zhodujú na dve desatinné miesta.

```
535 | x <- 8; N <- 10
536 | p.hat <- x/N
537 | "||" <- function(p, p.hat) {
538 |   -2*log(dbinom(8, 10, p)/dbinom(8, 10, p.hat)) - qchisq(0.95, 1)
539 | }
540 | vier.is.p.brent <- c(uniroot(||, c(0, p.hat)), p.hat=x/N)$root,
541 |                   uniroot(||, c(p.hat, 1)), p.hat=x/N)$root)
542 | vier.is.p.brent # 0.5005669 0.9636336
```

5 Testy dobrej zhody

V štatistickej inferencii často predpokladáme, že dáta pochádzajú z normálneho rozdelenia $N(\mu, \sigma^2)$. Na identifikáciu rozdelenia, z ktorého dáta pochádzajú, potrebujeme **testy dobrej zhody**, kde nulovou hypotézou je tvrdenie o (kumulatívnej) distribučnej funkcii. Ak sú pre nulovú hypotézu všetky potrebné parametre rozdelenia špecifikované, hovoríme o **jednoduchej nulovej hypotéze**. Ak nulová hypotéza presne nešpecifikuje všetky potrebné parametre rozdelenia, hovoríme o **zloženej nulovej hypotéze**. V nasledujúcich odstavcoch prezentujeme dva typy testov – χ^2 **test dobrej zhody** (primárne vytvorený pre diskkrétne dáta) a **Kolmogrov-Smirnovov test dobrej zhody** (vytvorený pre spojité dáta).

5.1 χ^2 test dobrej zhody

Majme jednoduchý náhodný výber s rozsahom n s neznámou populačnou distribučnou funkciou $F(x)$. Nulovú hypotézu špecifikujeme ako „ $F(x)$ má nejaké známe rozdelenie $F_0(x)$ pre všetky x “ alebo „ $F(x)$ je rovné nejakej známej distribučnej funkcii $F_0(x)$ pre všetky x “, t.j. $H_0 : F(x) = F_0(x)$ pre všetky x . Alternatívnu hypotézu špecifikujeme ako „ $F(x)$ nie je rovné nejakej známej distribučnej funkcii $F_0(x)$ pre nejaké x “, t.j. $H_1 : F(x) \neq F_0(x)$ pre nejaké x .

χ^2 test dobrej zhody je založený na normalizovanej testovacej štatistike, ktorá hodnotí vertikálne rozdiely medzi pozorovanými a očakávanými hodnotami (ak H_0 platí) v k disjunktných kategóriách. Dáta je teda potrebné rozdeliť do týchto kategórií na základe vopred určenej schémy a vypočítať početnosti v nich. Tieto nazývame **pozorované početnosti**. Ak H_0 úplne špecifikuje populáciu, z ktorej pochádza náhodný výber, môžeme vypočítať pravdepodobnosť, že náhodné pozorovanie padne do jednej z k kategórií, čomu hovoríme **očakávané pravdepodobnosti**. Pokiaľ tieto pravdepodobnosti vynásobíme rozsahom n , dostaneme **očakávané početnosti** pre každú kategóriu za platnosti H_0 .

■ Ak H_0 platí, rozdiel medzi pozorovanými a očakávanými početnosťami bude malý. χ^2 **testovacia štatistika** na testovanie H_0 oproti H_1 , ak je H_0 úplne špecifikovaná, má tvar

$$\chi^2 = \sum_{j=1}^k \frac{(\text{pozorované}_j - \text{očakávané}_j)^2}{\text{očakávané}_j} = \sum_{j=1}^k \frac{(O_j - E_j)^2}{E_j} \stackrel{\mathcal{D}}{\sim} \chi_{df}^2,$$

kde O_j sú pozorované početnosti, E_j očakávané početnosti v každej z k kategórií. Stupne voľnosti $df = k - 1$, ak je H_0 jednoduchá. Test sa nazýva **jednovýberový χ^2 -test dobrej zhody**. Ak je však H_0 zložená, musíme odpočítať jednotku za každý odhadovaný parameter, t.j. ak je počet odhadovaných parametrov k_p , potom $df = k - k_p - 1$, kde $k_p < k - 1$. Veľké hodnoty realizácie χ^2 , ozn. χ_{obs}^2 , budú indikovať nekonzistenciu dát s H_0 (nedostatok dôkazov na jej zamietnutie).

Príklad 163 (χ^2 -test dobrej zhody) Majme dáta *Grades* z knižnice *PASWR*, ktoré reprezentujú SAT skóre ($n = 200$) náhodne vybranej vzorky študentov z jednej univerzity v USA. Otestujte na hladine významnosti $\alpha = 0.05$, či majú dáta normálne rozdelenie. Použite intervaly $(\mu - 3\sigma, \mu - 2\sigma)$, $(\mu - 2\sigma, \mu - \sigma)$, $(\mu - \sigma, \mu)$, $(\mu, \mu + \sigma)$, $(\mu + \sigma, \mu + 2\sigma)$ a $(\mu + 2\sigma, \mu + 3\sigma)$. Nakreslite histogram použitím vyššie spomenutých intervalov a superponujte ho s očakávanými hodnotami SAT skóre v každej kategórii, keď $F_0(x) \sim N(\mu, \sigma^2)$.

Riešenie (aj v \mathbb{R} ; pozri tabuľku 5.1)

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : SAT skóre majú normálne rozdelenie (ich distribučná funkcia pochádza z normálneho rozdelenia) oproti H_1 : SAT skóre nemajú normálne rozdelenie (ich distribučná funkcia nepochádza z normálneho rozdelenia).

- **matematická formulácia** – testujeme $H_0 : F(x) = F_0(x) \sim N(\mu, \sigma^2)$ oproti $H_1 : F(x) \neq F_0(x)$ pre nejaké x .
2. **Testovacia štatistika** – Stredná hodnota μ a rozptyl σ^2 sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetický priemer $\bar{x} = 1134.65$ a rozptyl $s^2 = 21201.89$ (smerodajná odchýlka $s = 145.61$).

```
543 | library(PASWR) # nactanie kniznice
544 | attach(Grades)
545 | priemer <- mean(sat) # 1134.6500
546 | smerodch <- sd(sat) # 145.6087
547 | n <- length(sat) # 200
```

Intervaly zo zadania sú $\langle 697.8240, 843.4326 \rangle$, $\langle 843.4326, 989.0413 \rangle$, $\langle 989.0413, 1134.6500 \rangle$, $\langle 1134.6500, 1280.2587 \rangle$, $\langle 1280.2587, 1425.8674 \rangle$ a $\langle 1425.8674, 1571.4760 \rangle$. Dáta budú rozdelené na kategórie nasledovne

```
548 | bin <- seq(priemer-3*smerodch, priemer+3*smerodch, smerodch) # kategorie
549 | table(cut(sat, breaks=bin))
550 | poz.poc <- hist(sat, breaks=bin, plot=F)$counts # pozorovane pocetnosti
551 | ocak.prav <- c(pnorm(-2), pnorm(-1:2) - pnorm(-2:1), 1-pnorm(2))
552 | ocak.poc <- n*ocak.prav # ocakavane pocetnosti
553 | VVSL <- cbind(ocak.prav, ocak.poc, poz.poc)
```

Tabuľka 5.1: Očakávané pravdepodobnosti a početnosti a pozorované početnosti pre SAT skóre

interval	$f_0(x)$	$nf_0(x)$	n_i
$\langle \mu - 3\sigma, \mu - 2\sigma \rangle$	0.02275	4.55003	4
$\langle \mu - 2\sigma, \mu - \sigma \rangle$	0.13591	27.18102	27
$\langle \mu - \sigma, \mu \rangle$	0.34135	68.26895	65
$\langle \mu, \mu + \sigma \rangle$	0.34135	68.26895	80
$\langle \mu + \sigma, \mu + 2\sigma \rangle$	0.13591	27.18102	21
$\langle \mu + 2\sigma, \mu + 3\sigma \rangle$	0.02275	4.55003	3

Pozorovaná testovacia štatistika je potom rovná $\chi_{\text{obs}}^2 = 4.17$.

```
554 | chisq.obs <- sum((poz.poc-ocak.poc)^2/ocak.poc) # 4.173654
```

3. **Zamietacia oblasť** – H_0 bude zamietnutá, ak $\chi_{\text{obs}}^2 > \chi_{\alpha}^2(df)$, kde $df = k - 1 = 6 - 1 = 5$, ak by sme neodhadovali žiaden parameter rozdelenia. My však odhadujeme dva, preto $df = 6 - 2 - 1 = 3$, $\chi_{1-\alpha}^2(df) = \chi_{0.05}^2(3)$ je kritická hodnota.
4. **Štatistický záver** – p-hodnota=0.24.


```
555 | p.hodn <- 1-pchisq(chisq.obs,5) # 0.5246948 [ak df=5]
556 | p.hodn <- 1-pchisq(chisq.obs,3) # 0.2433129
```

Kedže p-hodnota nie je menšia ako hladina významnosti $\alpha = 0.05$ (ekvivalentne χ_{obs}^2 nepatrí do zamietacej oblasti), H_0 nezamietame na hladine významnosti α . Je možné použiť aj funkciu `chisq.test(x=poz.poc,p=ocak.prav)`.

5. **Slovný záver** – Nemáme dostatok dôkazov na zamietnutie nulovej hypotézy o tom, že skutočnou distribučnou funkciou SAT skóre je distribučná funkcia normálneho rozdelenia.

Histogram superponovaný s očakávanými hodnotami SAT skóre v každej kategórii nakreslíme nasledovne (pozri obrázok 5.1)

```
557 | windows(5, 5)
558 | par(mar=c(4.5, 4.5, 1, 1))
559 | hist(sat, breaks=bin, col="gray", ylab=" hustota", freq=TRUE, main="", cex.lab=1.2)
560 | x <- bin[2:7] - smerodch/2 # centrovanie do stredu intervalov
561 | lines(x, ocak.poc, type="h", lwd=2)
562 | points(x, ocak.poc, pch=16)
```



Obr. 5.1: Histogram superponovaný s očakávanými hodnotami SAT skóre

Príklad 164 (χ^2 -test dobrej zhody; pokrač.) Zopakujte výpočet z predchádzajúceho príkladu na intervaloch definovaných pomocou hraníc:

(a) kvartilové hranice – $x_{min}, \tilde{x}_{0.25}, \tilde{x}_{0.50}, \tilde{x}_{0.75}, x_{max}$;

(b) decilové hranice – $x_{min}, \tilde{x}_{0.1}, \tilde{x}_{0.2}, \dots, \tilde{x}_{0.8}, \tilde{x}_{0.9}, x_{max}$.

Nakreslite histogram použitím vyššie spomenutých intervalov a superponujte ho s očakávanými hodnotami SAT skóre v každej kategórii, keď $F_0(x) \sim N(\mu, \sigma^2)$. Porovnajete výsledky s výsledkami predchádzajúceho príkladu.

Príklad 164 vysvetľuje efekt zmeny intervalov na výsledok testu dobrej zhody s normálnym rozdelením.

Príklad 165 (χ^2 -test dobrej zhody) Johann Gregor Mendel vo svojich pokusoch s krížením rastlín hrachu (*Pisum sativum*) študoval dedičnosť siedmych rôznych znakov. V každom z pokusov, pri sledovaní jedného znaku, získal po krížení dvoch čistých línii (t.j. dominantného homozygota AA s recesívnym homozygotom aa) generáciu, v ktorej mali všetky rastliny rovnaký fenotyp (t.j. heterozygoti Aa). Po ich samooplodnení (čo je prirodzený spôsob rozmnožovania hrachu) získal ďalšiu generáciu, v ktorej sa vyskytovali sledované znaky v dvoch formách, a to zakaždým v pomere veľmi blízkom 3:1. Jedným zo znakov, ktoré študoval, bola farba semien. Po krížení 258 hybridov získal celkovo 8023 semien, z ktorých 6022 bolo žltých a 2001 zelených (Matalová, 2008). Otestujte platnosť fenotypového štiepneho pomeru 3 : 1 na hladine významnosti $\alpha = 0.05$.

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – H_0 : Fenotypový štiepny pomer je rovný 3 : 1 oproti H_1 : fenotypový štiepny pomer nie je rovný 3 : 1.
- **matematická formulácia** – H_0 : $\mathbf{p} = \mathbf{p}_0$, kde $\mathbf{p} = (p_1, p_2)$, $\mathbf{p}_0 = (p_{01}, p_{02})$, $p_{01} = 0.75$ a $p_{02} = 0.25$, oproti H_1 : $\mathbf{p} \neq \mathbf{p}_0$.

2. Testovacia štatistika

– $N = 6022 + 2001 = 8023$, očakávané početnosti $8023 \times 0.75 = 6017.25$ a $8023 \times 0.25 = 2005.75$.

```
563 | poz.poc <- c(6022,2001)
564 | N <- sum(poz)
565 | ocak.prav <- c(0.75,0.25)
566 | ocak.poc <- N*ocak.prav
```

Pozorovaná testovacia štatistika je potom rovná $\chi_{obs}^2 \doteq 0.015$.

```
567 | chisq.obs <- sum((poz.poc-ocak.poc)^2/ocak.poc) # 0.01499855
```

3. **Zamietacia oblasť** – H_0 bude zamietnutá, ak $\chi_{\text{obs}}^2 > \chi_{df}^2(\alpha) \doteq 3.84$, kde $\chi_{df}^2(\alpha)$ je kritická hodnota χ^2 rozdelenia s $df = 2 - 1 = 1$ a $\alpha = 0.05$.

```
568 | chisq.krit <- qchisq(1-0.05,1) # 3.841459
```

4. **Štatistický záver** – p-hodnota = 0.9.

```
569 | p.hodn <- 1-pchisq(chisq.obs, df=1) # 0.902528
```

Kedže p-hodnota nie je menšia ako hladina významnosti $\alpha = 0.05$ (ekvivalentne χ_{obs}^2 nepatrí zamietacej oblasti), H_0 nezamietame na hladine významnosti α . Je možné použiť aj funkciu `chisq.test()` nasledovne

```
570 | VYSL <- chisq.test(x=c(6022,2001),p=c(0.75,0.25))
571 | VYSL <- c(VYSL$stat,VYSL$param,VYSL$p.val)
572 | names(VYSL) <- c("test-stat","df","p-hodn")
573 | VYSL
574 | #test-stat      df      p-hodn
575 | #      0.0150    1.0000    0.9025
```

5. **Slovný záver** – Nemáme dostatok dôkazov na zamietnutie nulovej hypotézy o tom, že skutočný fenotypový pomer je 3 : 1.

Testovať H_0 oproti H_1 môžeme aj MC testom, kde odhadneme p-hodnotu simulačne pomocou $M = 100000$ simulácií z $Bin(N, p)$, kde $N = 8023, p = 0.75$.

```
576 | "chisq.stat" <- function(poz.poc,ocak.prav) {
577 |     N <- sum(poz.poc)
578 |     ocak <- N*ocak.prav
579 |     stat <- sum((poz.poc-ocak.poc)^2/ocak.poc)
580 |     return(stat)
581 | }
582 | M <- 100000
583 | ocak.prav <- c(0.75,0.25)
584 | chisq.obs <- chisq.stat(poz.poc,ocak.prav) # 0.01499855
585 | chisq.sim <- numeric(M)
586 | for(i in 1:M){
587 |   x1 <- rbinom(1,N,0.75)
588 |   x2 <- N - x1
589 |   chisq.sim[i] <- chisq.stat(c(x1,x2),ocak.prav)
590 | }
591 | p.hodn <- mean(chisq.sim>chisq.obs) # 0.89787
```

P-hodnota vypočítaná na základe MC simulácie je veľmi podobná vypočítanej asymptoticky (na dve desatinné miesta sú obe identické), keďže máme veľký počet opakovaní, ako aj veľké početnosti.

Príklad 166 (χ^2 -test dobrej zhody; početnosti úmrtí) *Otestujte zhodu početností X Pruských armádných jednotiek, v ktorých nastalo n úmrtí zapríčinených kopnutím koňom za rok (pozri príklad 78, tabuľka 2.7) s Poissonovým rozdelením s parametrom λ , t.j. $X \sim Poiss(\lambda)$ na hladine významnosti $\alpha = 0.05$.*

Príklad 167 (χ^2 -test dobrej zhody; početnosti chlapcov) *Otestujte zhodu početností rodín X s n chlapcami (pozri príklad 81, tabuľku 2.8 a 2.9) s binomickým rozdelením s parametrami N a π , t.j. $X \sim Bin(N, \pi)$ na hladine významnosti $\alpha = 0.05$.*

Príklad 168 (χ^2 -test dobrej zhody; úrazy robotníkov) *Otestujte zhodu početností robotníkov X s n úrazmi v továrni (pozri príklad 82, tabuľka 2.10 a 2.11; príklad 109, tabuľka 2.14)*
(a) s Poissonovým rozdelením s parametrom λ , t.j. $X \sim Poiss(\lambda)$ a
(b) s negatívne binomickým rozdelením s parametrami α a π , t.j. $Negbinom(\alpha, \pi)$ na hladine významnosti $\alpha = 0.05$.

Príklad 169 (χ^2 -test dobrej zhody; početnosti mužov) *Nech $\Pr(\text{muž}) = 0.515$ znamená pravdepodobnosť výskytu mužov v populácii (pozri príklad 78). Nech sa početnosti mužov X v populácii správajú podľa modelu $\text{Bin}(N, p)$, nazvime ich (v tomto príklade) pozorované početnosti. Aproximujme X normálnym rozdelením $N(Np, Npq)$ a prislúchajúce početnosti nazvime teoretické početnosti (počítame ich v $n = 0, 1, \dots, N$). Otestujte zhodu pozorovaných a teoretických početností na hladine významnosti $\alpha = 0.05$. Nakreslite (1) hustotu normálneho rozdelenia superponovanú pravdepodobnosťou funkciou binomického rozdelenia a (2) distribučnú funkciu normálneho rozdelenia superponovanú distribučnou funkciou binomického rozdelenia. Rozsahy N volíme nasledovne (a) $N = 20$, (b) $N = 50$ a (c) $N = 500$.*

Príklad 170 (χ^2 -test dobrej zhody; fetálna aktivita) *Nech X predstavuje početnosti päťsekundových intervalov (z 240) v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom, v ktorých sa plod ovce n -krát pohol (pozri tabuľku 5.2; Leroux a Puterman (1992)). Vypočítajte očakávané početnosti za predpokladu, že $X \sim \text{Poiss}(\lambda)$. Otestujte zhodu pozorovaných a teoretických početností na hladine významnosti $\alpha = 0.05$.*

Tabuľka 5.2: Pozorované početnosti m_n päťsekundových intervalov v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom, v ktorých sa plod ovce n -krát pohol

n	0	1	2	3	4	5	6	7
pozorované m_n	182	41	12	2	2	0	0	1

Riešenie (aj v \mathbb{R} ; pozri tabuľku 5.3 a 5.4)

$\hat{\lambda} = \frac{\sum_n n m_n}{\sum_n m_n} = \frac{86}{240} = 0.358$. Potom budú čakávané početnosti nasledovné Vzhľadom ku nízkym

Tabuľka 5.3: Očakávané početnosti m_n päťsekundových intervalov v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom (zaokruhlené na nula desatinných miest), v ktorých sa plod ovce n -krát pohol (Poissonovo rozdelenie)

n	0	1	2	3	4	5	6	7
m_n	182	41	12	2	2	0	0	1
očakávané m_n	168	60	11	1	0	0	0	0

početnostiam pre $n > 2$, m_n nim zodpovedajúce zahrnieme do jednej skupiny. Potom $\chi_{\text{obs}}^2 \doteq 16.57$ a p -hodnota $\doteq 0.0025$ ($df = k - k_p - 1 = 2$, kde $k = 4$ a $k_p = 1$).

```

592 | n <- 0:7
593 | m.n <- c(182, 41, 12, 2, 2, 0, 0, 1)
594 | lambda.hat <- sum(n*m.n)/sum(m.n)
595 | oca.k.poc <- dpois(n, lambda.hat)*sum(m.n)
596 | m.n.new <- c(m.n[1:3], sum(m.n[4:8]))
597 | oca.k.poc.new <- c(oca.k.poc[1:3], sum(oca.k.poc[4:8]))
598 | chi.obs <- sum((m.n.new-oca.k.poc.new)^2/oca.k.poc.new) # 16.56523
599 | 1-pchisq(chi.obs, df=2) # 0.0002528748

```

Ak máme v pozorovaných početnostiach príliš veľa núl (ide o *overdispersion*, tak ako v príklade 170), vhodným alternatívnym modelom bude **ZIP model** (z angličtiny *zero-inflated Poisson model*; Lambert 1992), kde

$$\Pr(X = x) = pI(x = 0) + (1 - p)f(x, \lambda) = \begin{cases} p + (1 - p)f(0, \lambda), & x = 0 \\ (1 - p)f(n, \lambda), & x = 1, 2, \dots \end{cases}$$

kde $p \in (0, 1)$ a $x = n$. Potom bude funkcia vierohodnosti pre **ZIP model** definovaná nasledovne

$$L((\lambda, p)^T | \mathbf{x}) = (p + (1 - p)f(0, \lambda))^{m_0} \prod_{I(n > 0)} (1 - p)^{m_n} f(n, \lambda).$$

Logaritmus funkcie vierohodnosti pre ZIP model je rovný

$$l((\lambda, p)^T | \mathbf{x}) = m_0 \log(p + (1-p)f(0, \lambda)) + \sum_{I(n>0)} m_n \log((1-p)f(x, \lambda)).$$

Príklad 171 (χ^2 -test dobrej zhody; fetálna aktivita) *Majme dáta z príkladu 170. Vypočítajte očakávané početnosti za predpokladu, že $X \sim ZIP(\lambda, n)$. Otestujte zhodu pozorovaných a teoretických početností na hladine významnosti $\alpha = 0.05$.*

Riešenie (aj v \mathbb{R})

$$\hat{\lambda} = 0.847 \text{ a } \hat{p} = 0.577.$$

Tabuľka 5.4: Očakávané početnosti m_n päťsekundových intervalov v posledných 2/3 ťarchavosti zaznamenaných ultrazvukom (zaokrúhlené na nula desatinných miest), v ktorých sa plod ovce n -krát pohol (ZIP rozdelenie)

n	0	1	2	3	4	5	6	7
m_n	182	41	12	2	2	0	0	1
očakávané m_n	182.00	36.86	15.61	4.41	0.93	0.16	0.02	0.00

Vzhľadom ku nízkym početnostiam pre $n > 2$, nim zodpovedajúce m_n zahrnieme do jednej skupiny. Potom $\chi_{\text{obs}}^2 \doteq 1.35$ a p -hodnota $\doteq 0.245$ ($df = k - k_p - 1 = 1$, kde $k = 4$ a $k_p = 2$).

```
600 "||.zip" <- function(theta){
601   n <- 0:7
602   m.n <- c(182,41,12,2,2,0,0,1)
603   m0 <- m.n[1]
604   if(((theta[2]+(1-theta[2]))==1)
605     {ll <- m0*log(theta[2]+(1-theta[2]))*dpois(0,theta[1]))+
606       sum(m.n[2:8]*log((1-theta[2])*dpois(n[2:8],theta[1]))))
607   return(ll)
608 }
609 OPTtheta <- optim(c(0.358,0.5),||.zip,control=list(fnscale=-1))
610 theta.hat <- OPTtheta$par # 0.8473558 0.5770943
611 lambda.hat <- theta.hat[1]
612 p.hat <- theta.hat[2]
613 ocak.poc <- c(p.hat+(1-p.hat)*dpois(0,lambda.hat),
614             (1-p.hat)*dpois(1:7,lambda.hat))*sum(m.n)
615 round(ocak.poc,2)
616 #[1] 182.00 36.86 15.61 4.41 0.93 0.16 0.02 0.00
617 m.n.new <- c(m.n[1:3],sum(m.n[4:8]))
618 ocak.poc.new <- c(ocak.poc[1:3],sum(ocak.poc[4:8]))
619 chi.obs <- sum((m.n.new-ocak.poc.new)^2/ocak.poc.new) # 1.353315
620 1-pchisq(chi.obs,df=1) # 0.2446995
```

V príkladoch 170 a 171 bola použitá $\hat{\lambda}$ vypočítaná zo všetkých m_n , ale v χ^2 teste dobrej zhody boli použité m_n spojením viacerých $n > 2$. Chernoff a Lehmann (1954) ukázali, že asymptotické rozdelenie χ^2 štatistiky vytvorenej na základe $\hat{\lambda}$ vypočítanej zo všetkých m_n konverguje ku sume χ^2 štatistiky s $df = k - k_p - 1$ a váženej sume k_p štatistík χ^2 s $df = 1$. Z toho vyplýva, že použitie $\chi_{k-k_p-1}^2$ je *liberálne*, t.j. aktuálna (skutočná) hladina významnosti presiahne nominálnu hladinu významnosti. *Konzervatívnym* prístupom je použitie χ_{k-1}^2 . Odhad $\hat{\lambda}$ vypočítaný použitím zoskupených m_n je robustnejší na odľahlé pozorovania ako odhad $\hat{\lambda}$ vypočítaný použitím pozorovaných m_n (Cressie a Read, 1984).

Pre dáta z príkladu 170 potom konzervatívny prístup vedie k použitiu χ_3^2 , kde $\chi_{\text{obs}}^2 \doteq 16.57$ a p -hodnota $\doteq 0.00087$ (porovnaj s liberálnou p -hodnotou $\doteq 0.00025$). Pre dáta z príkladu 171 potom konzervatívny prístup tiež vedie k použitiu χ_3^2 , kde $\chi_{\text{obs}}^2 \doteq 1.35$ a p -hodnota $\doteq 0.717$ (porovnaj s liberálnou p -hodnotou $\doteq 0.245$).

Správny prístup predstavuje použitie $\hat{\lambda}$ vypočítanej zo zoskupených m_n a následné použitie χ^2 testu dobrej zhody tiež zo zoskupených m_n . Pre príklad 170 bude mať jadro funkcie vierohodnosti nasledovný tvar

$$L(\lambda | \mathbf{x}) = \left(\frac{\lambda^0 e^{-\lambda}}{0!} \right)^{182} \left(\frac{\lambda^1 e^{-\lambda}}{1!} \right)^{41} \left(\frac{\lambda^2 e^{-\lambda}}{2!} \right)^{12} \left(\sum_{n=3}^{\infty} \frac{\lambda^n e^{-\lambda}}{n!} \right)^5.$$

Potom $\hat{\lambda} \doteq 0.335$, $\chi_{\text{obs}}^2 \doteq 20.237$ a p-hodnota $\doteq 0.00004$ ($df = 2$). Pre príklad 171 bude mať jadro funkcie vierohodnosti nasledovný tvar

$$L((\lambda, p)^T | \mathbf{x}) = (p + (1-p)f(0, \lambda))^{182} (1-p)^{41} f(1, \lambda) (1-p)^{12} f(2, \lambda) (1-p)^5 \prod_{n=3}^{\infty} f(n, \lambda).$$

Potom $\hat{\lambda} \doteq 0.954$, $\hat{p} \doteq 0.607$, $\chi_{\text{obs}}^2 \doteq 2.415$ a p-hodnota $\doteq 0.1202$ ($df = 1$).

5.2 Kolmogorov-Smirnov test dobrej zhody

Detaily Kolmogorov-Smirnovovho testu dobrej zhody sa odlišujú od χ^2 testu dobrej zhody, avšak princíp výpočtu vertikálnych vzdialeností je zachovaný. Teraz ale používame všetkých n pozorovaní a počítame vertikálny rozdiel medzi (kumulatívnou) distribučnou funkciou $F_0(x)$, kde máme všetky parametre rozdelenia špecifikované a empirickou (kumulatívnou) distribučnou funkciou $\hat{F}_n(x)$ pre všetky x .

Za platnosti H_0 bude vzdialenosť medzi $F_0(x)$ a $\hat{F}_n(x)$ malá pre všetky x . **Jednovýberová Kolmogorov-Smirnovova testovacia štatistika** je definovaná nasledovne

$$D_n = \sup_{\forall x} |\hat{F}_n(x) - F_0(x)|.$$

D_n nezávisí na $F_0(x)$, ak je $F(x)$ spojitá. Test sa nazýva **jednovýberový Kolmogorov-Smirnov test dobrej zhody**. Je potrebné zdôrazniť, že D_n môžeme použiť, len ak je hypotéza jednoduchá. Empirická distribučná funkcia je definovaná nasledovne

$$\hat{F}_n(x) = \sum_{i=1}^n I(x_i \leq x) / n$$

alebo alternatívne ako

$$\hat{F}_n(x) = \begin{cases} 0, & \text{ak } x < x_{(1)}, \\ \frac{i}{n}, & \text{ak } x_{(i)} \leq x < x_{(i+1)}, \\ 1, & \text{ak } x \geq x_{(n)}. \end{cases}$$

Ak sa nevyskytujú v pozorovaniach zhody,

$$D_n = \max_{\forall i} M_i,$$

kde

$$M_i = \max \left\{ |\hat{F}_n(x_i) - F_0(x_i)|, |F_0(x_i) - \hat{F}_n(x_{i-1})| \right\}.$$

Keďže $\hat{F}_n(x_i) = \frac{i}{n}$ a $\hat{F}_n(x_{i-1}) = \frac{i-1}{n}$, môžeme písať

$$M_i = \max \left\{ D_i^+ = \left| \frac{i}{n} - F_0(x_i) \right|, D_i^- = \left| F_0(x_i) - \frac{i-1}{n} \right| \right\}.$$

Nulovú a alternatívnu hypotézu definujeme nasledovne

$$H_0 : F(x) = F_0(x) \text{ pre všetky } x \text{ proti } H_1 : F(x) \neq F_0(x) \text{ pre nejaké } x.$$

H_0 zamietame, keď $D_n > D_n(\alpha)$, kde $D_n(\alpha)$ je kritická hodnota.

Príklad 172 (Kolmogorov-Smirnov test dobrej zhody) Majme výšky $n = 12$ náhodne vybraných 10-ročných dievčat $\mathbf{x} = (131, 132, 135, 141, 141, 141, 141, 142, 143, 146, 146, 151)^T$. Otestujte na hladine významnosti $\alpha = 0.05$, či majú dáta normálne rozdelenie, kde $F_0(x) \sim N(\mu, \sigma^2)$.

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : Výška 10-ročných dievčat má normálne rozdelenie (jej distribučná funkcia pochádza z normálneho rozdelenia) oproti H_1 : výška 10-ročných dievčat nemá normálne rozdelenie (jej distribučná funkcia nepochádza z normálneho rozdelenia).
- **matematická formulácia** – testujeme $H_0 : F(x) = F_0(x) \sim N(\mu, \sigma^2)$ oproti $H_1 : F(x) \neq F_0(x)$ pre nejaké x .

2. **Testovacia štatistika** – Stredná hodnota μ a rozptyl σ^2 sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetický priemer $\bar{x} = 140.83$ a rozptyl $s^2 = 33.79$ (smerodajná odchýlka $s = 5.81$)

```
621 | vyska <- c(131,132,135,141,141,141,141,142,143,146,146,151)
622 | priemer <- mean(vyska) # 140.8333
623 | smerodch <- sd(vyska) # 5.812734
```

Najprv vypočítame očakávané hodnoty $F_0(x_{(i)})$, potom zoradíme výšky podľa veľkosti, vypočítame pozorované hodnoty $\hat{F}_n(x_{(i)}) = \frac{i}{n}$, $\hat{F}_n(x_{(i-1)}) = \frac{i-1}{n}$ ako aj D_i^+ , D_i^- , M_i a nakoniec D_n . Keďže $F_0(x) \sim N(140.83, 5.81)$, potom $F_0(x_{(i)}) = \Pr(X \leq x_{(i)}) = \Pr\left(\frac{Y-140.83}{5.81} \leq \frac{x_{(i)}-140.83}{5.81}\right) = \Pr\left(Z \leq \frac{x_{(i)}-140.83}{5.81}\right)$.

```
624 | vyska <- sort(vyska)
625 | n <- length(vyska)
626 | FoX <- pnorm(vyska, mean=priemer, sd=smerodch) # teoreticke pravdepodobnosti
627 | FnX <- seq(1:n)/n # pozorovane pravdepodobnosti
628 | Fn1X <- (seq(1:n)-1)/n
629 | D.plus <- abs(FnX-FoX)
630 | D.minus <- abs(FoX-Fn1X)
631 | VVSL <- cbind(x, FnX, Fn1X, FoX, D.plus, D.minus)
632 | Mi <- apply(VVSL[, c(5,6)], 1, max)
633 | VVSL <- cbind(VVSL, Mi)
```

Pozn.: Funkciu `ecdf()` (príkaz v podobe `Fn` i- `ecdf(vyska)`; `FnX` i- `Fn(vyska)`) nie je možné použiť, pretože pri zhodách je posunutá $\hat{F}_n(x_{i-1})$ vypočítaná z $\hat{F}_n(x_i)$ nesprávna.

Pozorovaná testovacia štatistika je potom rovná $D_n \doteq 0.26$.

```
634 | Dn <- max(Mi) # 0.2614372
```

3. **Zamietacia oblasť** – H_0 bude zamietnutá, ak $D_n > D_n(\alpha)$, kde $D_n(\alpha)$ je kritická hodnota.

4. **Štatistický záver** – p-hodnota $\doteq 0.385$.

```
635 | p.hodn <- ks.test(vyska, y="pnorm", mean=priemer, sd=smerodch)$p.val # 0.384988
```

Keďže p-hodnota nie je menšia ako hladina významnosti $\alpha = 0.05$ (ekvivalentne D_n nepatrí zamietacej oblasti), H_0 nezamietame na hladine významnosti α .

Pozn.: Ak by sme vykonali MC simuláciu kritických hodnôt štatistiky D_n pre $n = 12$ pre dáta z normálneho rozdelenia ($M = 10000$), dalo by sa ukázať, že pri $n = 12$ H_0 nezamietame (pozri obrázok 5.2 vľavo).

```
636 | "ks.mc" <- function (n=10,M=10000,alpha=0.05) {
637 |   Dn <- replicate(M, ks.test(rnorm(n), pnorm)$statistic)
638 |   kh <- quantile(Dn, 1-alpha)
639 |   plot(density(Dn), col="black", lwd=2, ylab="hustota", main="",
640 |        xlab = paste("simulovana_kriticka_hodnota=", round(kh,3), "pre_n=", n))
641 |   title(sub=list(expression(paste("simulovane_rozdelenie_", D[n]))))
642 |   return(kh)
643 | }
644 | par(mfcol=c(1,2))
645 | ks.mc(n=12,M=10000,alpha=0.05) # 0.376
```

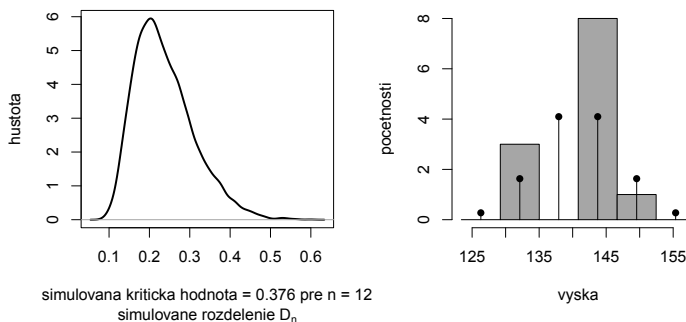
5. **Slovný záver** – Nemáme dostatok dôkazov na zamietnutie nulovej hypotézy o tom, že skutočnou distribučnou funkciou výšky 10-ročných dievčat je distribučná funkcia normálneho rozdelenia.

Histogram superponovaný s očakávanými početnosťami výšok nakreslíme nasledovne (pozri obrázok 5.2 vpravo)

```

646 bin <- seq(priemer-3*smerodch, priemer+3*smerodch, smerodch) # kategorie
647 hist(vyska, breaks=bin, col="gray", ylab="pocetnosti", freq=TRUE, main="")
648 x <- bin[2:7] - smerodch/2 # centrovanien do stredu intervalov
649 ocak.prav <- c(pnorm(-2), pnorm(-1:2)-pnorm(-2:1), 1-pnorm(2))
650 ocak <- 12*ocak.prav # ocakavane pocetnosti
651 lines(x, ocak, type="h")
652 points(x, ocak, pch=16)

```



Obr. 5.2: Simulované rozdelenie D_n (vľavo) a histogram superponovaný s očakávanými početnosťami výšok (vpravo)

Ak je hypotéza zložená, Kolmogorov-Smirnov test je veľmi konzervatívny. Avšak D_n môžeme použiť na výpočet, len ak odhadneme parametre príslušného rozdelenia, kde $\hat{F}_0(x)$ substituujeme za $F_0(x)$. Potom však nastávajú problémy s rozdelením D_n . Problém rieši modifikácia Kolmogorovho-Smirnovovho testu, kedy sa tento test nazýva **Lillieforsov test dobrej zhody**, použitím MC simulácií, kde kritické hodnoty označíme $D_n^{(l)}(\alpha)$. Simulované hodnoty D_n pozri na obrázku 5.3.

```

653 "ks.l.mc" <- function (n=10,M=1000,alpha=0.05)
654 {
655   Dn <- c()
656   DnL <- c()
657   for (i in 1:M) {
658     x <- rnorm(n)
659     mu <- mean(x)
660     sig <- sd(x)
661     Dn[i] <- ks.test(x, pnorm)$statistic
662     DnL[i] <- ks.test(x, pnorm, mean=mu, sd=sig)$statistic
663   }
664   ys <- range(density(DnL)$y)
665   xs <- range(density(Dn)$x)
666   cv <- quantile(DnL, 1-alpha)
667   cvL <- quantile(DnL, 1-alpha)
668   plot(density(Dn, bw=0.02), col="black", lwd=2, ylim=ys,
669        xlim=xs, main="", xlab="", ylab="hustota",
670        sub=paste("simulovana_kriticka_hodnota =", round(cv, 3),
671                 "(jednoduchaja_hypoteza)_a_=", round(cvL, 3),
672                 "(zlozenaja_hypoteza)\n_pre_n_=", n))
673   lines(density(DnL, bw=0.02), col="black", lwd=2, lty=2)
674   legend("topright", legend=c("jednoduchaja_hypoteza",
675                               "zlozenaja_hypoteza"), lty=c(1, 2), lwd=2)
676   #box()
677   abline(h=0)
678 }
679 ks.l.mc(n=12,M=1000)


```

Z histogramu je zreteľné, že rozdiely medzi očakávanými a odhadnutými početnosťami sú značné z dôvodu štruktúry dát a ich rozsahu, čo je v rozpore so záverom Kolmogorov-Smirnovovho testu, ktorý H_0 nezamietol. Avšak použitím Lillieforsovho testu normality H_0 zamietame, kde $D_n > D_n^{(l)}(\alpha)$.

Pri testovaní sa často používa **Dallal-Wilkinsonova aproximácia p-hodnoty** v podobe

$$p\text{-hodnota} = \exp(-7.01256D_n^2(n+2.78019)+2.99587D_n\sqrt{n+2.78019}-0.122119+\frac{0.974598}{\sqrt{n}}+\frac{1.67997}{n})$$

pre $n \in (5, 100)$ a p-hodnotu ≤ 0.1 . Ak je $n \geq 100$, potom D_n vo vyššie uvedenom vzorci nahradíme $D_m = D_n(\frac{m}{100})^{0.49}$, kde m je skutočný rozsah a n substituujeme číslom 100. Ak p-hodnota > 0.1 ,

Obr. 5.3: Simulované hustoty rozdelenia D_n pre jednoduchú a zloženú hypotézu

potom D_n nahradíme $D_{\text{mod}} = D_n(\sqrt{n} - 0.01 + 0.85\sqrt{n})$. Podľa veľkosti D_{mod} vypočítame p-hodnotu nasledovne (Dallal a Wilkinson, 1986; Stephens, 1974):

- ak $D_{\text{mod}} \leq 0.302$, $\widehat{\text{p-hodnota}} = 1$,
- ak $D_{\text{mod}} \leq 0.5$,
 $\widehat{\text{p-hodnota}} = 2.76773 - 19.828315D_{\text{mod}} + 80.709644D_{\text{mod}}^2 - 138.55152D_{\text{mod}}^3 + 81.218052D_{\text{mod}}^4$,
- ak $D_{\text{mod}} \leq 0.9$,
 $\widehat{\text{p-hodnota}} = -4.901232 + 40.662806D_{\text{mod}} - 97.490286D_{\text{mod}}^2 + 94.029866D_{\text{mod}}^3 - 32.355711D_{\text{mod}}^4$,
- ak $D_{\text{mod}} \leq 1.31$,
 $\widehat{\text{p-hodnota}} = 6.198765 - 19.558097D_{\text{mod}} + 23.186922D_{\text{mod}}^2 - 12.234627D_{\text{mod}}^3 + 2.423045D_{\text{mod}}^4$.

Na Lillieforsov test normality môžeme použiť aj funkciu

```
680 library(nortest)
681 lillie.test(vyska)$stat # 0.2614372
682 lillie.test(vyska)$p.val # 0.02296345
```

Nulovú hypotézu o tom, že skutočnou distribučnou funkciou výšky 10-ročných dievčat je distribučná funkcia normálneho rozdelenia, zamietame.

Výhody Kolmogorovho-Smirnovovho testu. Kolmogorov-Smirnov test má dve hlavné výhody oproti χ^2 testu

1. je použiteľný aj pre malé rozsahy výberov, kedy je validita χ^2 testu dobrej zhody otázná,
2. jeho sila je väčšia ako sila χ^2 testu dobrej zhody pre akýkoľvek rozsah výberu.


Ak však ide o zloženú hypotézu, kde je potrebné odhadnúť aj parametre rozdelenia, Kolmogorov-Smirnov test v jeho klasickej podobe nie je možné použiť. Výsledky by v tomto prípade boli konzervatívne v zmysle pravdepodobnosti chyby prvého druhu, ktorá by bola v skutočnosti menšia, t.j. pozorovaná hladina významnosti by bola tiež menšia, čo by znamenalo „pomalšie“ zamietanie za použitia $D_n(\alpha)$ namiesto $D_n^{(l)}(\alpha)$. Ak odhadujeme strednú hodnotu a rozptyl, použijeme Lillieforsov test normality. Približný vzťah medzi kritickými hodnotami $D_n^{(l)}(\alpha)$ tohoto testu a kritickými hodnotami $D_n(\alpha)$

môžeme vyjadriť ako $D_n^{(l)}(\alpha) \approx \frac{2}{3} D_n(\alpha)$. Pre veľké hodnoty n hodnoty $D_n^{(l)}(\alpha)$ klesajú tak, ako klesá $\frac{1}{\sqrt{n}}$.

Príklad 173 (Lillieforsov test normality) Pomocou Lillieforsovho testu otestujte normalitu premenných:

- (a) výška postavy žien (`body.H`; v mm; dáta: `anova-head.txt`),
- (b) stranový rozdiel vertikálneho priemeru diafýzy kľúčnej kosti (`simd.R` a `simd.L`; v mm) na pravej a ľavej strane tela (dáta: `paired-means-clavicle2.txt`),
- (c) najväčšia výška mozgovne u mužov (`skull.pH`; v mm; dáta: `one-sample-correlation-skull-mf.txt`) a
- (d) morfológická výška tváre u žien (`face.H`; v mm; dáta: `one-sample-correlation-skull-mf.txt`).

Príklad 174 (pásky normality) Na základe vygenerovaných pseudonáhodných čísel $X \sim N(\mu, \sigma^2)$, $n = 100$, $\mu = 0$, $\sigma^2 = 1$, kde $M = 1000$, odhadnite (a) hustotu m -tej realizácie pomocou funkcie `density()`; ponechajte argument `n=512` a nastavte `from=-3` a `to=3`; (b) distribučnú funkciu m -tej realizácie pomocou (a) a funkcie `cumsum()` a (c) empirické kvantily m -tej realizácie pomocou funkcie `qqnorm()`. Vygenerované čísla x_{mi} , $m = 1, 2, \dots, 1000$ a $i = 1, 2, \dots, 100$, uložte po riadkoch do matice **X**, ktoré budú mať rozmery 1000×100 . Odhadnuté hustoty a distribučné funkcie uložte po riadkoch do matic **H** a **D**, ktoré bude mať rozmery 1000×512 a empirické kvantily do matice **K**, ktorá bude mať rozmery 1000×100 . Pre každú z matic **H**, **D** a **K** vypočítajte $\tilde{x}_{0.05}$ a $\tilde{x}_{0.95}$ po stĺpcoch a zobrazte ich ako pásky pomocou funkcie `polygon()`. Do obrázkov vkreslite (a) teoretickú hustotu, (b) teoretickú distribučnú funkciu a (c) kvantilovú priamku (pomocou funkcie `qqline()`) červenou farbou. Obrázky usporiadajte ako trojicu vedľa seba. Dáta, ktorých normalitu chceme graficky testovať, budú (1) $X \sim N(0, 1)$, $n = 100$, (2) $X \sim [pN(0, 1) + (1-p)N(0, 4)]$, $n = 100$ a $p = 0.95$ a (3) $X \sim [pN(0, 1) + (1-p)N(0, 4)]$, $n = 100$ a $p = 0.9$. Zobrazte (1), (2) a (3) oddelene do grafov (a), (b) a (c). Okomentujte. Riešenie (1) pozri na obrázku 5.4.



Obr. 5.4: Pásky spoľahlivosti normálneho rozdelenia – pre hustotu (vľavo), distribučnú funkciu (uprostred) a kvantilovú priamku (vpravo)

6 Testovanie hypotéz o jednom parametri

V tejto kapitole sa budeme venovať testovaniu hypotéz o strednej hodnote μ a rozptyle σ^2 za predpokladu normality X , t.j. $X \sim N(\mu, \sigma^2)$; o korelačnom koeficiente ρ premenných X a Y za predpokladu dvojrozmernej normality $(X, Y)^T$, t.j. $(X, Y)^T \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ a nakoniec o pravdepodobnosti p za predpokladu $X \sim \text{Bin}(N, p)$ a $X \sim \text{Pois}(\lambda)$.

6.1 Asymptotické testy o strednej hodnote

Jednovýberový test hypotézy o strednej hodnote normálneho rozdelenia sa v biologickej antropológii používa najčastejšie v situáciách, keď máme k dispozícii namerané hodnoty nejakej spojitej premennej (napríklad výšky postavy) a chceme zistiť, či sa stredná hodnota výšky postavy našej populácie líši alebo nelíši od referenčnej (napr. reprezentatívneho, celoštátneho súboru) či publikovanej (napr. z iného mesta, iného obdobia alebo inej generácie) strednej hodnoty výšky postavy vzorky, z ktorej nemáme k dispozícii primárne dáta (individuálne hodnoty všetkých prípadov), ale iba sekundárne dáta ako štatistické charakteristiky/parametre (aritmetický priemer, počet jedincov a smerodajnú odchýlku). Keďže číselne sa stredné hodnoty (pri dostatočnej presnosti, počte desiatinných miest) akýchkoľvek dvoch populácií vždy líšia (t.j. jedna je vždy menšia a druhá väčšia), je potrebné zistiť, či je rozdiel štatisticky významný (signifikantný; v minulosti sa používalo označenie štatisticky závažný). Potrebujeme rozhodnúť, či má rozdiel takú váhu, že je opodstatnené hľadať vysvetlenie príčin tohto rozdielu (interpretáciu výsledkov) alebo je rozdiel iba malý, daný náhodnými vplyvmi a nemá zmysel sa ním zaoberať (resp. má zmysel zaoberať sa jeho neexistenciou). Nie je preto správne porovnávať strednú hodnotu s referenčnou hodnotou iba číselne, príp. graficky (i keď sa to, žiaľ, v prehľadových štúdiách a diskusiách antropológických štúdií často deje), ale je nevyhnutné rozdiel vždy štatisticky testovať. Až potom sa môžeme pokúsiť o vysvetlenie rozdielu (v prípade zamietnutia nulovej hypotézy o zhode strednej hodnoty s referenčnou strednou hodnotou) alebo, naopak, o vysvetlenie zhody či veľkej podobnosti oboch vzoriek (v prípade nezamietnutia nulovej hypotézy). Na to však spravidla nestačia hodnoty rozdielu alebo výsledky samotného testu, potrebujeme aj ďalšie informácie o populácii, vzorke a spôsobe jej vzniku. Príčinou rozdielu v sledovanom znaku môžu byť genetické (veľkosť populácie, špecifické evolučné adaptácie a i.), environmentálne (fyzikálne a geografické faktory prostredia, zát'až, strava, a i.) či socio-kultúrne (behaviorálne, kultúrne, sociálne a ekonomické) rozdiely medzi geografickými oblasťami, populáciami, generáciami, sociálnymi vrstvami atď. Štandardne sa vo väčšine znakov vo všetkých ľudských populáciách vyskytujú rozdiely vekové (ontogenetické rastové a vývojové zmeny v priebehu dospievania a involučné funkčné a morfológické zmeny v priebehu starnutia) a rozdiely pohlavné (sexuálny dimorfizmus), ktoré je nevyhnutné vždy zohľadňovať, t.j. nie je možné porovnávať vzorky z tej istej alebo odlišných populácií, u ktorých nepoznáme vekové a pohlavné zloženie (počet mužov a žien a ich vek).

Pomocou jednovýberového testu strednej hodnoty možno testovať rozdiely spojených premenných (rozmery živého človeka, rozmery skeletu), ktoré majú známe rozdelenie. Nevýhodou využitia jednovýberového testu a porovnávaním s referenčnou či publikovanou hodnotou je ale skutočnosť, že testujeme rozdiely medzi dátami zmeranými inými pozorovateľmi, inými meradlami a stanovené väčšinou nedostatočne spresneným a nekontrolovaným spôsobom. Presnosť meradiel, spôsob merania a odlišné okolnosti pri zbere dát v oboch vzorkách môžu byť príčinou časti rozdielov v stredných hodnotách. Preto je vhodnejšie použiť dvojjvýberové testy, kde obe porovnávané vzorky merala jedna osoba rovnakým meradlom a najlepšie vo vhodnom znáhodnom poradí z hľadiska príslušnosti meraných jednotiek k porovnávaným skupinám/vzorkám.

Nech $X \sim N(\mu, \sigma^2)$, kde σ^2 je neznáma. Majme dvojicu hypotéz $H_{01} : \mu = \mu_0$ oproti $H_{11} : \mu \neq \mu_0$, $H_{02} : \mu \leq \mu_0$ oproti $H_{12} : \mu > \mu_0$, $H_{03} : \mu \geq \mu_0$ oproti $H_{13} : \mu < \mu_0$, ktoré chceme testovať.

Ak H_0 platí, potom

$$T_W = \frac{\bar{X} - \mu_0}{S} \sqrt{n} \stackrel{\mathcal{D}}{\sim} t_{n-1},$$

kde $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ a rozdelenie t_{df} , kde $df = n - 1$, sa nazýva **centrálne t -rozdelenie** s $n - 1$ stupňami voľnosti. T_W sa nazýva **Waldova testovacia štatistika** (alebo **t -štatistika**) a test **jednovýberový Studentov t -test o strednej hodnote μ** .

Ak H_0 neplatí, táto situácia vedie k **necentrálnemu t -rozdeleniu** s df stupňami voľnosti a parametrom necentrality λ , ozn. $t_{df,\lambda}$, kde

$$T_{W,\lambda} = \frac{Z_W + \lambda}{\sqrt{V/df}} = \frac{\sqrt{n}(\bar{X} - \mu)/\sigma + \sqrt{n}(\mu - \mu_0)/\sigma}{S/\sigma} \mathcal{D} t_{df,\lambda},$$

kde $df = n - 1$, $Z_W = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \stackrel{\mathcal{D}}{\sim} N(0, 1)$, parameter necentrality $\lambda = (\delta/\sigma) \sqrt{n}$, $\delta = \mu - \mu_0$ je **minimálne detegovateľná vzdialenosť** medzi μ a μ_0 , $V = \frac{(n-1)S^2}{\sigma^2} \stackrel{\mathcal{D}}{\sim} \chi_{df}^2$ a je nezávislé na Z_W . Označme kumulatívnu distribučnú funkciu $T_{W,\lambda}$ ako $G_{df,\lambda}(t) = \Pr(T_{W,\lambda} \leq t)$. Ak $\lambda = 0$, potom sa necentrálne t -rozdelenie redukuje na centrálne (Studentove) t -rozdelenie.

Ak H_{02} neplatí, potom silofunkcia

$$1 - \beta(\mu, \sigma) = \Pr_{\mu, \sigma} \left(\frac{\bar{X} - \mu_0}{S} \sqrt{n} \geq t_{n-1}(\alpha) \right) = 1 - G_{n-1,\lambda}(t_{n-1}(\alpha)),$$

kde argumenty (μ, σ) indikujú, že pravdepodobnosť je počítaná za predpokladu $X \sim N(\mu, \sigma^2)$, $\mu > \mu_0$. Ak H_{03} neplatí, potom silofunkcia

$$1 - \beta(\mu, \sigma) = \Pr_{\mu, \sigma} \left(\frac{\bar{X} - \mu_0}{S} \sqrt{n} \leq -t_{n-1}(\alpha) \right) = G_{n-1,\lambda}(t_{n-1}(\alpha)),$$

kde argumenty (μ, σ) indikujú, že pravdepodobnosť je počítaná za predpokladu $X \sim N(\mu, \sigma^2)$, $\mu < \mu_0$. Ak H_{01} neplatí, potom silofunkcia

$$\begin{aligned} 1 - \beta(\mu, \sigma) &= \Pr_{\mu, \sigma} \left(\frac{\bar{X} - \mu_0}{S} \sqrt{n} \leq -t_{n-1}(\alpha/2) \vee \frac{\bar{X} - \mu_0}{S} \sqrt{n} \geq t_{n-1}(\alpha/2) \right) \\ &= 1 - G_{n-1,\lambda}(t_{n-1}(\alpha/2)) + G_{n-1,\lambda}(-t_{n-1}(\alpha/2)), \end{aligned}$$

kde argumenty (μ, σ) indikujú, že pravdepodobnosť je počítaná za predpokladu $X \sim N(\mu, \sigma^2)$, $\mu \neq \mu_0$.


Definícia 52 (Kritický obor a silofunkcia T_W testu o μ) Kritický obor a silofunkcia sú definované (za platnosti $t_{n-1}^2(\alpha/2) \approx F_{1,n-1}(\alpha)$ a $t_{n-1,\lambda}^2(\alpha/2) \approx F_{1,n-1,\lambda^2}(\alpha)$) nasledovne (pozri obrázok 6.1):

H_0	H_1	\mathcal{W}	$1 - \beta(\mu)$
$\mu = \mu_0$	$\mu \neq \mu_0$	$\mathcal{W}_1 = \{T_W; T_W \geq t_{n-1}(\alpha/2)\}$	$\Pr(F_{1,n-1,\lambda^2} \geq F_{1,n-1}(\alpha))$
$\mu \leq \mu_0$	$\mu > \mu_0$	$\mathcal{W}_2 = \{T_W; T_W \geq t_{n-1}(\alpha)\}$	$\Pr(t_{n-1,\lambda} \geq t_{n-1}(\alpha))$
$\mu \geq \mu_0$	$\mu < \mu_0$	$\mathcal{W}_3 = \{T_W; T_W \leq -t_{n-1}(\alpha)\}$	$\Pr(t_{n-1,\lambda} \leq -t_{n-1}(\alpha))$

Definícia 53 (p-hodnota T_W testu o μ) Nech T_W je nejaká testovacia štatistika a $t_W = \frac{\bar{x} - \mu_0}{s} \sqrt{n}$ je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p -hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\Pr(T_W \geq |t_W| | H_{01}), & \text{ak } H_{11}: \mu \neq \mu_0 \\ \Pr(T_W \geq t_W | H_{02}), & \text{ak } H_{12}: \mu > \mu_0 \\ \Pr(T_W \leq t_W | H_{03}), & \text{ak } H_{13}: \mu < \mu_0 \end{cases}$$

Definícia 54 (Waldove $100 \times (1 - \alpha)\%$ empirické IS pre μ) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre μ pre všetky tri typy hypotéz majú nasledovný tvar:



Obr. 6.1: Silofunkcie asymptotického testu o μ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\mu = \mu_0$	$\mu \neq \mu_0$	$\mathcal{CS}_{1-\alpha} = \left\{ \mu_0 : \mu_0 \in \left(\bar{x} - t_{n-1}(\alpha/2) \frac{s}{\sqrt{n}}, \bar{x} + t_{n-1}(\alpha/2) \frac{s}{\sqrt{n}} \right) \right\}$
$\mu \leq \mu_0$	$\mu > \mu_0$	$\mathcal{CS}_{1-\alpha} = \left\{ \mu_0 : \mu_0 \in \left(\bar{x} - t_{n-1}(\alpha) \frac{s}{\sqrt{n}}, \infty \right) \right\}$
$\mu \geq \mu_0$	$\mu < \mu_0$	$\mathcal{CS}_{1-\alpha} = \left\{ \mu_0 : \mu_0 \in \left(-\infty, \bar{x} + t_{n-1}(\alpha) \frac{s}{\sqrt{n}} \right) \right\}$


Príklad 175 (nezávislosť μ a σ^2 ; pravdepodobnosť pokrytia) *Nech $X \sim N(\mu, \sigma^2)$, kde $\mu = 20$ a $\sigma^2 = 100$. Vypočítajte Pearsonov korelačný koeficient $r_{\bar{X}, S}$ pomocou simulačnej štúdie. Nakreslite sivou farbou rozptyľový graf (\bar{x}_m, s_m) , kde $m = 1, 2, \dots, M$, kde $M = 100000$. Dokreslite do grafu čiernou farbou také body, pre ktoré platí $t_{W,m} = \left| \frac{\bar{x}_m - \mu}{s_m} \sqrt{n} \right| < t_{n-1}(\alpha/2)$, ako aj hranice, ktoré definujú také body (\bar{x}_m, s_m) , pre ktoré $t_{W,m} = t_{n-1}(\alpha/2)$. Vypočítajte pravdepodobnosť pokrytia 95% DIS pre μ ako podiel $\sum_m I(t_{W,m} < t_{n-1}(\alpha/2)) / M$. Zvoľte (a) $n = 5$, (b) $n = 50$ a (c) $n = 100$.*

Riešenie v R (pozri obrázok 6.2)

```
683 M <- 100000
684 n <- 5
685 mu <- 20
686 sigma <- 10
687 x <- rnorm(M*n, mu, sigma)
688 DATA <- matrix(x, nrow=M)
689 mu.hat <- rowMeans(DATA)
690 sd.hat <- sqrt(rowSums((DATA-mu.hat)^2)/(n-1))
691 cor(mu.hat, sd.hat) # 0.002212632
692
693 windows(12, 4)
694 par(mfcol=c(1,3), mar=c(5,4.2,1,1))
695 plot(mu.hat, sd.hat, xlab="aritmeticky_priemer", ylab="smerodajna_odchylka",
696      col="darkgrey", pch=16, cex=0.2, cex.lab=1.5,
697      sub=paste("n=5, ", "r=", round(cor(mu.hat, sd.hat), 6)), cex.sub=1.5)
698 ## pravdepodobnosť pokrytia
699 t.krit <- qt(0.975, n-1)
700 tW.obs <- sqrt(n)*(mu.hat-mu)/sd.hat
701 pokrytie <- (1:M)[abs(tW.obs)<t.krit]
702 points(mu.hat[pokrytie], sd.hat[pokrytie], pch=16, cex=0.2)
703 mu.hat.i <- seq(min(mu.hat), max(mu.hat), length=1000)
704 sd.hat.i <- abs(sqrt(n)*(mu.hat.i-mu)/t.krit)
705 lines(mu.hat.i, sd.hat.i, lwd=2)
706 p.pokrytie <- sum(abs(tW.obs)<t.krit)/M # 0.94856
```

Ak sú \bar{X} a S nezávislé, potom $\rho_{\bar{X}, S} = 0$ a $r_{\bar{X}, S} \approx 0$. Na základe výsledkov simulačnej štúdie môžeme konštatovať, že $r_{\bar{X}, S} \approx 0$ pre $n = 5, 50$ a 100 (pozri obrázok 47). Pravdepodobnosť pokrytia je pre $n = 5$ rovná 0.94856 , pre $n = 50$ je rovná 0.95021 a pre $n = 100$ je rovná 0.95015 . Z toho vyplýva, že aktuálne hodnoty pravdepodobnosti pokrytia (získané zo simulačnej štúdie) sú pre $X \sim N(\mu, \sigma^2)$ dostatočne blízke nominálnej hodnote $1 - \alpha = 0.95$.

Príklad 176 (nezávislosť μ a σ^2 ; pravdepodobnosť pokrytia) *Nech $X \sim [pN(\mu, \sigma_1^2) + (1 - p)N(\mu, \sigma_2^2)]$, kde $p = 0.9$, $\mu = 20$, $\sigma_1^2 = 100$ a $\sigma_2^2 = 400$. Vypočítajte Pearsonov korelačný koeficient $r_{\bar{X}, S}$*



Obr. 6.2: Rozptylový graf $\bar{x}_i, s_i, i = 1, 2, \dots, M, M = 100000$ pre $n = 5$ (vľavo), $n = 50$ (v strede) a $n = 100$ (vpravo)

pomocou simulačnej štúdie. Nakreslite sivou farbou rozptylový graf (\bar{x}_m, s_m) , kde $m = 1, 2, \dots, M$, kde $M = 100000$. Dokreslite do grafu čiernou farbou také body, pre ktoré platí $t_{W,m} = \left| \frac{\bar{x}_m - \mu}{s_m} \sqrt{n} \right| < t_{n-1}(\alpha/2)$, ako aj hranice, ktoré definujú také body (\bar{x}_m, s_m) , pre ktoré $t_{W,m} = t_{n-1}(\alpha/2)$. Vypočítajte pravdepodobnosť pokrytia 95% DIS pre μ ako podiel $\sum_m I(t_{W,m} < t_{n-1}(\alpha/2)) / M$. Zvoľte (a) $n = 5$, (b) $n = 50$ a (c) $n = 100$.

Jednovýberový Studentov t -test o strednej hodnote μ v \mathbb{R} (funkcia `t.test()`).

Argumenty (vstupy) funkcie:

1. vektor dát x ;
2. alternatíva `alternative="two.sided"` je prednastavená, ďalšie voľby sú "greater", "less";
3. stredná hodnota za platnosti nulovej hypotézy μ_0 , t.j. μ_0 ;
4. spoľahlivosť `conf.level=p`, prednastavené je $p = .95$.

Výstupy funkcie:

1. názov použitého testu `method`;
2. testovacia štatistika `statistic`;
3. počet stupňov voľnosti `df` parameter;
4. p -hodnota `p.value`;
5. alternatívna hypotéza `alternative hypothesis`;
6. interval spoľahlivosti pre μ `conf.int`;
7. bodový odhad (aritmetický priemer \bar{x}) `sample estimates`.

Príklad 177 (necentrálne t -rozdelenie) Nakreslite distribučnú funkciu necentrálneho t -rozdelenia $t_{n-1, \lambda}$, kde $\delta = \mu - \mu_0$ a $\lambda = \delta / (\sigma / \sqrt{n})$. Použite $\mu_0 = 0$, $\delta = 1$, $\sigma = 1.4$ a $n = 26$. Vypočítajte pravdepodobnosť nad kvantilom $x_{0.975}$ pod krivkou hustoty tohoto rozdelenia.

Riešenie v \mathbb{R} (pozri obrázok 6.3 vľavo)

```

707 | delta <- 1
708 | sigma <- 1.4
709 | n <- 26
710 | lambda <- delta/sigma*sqrt(n)
711 | curve(pt(x,25,ncp=lambda),from=0,to=6,xlab="x",ylab="distribucna funkcia")
712 | abline(v=qt(.975,25)) # 2.06
713 | 1-pt(qt(.975,25),25,ncp=lambda) # 0.9381038

```


Príklad 178 (necentrálne t -rozdelenie) Nakreslite hustoty jedného centrálného a štyroch necentrálnych t -rozdelení $t_{n-1,\lambda}$ ($\delta = \mu - \mu_0$ a $\lambda = \delta/(\sigma/\sqrt{n})$) do jedného obrázka tak, aby boli odlišiteľné farbou alebo typom čiary. Použite $\mu_0 = 0$, $\delta = 0, 0.5, 0.8, 1$ a 1.2 , $\sigma = 1.4$ a $n = 26$.

Riešenie v \mathbb{R} (pozri obrázok 6.3 vpravo)

```

714 delta <- c(0,0.5,0.8,1,1.2)
715 sigma <- 1.4
716 n <- 26
717 lambda <- delta/sigma*sqrt(n)
718 curve(dt(x,n,ncp=delta[1]),from=-4,to=9,xlab="x",ylab="hustota",xlim=c(-4,12))
719 curve(dt(x,n,ncp=delta[2]),add=T,from=-5,to=10,lty=2)
720 curve(dt(x,n,ncp=delta[3]),add=T,from=-5,to=10,lty=3)
721 curve(dt(x,n,ncp=delta[4]),add=T,from=-5,to=10,lty=4)
722 curve(dt(x,n,ncp=delta[5]),add=T,from=-5,to=10,lty=5)
723 legend("topright",c(expression(paste(delta==0,sep="")),
724 expression(paste(delta==0.5,sep="")),expression(paste(delta==0.8,sep="")),
725 expression(paste(delta==1,sep="")),expression(paste(delta==1.2,sep="))),
726 lty=1:5)

```



Obr. 6.3: Distribučná funkcia (vľavo) a hustoty (vpravo) necentrálneho t -rozdelenia pri rôznych parametroch necentrality λ vyjadreného pomocou δ

Príklad 179 Nech $X \sim N(\mu, \sigma^2)$, kde odhady $\bar{x} = 4$ a $s^2 = 2.89^2$. Rozsah náhodného výberu $n = 25$.

(a) Testujte $H_0 : \mu = 2.5$ oproti $\mu \neq 2.5$ na hladine významnosti $\alpha = 0.05$.

(b) Vypočítajte silu $1 - \beta$ pre $\mu_0 = 2.5$ a $\mu_1 = 4$ (μ_1 predstavuje hodnotu μ za platnosti H_1) za predpokladu, že $\sigma = 2.5$.

(c) Použite \mathbb{R} na simuláciu hustoty rozdelenia $t_{n-1,\lambda}$ testovacích štatistík $t_{W,\lambda}^{(m)} = \frac{\bar{x}_m - \mu_0}{s_m} \sqrt{n}$ (necentrálne t -rozdelenie s $n - 1$ stupňami voľnosti a parametrom necentrality λ), kde $n = 25$, $\lambda = 3$, $m = 1, 2, \dots, M$, pri $M = 20000$ opakovaníach. Na základe tohoto rozdelenia vypočítajte silu testu pre $\mu_0 = 2.5$ a $\mu_1 = 4$ (pozri obrázok 4.5). (1) $X \sim N(4, 2.5^2)$ a (2) $X \sim [pN(4, 2.5^2) + (1 - p)N(4, 4.5^2)]$, kde $p = 0.9$.

Riešenie (aj v \mathbb{R})

(a) $t_W = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} \doteq \frac{4 - 2.5}{2.89/\sqrt{25}} \doteq 2.595$, p -hodnota $= 2 \times \Pr(|T_W| \geq t_{\text{obs}} | T_W \sim t_{24}) \doteq 0.016$;

(b) $\lambda = \frac{\mu_1 - \mu_0}{\sigma/\sqrt{n}} \doteq \frac{4 - 2.5}{2.5/\sqrt{25}} \doteq 3.0$;

Za platnosti alternatívny $t_W = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$.

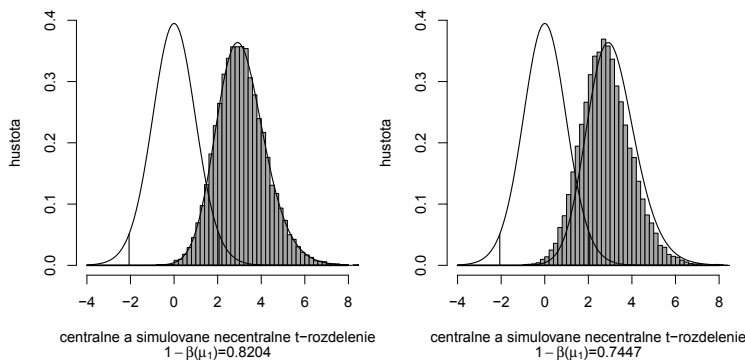
$1 - \beta(\mu_1 = 4) = \Pr(\text{zamietni } H_0 | H_1) = \Pr(T_W < t_{n-1}(1 - \alpha/2) \cup T_W > t_{n-1}(\alpha/2) | T \sim t_{n-1,\lambda}) = \Pr(T_{W,3} < t_{24}(0.975) \cup T_{W,3} > t_{24}(0.025) | T_{W,3} \sim t_{24,3}) \doteq 0.82$.

Platí nasledovné: $\Pr(T_{W,3} < t_{24}(0.975) \cup T_{W,3} > t_{24}(0.025) | T_{W,3} \sim t_{24,3}) = \Pr(F_{1,24,3^2} > F_{1,24}(0.05))$, kde $F_{1,24}(0.05) = (t_{24}(0.025))^2$.

```

727 cv <- qt(0.975,24) # 2.063899
728 p.hodn <- 2*(1-pt(2.595156,24)) # 0.01587727
729 sila.t.test <- pt(qt(0.025,24),24,3)+(1-pt(qt(0.975,24),24,3)) # 0.8207219
730 sila.t.test <- 1-pf(qt(0.975,24)^2,1,24,3^2) # 0.8207219

```

Obr. 6.4: Hustota centrálneho a necentrálneho t -rozdelenia; vľavo – hustota necentrálneho t -rozdelenia je superponovaná histogramom simulácií pre $X \sim N(4, 2.5^2)$ a vpravo – pre $X \sim [pN(4, 2.5^2) + (1-p)N(4, 4.5^2)]$, kde $p = 0.9$

Simuláciu silofunkcie (1) pozri na obrázku 6.4 vľavo a (2) na obrázku 6.4 vpravo.

Pravdepodobnosť empirickej CHPD pre MC experiment je pravdepodobnosť p signifikantných testovacích štatistík medzi ich M opakovaniami, ak H_0 platí. Potom $SE(p) = \sqrt{p(1-p)/M}$ je menšia alebo rovná $0.5/\sqrt{M}$.

Príklad 180 (pravdepodobnosť empirickej CHPD t -testu) Nech $X \sim N(\mu, \sigma^2)$, kde $\mu = 500$ a $\sigma^2 = 100$. Testujte $H_0 : \mu = 500$ oproti $H_1 : \mu > 500$, ak $\alpha = 0.05$, σ je neznáme. Použite \mathbb{R} na simuláciu empirickej $\Pr(\text{CHPD})$, kde počet simulácií je $M = 10000$ a rozsah náhodného výberu je $n = 20$ pre jednovýberový Studentov t -test o strednej hodnote μ . Použite funkciu `t.test(x, alternative = "greater", mu = mu0)` a pre každú testovaciu štatistiku $t_m, m = 1, 2, \dots, M$ vypočítajte p -hodnotu a jej štandardnú chybu za platnosti H_0 . Ide o zistenie relatívnej početnosti p zamietnutých H_0 na hladine významnosti $\alpha = 0.05$ medzi M testami, kde $p = \Pr(\text{CHPD}) = \frac{\sum_{m=1}^M I(H_0 \text{ zamietame})}{M}$.

Riešenie v \mathbb{R}

```

731 | n <- 20
732 | alfa <- .05
733 | mu0 <- 500
734 | sigma <- 100
735 | M <- 10000
736 | p.hodnoty <- numeric(M)
737 | for (j in 1:M) {
738 |   x <- rnorm(n, mu0, sigma)
739 |   ttest <- t.test(x, alternative="greater", mu=mu0)
740 |   p.hodnoty[j] <- ttest$p.value
741 | }
742 | p.hat <- mean(p.hodnoty < alfa)
743 | se.hat <- sqrt(p.hat*(1-p.hat)/M)
744 | print(c(p.hat, se.hat)) # 0.052100000 0.002222287

```


Odhadnutá pravdepodobnosť chyby prvého druhu bude oscilovať okolo **nominálnej hladiny významnosti** $\alpha = 0.05$, pretože všetky náhodné výbery boli generované za platnosti H_0 za predpokladu modelu normálneho rozdelenia.

Ak nie je možné vypočítať silofunkciu testu H_0 oproti fixovanej obojstrannej H_1 analyticky, je možné túto silu odhadnúť pomocou MC metód. Treba si ale uvedomiť, že hoci sila $1-\beta$ je definovaná na celom parametrickom priestore Θ , α je definovaná na podpriestore Θ_0 .

Príklad 181 (empirická silofunkcia t -testu) Nech (a) X pochádza z normálneho rozdelenia, $X \sim N(\mu_1, 100^2)$, a (b) X pochádza zo zmesi dvoch normálnych rozdelení, $X \sim [pN(\mu_1, 100^2) + (1-p)N(\mu_1, 200^2)]$, kde $p = 0.9$. Rozsah náhodného výberu $n = 20$. Použite \mathbb{R} na simuláciu empirickej silofunkcie pre jednovýberový Studentov t -test. Testujeme $H_0 : \mu = 500$ oproti $H_1 : \mu \neq 500$, kde $\mu_1 = 450, 460, \dots, 640, 650$ (ide o obojstrannú alternatívu). Použite funkciu `t.test(x, mu=500)`, na výpočet každej testovacej štatistiky $t_m, m = 1, 2, \dots, M$, kde $M = 10000$, vypočítajte p -hodnotu

korešpondujúcu t_m a porovnajte ju s hladinou významnosti $\alpha = 0.05$. Tak získate empirickú silofunkciu $1 - \widehat{\beta}(\mu_1)$ pri danej alternatíve. Do grafu zakreslite $1 - \widehat{\beta}(\mu_1)$ pri danej alternatíve ako aj ich štandardné chyby $SE[1 - \widehat{\beta}(\mu_1)] = \sqrt{\frac{(1 - \widehat{\beta}(\mu_1))\widehat{\beta}(\mu_1)}{M}}$ v podobe chybovej úsečky $1 - \widehat{\beta}(\mu_1) \pm SE[1 - \widehat{\beta}(\mu_1)]$. Do grafu vkreslite aj teoretickú silofunkciu $1 - \beta(\mu_1)$, $\mu_1 \in \langle 450, 650 \rangle$ (použite funkciu `power.t.test()`).

Riešenie (pozri obrázok 6.5)



Obr. 6.5: Empirická (krivka s chybovými úsečkami vo vybraných bodoch) a teoretická (hladká krivka) silofunkcia t -testu; simulácie; vľavo $- X \sim N(500, 100^2)$ a vpravo $- X \sim [pN(500, 100^2) + (1 - p)N(500, 200^2)]$, kde $p = 0.9$

Test pomerom vierohodnosti pre μ .

Majme H_{01} oproti H_{11} . Nech $X \sim N(\mu, \sigma^2)$, kde $\theta = (\mu, \sigma^2)^T$. Funkcia vierohodnosti je rovná

$$L(\theta|\mathbf{x}) = (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$

MLE θ je rovný

$$\widehat{\theta} = (\bar{x}, \widehat{\sigma}^2)^T = \left(\frac{1}{n} \sum_{i=1}^n x_i, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^T,$$

t.j. $\Theta_1 = \{\theta : \mu \neq \mu_0\}$. Za platnosti H_{01} je $\theta_0 = (\mu_0, \widehat{\sigma}_0^2)^T$ t.j. $\Theta_0 = \{\theta : \mu = \mu_0\}$. Výpočet $\max(l(\theta|\mathbf{x})|\theta \in \Theta_0)$ sa redukuje na výpočet MLE $\widehat{\sigma}_0^2$ parametra σ^2 za predpokladu $\mu = \mu_0$ je známe, kde ďalej použijeme $l(\theta|\mathbf{x})$ v bode θ_0 . Derivácia $l(\theta|\mathbf{x})$ podľa σ^2 je rovná

$$\frac{\partial}{\partial \sigma^2} l(\theta|\mathbf{x}) = \frac{1}{2} \left(\frac{1}{\sigma^4} \sum_{i=1}^n (x_i - \mu_0)^2 - \frac{n}{\sigma^2} \right) = 0,$$

odkiaľ

$$\widehat{\sigma}_0^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_0)^2.$$

Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x})) &= l(\widehat{\theta}|\mathbf{x}) - l(\theta_0|\mathbf{x}) \\ &= \left(-\frac{n}{2}(\ln(2\pi) + \ln \widehat{\sigma}^2 + 1)\right) - \left(-\frac{n}{2}(\ln(2\pi) + \ln \widehat{\sigma}_0^2 + 1)\right) \\ &= \frac{n}{2} \ln \frac{\widehat{\sigma}_0^2}{\widehat{\sigma}^2} \end{aligned}$$

a testovacia štatistika pomerom vierohodnosti $U_{LR} = -2 \ln(\lambda(\mathbf{X})) \stackrel{\mathcal{D}}{\sim} \chi_1^2$, kde H_0 bude zamietnutá pre veľké hodnoty podielu $\frac{\hat{\sigma}_0^2}{\sigma^2}$. Dá sa ukázať, že $\hat{\sigma}_0^2 = \hat{\sigma}^2 + (\bar{x} - \mu_0)^2$ a potom $\frac{\hat{\sigma}_0^2}{\sigma^2} = 1 + \frac{(\bar{x} - \mu_0)^2}{\sigma^2}$. Keďže $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{n}{n-1} \hat{\sigma}^2$, podiel $\frac{\hat{\sigma}_0^2}{\sigma^2}$ je rastúcou funkciou $|t_W|$ a potom

$$u_{LR} = -2 \ln(\lambda(\mathbf{x})) = n \ln \frac{\hat{\sigma}_0^2}{\hat{\sigma}^2} = n \ln \left(1 + \frac{t_W^2}{n-1} \right).$$

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre μ bude mať tvar

$$CS_{1-\alpha} = \{ \mu_0 : U_{LR} < \chi_1^2(\alpha) \}.$$

Majme H_{02} oproti H_{12} . Nech $\hat{\mu}_0 = \bar{x}$ ak $\bar{x} \leq \mu_0$ a $\hat{\mu}_0 = \mu_0$ inak. Potom $u_{LR} = 0$ ak $t_W \leq 0$ a $u_{LR} = \frac{n}{2} \ln(1 + \frac{t_W^2}{n-1})$ pre $t_W > 0$.

Majme H_{03} oproti H_{13} . Nech $\hat{\mu}_0 = \bar{x}$ ak $\bar{x} \geq \mu_0$ a $\hat{\mu}_0 = \mu_0$ inak. Potom $u_{LR} = 0$ ak $t_W \geq 0$ a $u_{LR} = \frac{n}{2} \ln(1 + \frac{t_W^2}{n-1})$ pre $t_W < 0$.

Príklad 182 (test o strednej hodnote μ) Majme dáta *one-sample-mean-skull-mf.txt* a premennú dĺžka lebky *skull.L* v mm starovekej egyptskej mužskej populácie, o ktorej predpokladáme, že má normálne rozdelenie $N(\mu, \sigma^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty dĺžky lebky tejto populácie so strednou hodnotou dĺžky lebky novovekej egyptskej mužskej populácie 177.568 mm na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu dĺžky lebky, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku T_W , (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2). Výsledky Waldovho testu skontrolujte pomocou funkcie *t.test()*.

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : stredná hodnota dĺžky lebky starovekej egyptskej mužskej populácie je zhodná so strednou hodnotou dĺžky lebky novovekej egyptskej mužskej populácie oproti H_1 : stredná hodnota dĺžky lebky starovekej egyptskej mužskej populácie nie je zhodná so strednou hodnotou dĺžky lebky novovekej egyptskej mužskej populácie.
- **matematická formulácia** – $H_0 : \mu = \mu_0$ oproti $H_1 : \mu \neq \mu_0$, kde $\mu_0 = 177.568$.

2. **Testovacia štatistika** – Stredná hodnota μ a rozptyl σ^2 sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetický priemer $\bar{x} \doteq 182.037$ a rozptyl $s^2 \doteq 40.582$ (smerodajná odchýlka $s \doteq 6.370$).

```
745 | DATA <- read.table("one-sample-mean-skull-mf.txt", header=TRUE)
746 | attach(DATA)
747 | x <- na.omit(skull.L)
748 | n <- length(x) # 217
749 | priemer <- mean(x) # 182.0369
750 | rozptyl <- var(x) # 40.58197
751 | smerodch <- sd(x) # 6.370398
```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $t_W = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = \frac{182.037 - 177.568}{6.370} \sqrt{217} \doteq 10.334$.

Testovacia štatistika pomerom vierohodnosti $u_{LR} = n \ln \left(1 + \frac{t_W^2}{n-1} \right) \doteq 87.172$.

```
752 | mu0 <- 177.568
753 | tW.obs <- (priemer - mu0) / smerodch * sqrt(n) # 10.33382
754 | sigma.sq.hat <- (n-1) / n * var(x) # 40.58197
755 | sigma0.sq.hat <- sum((x - mu0)^2) / n # 60.36572
756 | uLR.obs <- n * log(sigma0.sq.hat / sigma.sq.hat) # 87.17249
```

3. **Zamietacia oblasť** –

Waldov test:

kritické hodnoty $t_{n-1}(1 - \alpha/2) = t_{216}(1 - 0.025) \doteq -1.971$ a $t_{n-1}(\alpha/2) = t_{216}(0.025) \doteq 1.971$;kritický obor $\mathcal{W}_1 = (t_{\min}, t_{n-1}(1 - \alpha/2)) \cup (t_{n-1}(\alpha/2), t_{\max}) = (-\infty, -1.971) \cup (1.971, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;kritický obor $\mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty)$.

```
757 | t.krit.d <- qt(0.025, df=n-1) # -1.971007
758 | t.krit.h <- qt(0.975, df=n-1) # 1.971007
759 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. **Empirický dvojstranný interval spoľahlivosti** –Waldov $100 \times (1 - \alpha)\%$ empirický DIS = 95% empirický DIS pre μ :
$$(d, h) = (\bar{x} - t_{n-1}(1 - \alpha/2) \frac{s}{\sqrt{n}}, \bar{x} + t_{n-1}(\alpha/2) \frac{s}{\sqrt{n}}) \doteq (182.037 - 1.971 \frac{6.370}{\sqrt{30}}, 182.037 + 1.971 \frac{6.370}{\sqrt{30}}) = (181.185, 182.890).$$
Vierohodnostný 95% empirický DIS pre μ :
$$CS_{0.95} = \{\mu_0 : u_{LR}(\mu_0) < \chi_1^2(\alpha)\} \doteq (181.188, 182.886).$$

```
760 | IS.W <- priemer+c(-1,1)*t.krit.h*smerodch/sqrt(n) # 181.1845 182.8892
761 | min.mu <- priemer-1*sd(x)
762 | max.mu <- priemer+1*sd(x)
763 | mu.0.i <- seq(min.mu, max.mu, by = 0.0001)
764 | tW.obs.i <- (priemer-mu.0.i)/sd(x)*sqrt(n)
765 | uW.obs.i <- tW.obs.i^2
766 | uLR.i <- n*log(1+uW.obs.i/(n-1))
767 | IS.LR <- range(mu.0.i[which(uLR.i < lr.krit.hodn)]) # 181.1876 182.8862
```

5. **Štatistický záver** –Waldov test: p-hodnota $\doteq 2\Pr(T_W \geq |10.334| | H_0) < 0.0001$.Test pomerom vierohodnosti: p-hodnota $\doteq \Pr(U_{LR} \geq 87.172 | H_0) < 0.0001$.

```
768 | p.hodn.W <- 2*(1-pt(abs(tW.obs), df=n-1)) # < 0.0001
769 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # < 0.0001
```

H_0 na hladine významnosti zamietame, pretože (1) testovacia štatistika patrí kritickému oboru, (2) $\mu_0 = 177.568$ nepatrí DIS a nakoniec (3) p-hodnota je menšia ako 0.05.

6. **Slovný záver** – Zamietame nulovú hypotézu o tom, že stredná hodnota dĺžky lebky starovekej egyptskej mužskej populácie je zhodná so strednou hodnotou dĺžky lebky novovekej egyptskej mužskej populácie.7. **Antropologický slovný záver** – V starovekej egyptskej populácii je hodnota dĺžky lebky štatisticky významne vyššia než v populácii novovekej. V uvedených populáciách by tak mohlo ísť o prejav sekulárneho trendu v zmysle skracovania dĺžky lebky, keďže ide o zmenu určitého parametra za dlhé časové obdobie. Vyvodzovanie záverov však vyžaduje testovanie rozdielov a j v šírkových rozmeroch, keďže brachycefalizácia predstavuje relatívne skracovanie lebky a ukazuje sa, že za zmeny v tvare lebky zodpovedajú predovšetkým zmeny v jej šírke.Riešenie pomocou funkcie `t.test()`:

```
770 | W.test <- t.test(x, mu=mu0)
771 | W.test$estimate # 182.0369
772 | W.test$conf.int # 181.1845 182.8892
773 | W.test$stat # 10.33382
774 | W.test$p.val # 1.344108e-20
```

Príklad 183 (vierohodnostný DIS pre μ) *Majme dáta one-sample-mean-skull-mf.txt a premennú dĺžka lebky skull.L v mm starovekej egyptskej mužskej populácie, o ktorej predpokladáme, že má normálne rozdelenie $N(\mu, \sigma^2)$. Vypočítajte vierohodnostný 95% empirický DIS pre strednú hodnotu dĺžky lebky μ pomocou 15% cut-off relatívnej (štandardizovanej) funkcie vierohodnosti $L(\theta|\mathbf{x}) = L(\theta|\mathbf{x})/L(\hat{\theta}|\mathbf{x})$ a porovnajte ho s vierohodnostným 95% empirický DIS pre μ .*

Príklad 184 (test o strednej hodnote μ) Majme dáta *one-sample-mean-skull-mf.txt* a premennú šírku lebky *skull.B* v mm starovekej egyptskej mužskej populácie, o ktorej predpokladáme, že má normálne rozdelenie $N(\mu, \sigma^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty šírky lebky tejto populácie so strednou hodnotou šírky lebky novovekej egyptskej mužskej populácie 136.402 mm na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu šírky lebky, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku T_W , (2) testovaciu štatistiku pomeru vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2).

Párový prípad. Predpokladajme, že $X_j \sim N(\mu_j, \sigma_j^2)$, kde σ_j^2 nie sú známe a $j = 1, 2$. Potom $X_d = X_1 - X_2 \sim N(\mu_d, \sigma_d^2)$, kde $\mu_d = \mu_1 - \mu_2$, $\sigma_d = \sqrt{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2}$ a ρ je korelačný koeficient medzi premennými X_1 a X_2 . Tiež platí $\bar{X}_d = \bar{X}_1 - \bar{X}_2 \sim N(\mu_d, \sigma_d^2/n)$. Majme dvojice hypotéz $H_{01} : \mu_d = \mu_0$ oproti $H_{11} : \mu_d \neq \mu_0$, $H_{02} : \mu_d \leq \mu_0$ oproti $H_{12} : \mu_d > \mu_0$, $H_{03} : \mu_d \geq \mu_0$ oproti $H_{13} : \mu_d < \mu_0$, ktoré chceme testovať. Na ich testovanie použijeme

1. **Waldovu testovaciu štatistiku** $t_W^{(d)}$, ktorá je ekvivalentná t_W , kde \bar{x} nahradíme \bar{x}_d a s nahradíme $s_d = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{d,i} - \bar{x}_d)^2}$; prislúchajúci test nazývame **párový Studentov t -test o strednej hodnote μ_d** ;
2. **testovaciu štatistiku pomerom vierohodnosti** $u_{LR}^{(d)}$, ktorá je ekvivalentná u_{LR} , kde $\hat{\sigma}_0^2$ nahradíme $\hat{\sigma}_{d,0}^2 = \frac{1}{n} \sum_{i=1}^n (x_{d,i} - \mu_d)^2$ a $\hat{\sigma}^2$ nahradíme $\hat{\sigma}_d^2 = \frac{1}{n} \sum_{i=1}^n (x_{d,i} - \bar{x}_d)^2$.

Párový prípad vzniká v praxi v troch základných situáciách:

1. jeden výskumník vykoná dve opakované merania jednej premennej v čase (sledovanou premennou je rozdiel merania v prvom a druhom časovom bode); merania slúžia na zistenie **intraindividuálnej chyby**;
2. dvaja výskumníci vykonajú každý jedno meranie jednej premennej (sledovanou premennou je rozdiel meraní prvého a druhého výskumníka); merania slúžia na zistenie **interindividuálnej chyby**;
3. jeden výskumník vykoná jedno meranie premennej na pravej a jedno na ľavej strane tela (sledovanou premennou je rozdiel meraní na pravej a ľavej strane); merania slúžia na zistenie **(a)symetrie**.

Párový Studentov t -test o strednej hodnote μ_d v \mathbb{R} (funkcia **t.test()**).

Argumenty (vstupy) funkcie:

1. vektor dát x ;
2. vektor dát y ;
3. alternatíva `alternative="two.sided"` je prednastavená, ďalšie voľby sú "greater", "less";
4. stredná hodnota za platnosti nulovej hypotézy μ_0 , t.j. μ_0 ;
5. párový prípad `paired = TRUE` (prednastavený je jednovýberový prípad `paired = FALSE`);
6. spoľahlivosť `conf.level=p`, prednastavené je `p=.95`.

Výstupy funkcie:

1. názov použitého testu `method`;
2. testovacia štatistika `statistic`;
3. počet stupňov voľnosti `df` parameter;
4. p -hodnota `p.value`;

5. alternatívna hypotéza *alternative hypothesis*;
6. interval spoľahlivosti pre μ_d *conf.int*;
7. bodový odhad rozdielu stredných hodnôt (aritmetický priemer \bar{x}_d) *sample estimates*.

Príklad 185 (test o strednej hodnote μ_d) *Majme dáta `paired-means-clavicle.txt` a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v podobe jej prvého (`simd.1`) a druhého (`simd.2`) merania v mm na pravej strane (`side` je rovná R). Zaujímá nás rozdiel prvého a druhého merania (**intraindividuálna chyba**) na pravej strane. O tomto rozdieli X_d predpokladáme, že má normálne rozdelenie $N(\mu_d, \sigma_d^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej strane na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej strane, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku $T_W^{(d)}$, (2) testovaciu štatistiku pomeru vierohodnosti $U_{LR}^{(d)}$ a DIS prishúchajúce (1) a (2).*

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : stredná hodnota rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej strane je rovná nule oproti H_1 : stredná hodnota rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej strane nie je rovná nule.
- **matematická formulácia** – $H_0 : \mu_d = \mu_0$ oproti $H_1 : \mu_d \neq \mu_0$, kde $\mu_0 = 0$.

2. **Testovacia štatistika** – Stredná hodnota μ_d a rozptyl σ_d^2 sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetický priemer $\bar{x}_d \doteq 0.011$ a rozptyl $s_d^2 \doteq 0.040$ (smerodajná odchýlka $s_d \doteq 0.200$).

```
775 | DATA <- read.table("paired-means-clavicle.txt", header=TRUE)
776 | attach(DATA)
777 | xd <- simd.1[side=="R"]-simd.2[side=="R"]
778 | n <- length(xd) # 40
779 | priemer <- mean(xd) # 0.01075
780 | rozptyl <- var(xd) # 0.04015583
781 | smerodch <- sd(xd) # 0.2003892
```

Pozorované testovacie štatistiky:

$$\text{Waldova testovacia štatistika } t_W^{(d)} = \frac{\bar{x}_d - \mu_0}{s_d} \sqrt{n} \doteq \frac{0.011 - 0}{0.200} \sqrt{40} \doteq 0.339.$$

$$\text{Testovacia štatistika pomerom vierohodnosti } u_{LR}^{(d)} = n \ln \left(1 + \frac{(t_W^{(d)})^2}{n-1} \right) \doteq 0.118.$$

```
782 | mu0 <- 0
783 | tdW.obs <- (priemer-mu0)/smerodch*sqrt(n) # 0.3392846
784 | sigmad.sq.hat <- (n-1)/n*var(xd) # 0.03915194
785 | sigmad0.sq.hat <- sum((xd-mu0)^2)/n # 0.0392675
786 | udLR.obs <- n*log(sigmad0.sq.hat/sigmad.sq.hat) # 0.1178918
```

3. Zamietacia oblasť –

Waldov test:

$$\text{kritické hodnoty } t_{n-1}(1 - \alpha/2) = t_{39}(1 - 0.025) \doteq -2.023 \text{ a } t_{n-1}(\alpha/2) = t_{39}(0.025) \doteq 2.023;$$

$$\text{kritický obor } \mathcal{W}_1 = (t_{\min}, t_{n-1}(1 - \alpha/2)) \cup (t_{n-1}(\alpha/2), t_{\max}) = (-\infty, -2.023) \cup (2.023, \infty).$$

Test pomerom vierohodnosti:

$$\text{kritická hodnota } \chi_1^2(\alpha) \doteq 3.841;$$

$$\text{kritický obor } \mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty).$$

```
787 | t.krit.d <- qt(0.025, df=n-1) # -2.022691
788 | t.krit.h <- qt(0.975, df=n-1) # 2.022691
789 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov $100 \times (1 - \alpha)\%$ empirický DIS=95% empirický DIS pre μ_d :

$$(d, h) = (\bar{x}_d - t_{n-1}(1 - \alpha/2) \frac{s_d}{\sqrt{n}}, \bar{x}_d + t_{n-1}(\alpha/2) \frac{s_d}{\sqrt{n}}) \doteq (-0.053, 0.075).$$

Vierohodnostný 95% empirický DIS pre μ_d :

$$\mathcal{CS}_{0.95} = \left\{ \mu_0 : u_{LR}^{(d)}(\mu_0) < \chi_1^2(\alpha) \right\} \doteq (-0.052, 0.074).$$

```

790 | IS.dW <- priemer+c(-1,1)*t.krit.h*smerodch/sqrt(n) # -0.05333758 0.07483758
791 | min.mu <- priemer-1*sd(xd)
792 | max.mu <- priemer+1*sd(xd)
793 | mu.0.i <- seq(min.mu, max.mu, by=0.0001)
794 | tdW.obs.i <- (priemer-mu.0.i)/sd(xd)*sqrt(n)
795 | udW.obs.i <- tdW.obs.i^2
796 | udLR.i <- n*log(1+udW.obs.i/(n-1))
797 | IS.dLR <- range(mu.0.i[which(udLR.i<lr.krit.hodn)]) # -0.0520392 0.0735608

```

5. Štatistický záver –

Waldov test: p-hodnota $\doteq 2\Pr(T_W^{(d)} \geq |0.339| | H_0) \doteq 0.736$.

Test pomerom vierohodnosti: p-hodnota $\doteq \Pr(U_{LR} \geq 0.118 | H_0) \doteq 0.731$.

```

798 | p.hodn.dW <- 2*(1-pt(abs(tdW.obs), df=n-1)) # 0.7362156
799 | p.hodn.dLR <- 1-pchisq(udLR.obs, df=1) # 0.7313324

```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\mu_0 = 0$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. **Slovný záver** – Nezamietame nulovú hypotézu o tom, že stredná hodnota rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej strane je rovná nule.

7. **Antropologický slovný záver** – Rozdiely medzi opakovanými meraniami sú dostatočne nízke, intraindividuálna chyba akceptovateľná a predpoklady ďalších analýz splnené.

Riešenie pomocou funkcie `t.test()`:

```

800 | Wd.test <- t.test(simd.1[side=="R"], simd.2[side=="R"], mu=0, paired=TRUE)
801 | Wd.test$estimate # 0.01075
802 | Wd.test$conf.int # -0.05333758 0.07483758
803 | Wd.test$stat # 0.3392846
804 | Wd.test$p.val # 0.7362156

```

Príklad 186 (test o strednej hodnote μ_d) Majme dáta `paired-means-clavicle.txt` a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v podobe jej prvého (`simd.1`) a druhého (`simd.2`) merania v mm na ľavej strane (`side` je rovná L). Zaujíma nás rozdiel prvého a druhého merania (**intraindividuálna chyba**) na ľavej strane. O tomto rozdieli X_d predpokladáme, že má normálne rozdelenie $N(\mu_d, \sigma_d^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej strane na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu rozdielu prvého a druhého merania vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej strane, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku $T_W^{(d)}$, (2) testovaciu štatistiku pomeru vierohodnosti $U_{LR}^{(d)}$ a DIS prislúchajúce (1) a (2).

Príklad 187 (test o strednej hodnote μ_d) Majme dáta `paired-means-clavicle.txt` a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v mm (priemer prvého a druhého merania `simd.1` a `simd.2`) na ľavej (`side` sa rovná L) a pravej (`side` sa rovná R). Tieto merania vykonal prvý výskumník. Druhý výskumník zmeral vertikálny priemer v strede dĺžky tela kľúčnej kosti jedenkrát (`simd`). Zaujíma nás rozdiel meraní oboch výskumníkov (**interindividuálna chyba**) na pravej strane. O tomto rozdieli X_d predpokladáme, že má normálne rozdelenie $N(\mu_d, \sigma_d^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti u prvého a druhého výskumníka

na pravej strane na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej a pravej strane, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku $T_W^{(d)}$, (2) testovaciu štatistiku pomeru vierohodnosti $U_{LR}^{(d)}$ a DIS prislúchajúce (1) a (2).

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : stredná hodnota rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti u prvého a druhého výskumníka na pravej strane je rovná nule oproti H_1 : stredná hodnota rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti u prvého a druhého výskumníka na pravej strane nie je rovná nule.
- **matematická formulácia** – $H_0 : \mu_d = \mu_0$ oproti $H_1 : \mu_d \neq \mu_0$, kde $\mu_0 = 0$.

2. **Testovacia štatistika** – Stredná hodnota μ_d a rozptyl σ_d^2 sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetický priemer $\bar{x}_d \doteq -0.457$ a rozptyl $s_d^2 \doteq 0.709$ (smerodajná odchýlka $s_d \doteq 0.842$).

```
805 | DATA <- read.table("paired-means-clavicle.txt", header=TRUE)
806 | attach(DATA)
807 | simd.xbar.R <- (simd.1[side=="R"]+simd.2[side=="R"])/2
808 | xd <- na.omit(simd.xbar.R-simd[side=="R"])
809 | n <- length(xd) # 39
810 | priemer <- mean(xd) # -0.4569231
811 | rozptyl <- var(xd) # 0.7085442
812 | smerodch <- sd(xd) # 0.8417507
```

Pozorované testovacie štatistiky:

$$\text{Waldova testovacia štatistika } t_W^{(d)} = \frac{\bar{x}_d - \mu_0}{s_d} \sqrt{n} \doteq \frac{-0.457 - 0}{0.842} \sqrt{39} \doteq -0.390.$$

$$\text{Testovacia štatistika pomerom vierohodnosti } u_{LR}^{(d)} = n \ln \left(1 + \frac{(t_W^{(d)})^2}{n-1} \right) \doteq 10.305.$$

```
813 | mu0 <- 0
814 | tdW.obs <- (priemer-mu0)/smerodch*sqrt(n) # -3.389939
815 | sigmad.sq.hat <- (n-1)/n*var(xd) # 0.6903764
816 | sigmad0.sq.hat <- sum((xd-mu0)^2)/n # 0.899155
817 | udLR.obs <- n*log(sigmad0.sq.hat/sigmad.sq.hat) # 10.30452
```

3. Zamietacia oblasť –

Waldov test:

$$\text{kritické hodnoty } t_{n-1}(1 - \alpha/2) = t_{38}(1 - 0.025) \doteq -2.024 \text{ a } t_{n-1}(\alpha/2) = t_{38}(0.025) \doteq 2.024;$$

$$\text{kritický obor } \mathcal{W}_1 = (t_{\min}, t_{n-1}(1 - \alpha/2)) \cup (t_{n-1}(\alpha/2), t_{\max}) = (-\infty, -2.024) \cup (2.024, \infty).$$

Test pomerom vierohodnosti:

$$\text{kritická hodnota } \chi_1^2(\alpha) \doteq 3.841;$$

$$\text{kritický obor } \mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty).$$

```
818 | t.krit.d <- qt(0.025, df=n-1) # -2.024394
819 | t.krit.h <- qt(0.975, df=n-1) # 2.024394
820 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov $100 \times (1 - \alpha)\%$ empirický DIS = 95% empirický DIS pre μ_d :

$$(d, h) = (\bar{x}_d - t_{n-1}(1 - \alpha/2) \frac{s_d}{\sqrt{n}}, \bar{x}_d + t_{n-1}(\alpha/2) \frac{s_d}{\sqrt{n}}) \doteq (-0.730, -0.184).$$

Vierohodnostný 95% empirický DIS pre μ_d :

$$\mathcal{CS}_{0.95} = \left\{ \mu_0 : u_{LR}^{(d)}(\mu_0) < \chi_1^2(\alpha) \right\} \doteq (-0.724, -0.190).$$

```
821 | IS.dW <- priemer+c(-1,1)*t.krit.h*smerodch/sqrt(n) # -0.7297871 -0.1840591
822 | min.mu <- priemer-1*sd(xd)
823 | max.mu <- priemer+1*sd(xd)
824 | mu.0.i <- seq(min.mu, max.mu, by = 0.0001)
825 | tdW.obs.i <- (priemer-mu.0.i)/sd(xd)*sqrt(n)
826 | udW.obs.i <- tdW.obs.i^2
827 | udLR.i <- n*log(1+udW.obs.i/(n-1))
828 | IS.dLR <- range(mu.0.i[which(udLR.i<lr.krit.hodn)]) # -0.7241738 -0.1896738
```


5. Štatistický záver –

Waldov test: p -hodnota $\doteq 2\Pr(T_W^{(d)} \geq | -0.390 | | H_0) \doteq 0.002$.

Test pomerom vierohodnosti: p -hodnota $\doteq \Pr(U_{LR}^{(d)} \geq 10.305 | H_0) \doteq 0.001$.

```
829 | p.hodn.dW <- 2*(1-pt(abs(tdW.obs),df=n-1)) # 0.001642062
830 | p.hodn.dLR <- 1-pchisq(udLR.obs,df=1) # 0.001327044
```

H_0 na hladine významnosti zamietame, pretože (1) testovacia štatistika patrí kritickému oboru, (2) $\mu_0 = 0$ nepatrí DIS a nakoniec (3) p -hodnota je menšia ako 0.05.

6. Slovný záver – Zamietame nulovú hypotézu o tom, že stredná hodnota rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti u prvého a druhého výskumníka na pravej strane je rovná nule.

7. Antropologický záver – Hodnoty meraní prvého výskumníka sú v priemere o 0.46 mm vyššie než hodnoty druhého výskumníka. Dôvodom tohto štatisticky významného rozdielu môže byť odlišnosť v kalibrácii merania, keďže obaja výskumníci merali iným prístrojom. Iným možným vysvetlením systematického rozdielu je odlišné chápanie definície rozmeru a vertikály na kosti.

Riešenie pomocou funkcie `t.test()`:

```
831 | Wd.test <- t.test(simd.xbar.R, simd[side=="R"], mu=0, paired=TRUE)
832 | Wd.test$estimate # -0.4569231
833 | Wd.test$conf.int # -0.7297871 -0.1840591
834 | Wd.test$stat # -3.389939
835 | Wd.test$p.val # 0.001642062
```

Príklad 188 (test o strednej hodnote μ_d) Majme dáta *paired-means-clavicle.txt* a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v mm (priemer prvého a druhého merania *simd.1* a *simd.2*) na ľavej (*side* sa rovná L) a pravej (*side* sa rovná R). Tieto merania vykonal prvý výskumník. Druhý výskumník zmeral vertikálny priemer v strede dĺžky tela kľúčnej kosti jedenkrát (*simd*). Zaujímá nás rozdiel meraní oboch výskumníkov (*interindividuálna chyba*) na ľavej strane. O tomto rozdiel X_d predpokladáme, že má normálne rozdelenie $N(\mu_d, \sigma_d^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti u prvého a druhého výskumníka na ľavej strane na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej a pravej strane, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku $T_W^{(d)}$, (2) testovaciu štatistiku pomeru vierohodnosti $U_{LR}^{(d)}$ a DIS prislúchajúce (1) a (2).

Príklad 189 (test o strednej hodnote μ_d) Majme dáta *paired-means-clavicle.txt* a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v mm (priemer prvého a druhého merania *simd.1* a *simd.2*) na ľavej (*side* sa rovná L) a pravej (*side* sa rovná R). Zaujímá nás rozdiel priemerných meraní na pravej a ľavej strane (**(a) symetria**). O tomto rozdiel X_d predpokladáme, že má normálne rozdelenie $N(\mu_d, \sigma_d^2)$. (a) Otestujte hypotézu o zhode strednej hodnoty rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej a ľavej strane na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre strednú hodnotu rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej a pravej strane, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku $T_W^{(d)}$, (2) testovaciu štatistiku pomeru vierohodnosti $U_{LR}^{(d)}$ a DIS prislúchajúce (1) a (2).

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : stredná hodnota rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej a pravej strane je rovná nule oproti H_1 : stredná hodnota rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej a pravej strane nie je rovná nule.

- **matematická formulácia** – $H_0 : \mu_d = \mu_0$ oproti $H_1 : \mu_d \neq \mu_0$, kde $\mu_0 = 0$.

2. **Testovacia štatistika** – Stredná hodnota μ_d a rozptyl σ_d^2 sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetický priemer $\bar{x}_d \doteq -0.029$ a rozptyl $s_d^2 \doteq 0.611$ (smerodajná odchýlka $s_d \doteq 0.782$).

```

836 DATA <- read.table("paired-means-clavicle.txt", header=TRUE)
837 attach(DATA)
838 simd.xbar.R <- (simd.1[side=="R"]+simd.2[side=="R"])/2
839 simd.xbar.L <- (simd.1[side=="L"]+simd.2[side=="L"])/2
840 xd <- simd.xbar.R-simd.xbar.L
841 n <- length(xd) # 40
842 priemer <- mean(xd) # -0.029
843 rozptyl <- var(xd) # 0.6112695
844 smerodch <- sd(xd) # 0.7818373

```

Pozorované testovacie štatistiky:

$$\text{Waldova testovacia štatistika } t_W^{(d)} = \frac{\bar{x}_d - \mu_0}{s_d} \sqrt{n} \doteq \frac{-0.029 - 0}{0.782} \sqrt{40} \doteq -0.23.$$

$$\text{Testovacia štatistika pomerom vierohodnosti } u_{LR}^{(d)} = n \ln \left(1 + \frac{(t_W^{(d)})^2}{n-1} \right) \doteq 0.056.$$

```

845 mu0 <- 0
846 tdW.obs <- (priemer-mu0)/smerodch*sqrt(n) # -0.2345912
847 sigmad.sq.hat <- (n-1)/n*var(xd) # 0.5959878
848 sigmad0.sq.hat <- sum((xd-mu0)^2)/n # 0.5968288
849 udLR.obs <- n*log(sigmad0.sq.hat/sigmad.sq.hat) # 0.05640433

```

3. **Zamietacia oblasť** –

Waldov test:

$$\text{kritické hodnoty } t_{n-1}(1 - \alpha/2) = t_{39}(1 - 0.025) \doteq -2.023 \text{ a } t_{n-1}(\alpha/2) = t_{39}(0.025) \doteq 2.023;$$

$$\text{kritický obor } \mathcal{W}_1 = (t_{\min}, t_{n-1}(1 - \alpha/2)) \cup (t_{n-1}(\alpha/2), t_{\max}) = (-\infty, -2.023) \cup (2.023, \infty).$$

Test pomerom vierohodnosti:

$$\text{kritická hodnota } \chi_1^2(\alpha) \doteq 3.841;$$

$$\text{kritický obor } \mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty).$$

```

850 t.krit.d <- qt(0.025, df=n-1) # -2.022691
851 t.krit.h <- qt(0.975, df=n-1) # 2.022691
852 lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459

```

4. **Empirický dvojstranný interval spoľahlivosti** –

Waldov 100 × (1 - α)% empirický DIS = 95% empirický DIS pre μ_d :

$$(d, h) = (\bar{x}_d - t_{n-1}(1 - \alpha/2) \frac{s_d}{\sqrt{n}}, \bar{x}_d + t_{n-1}(\alpha/2) \frac{s_d}{\sqrt{n}}) \doteq (-0.279, 0.221).$$

Vierohodnostný 95% empirický DIS pre μ_d :

$$CS_{0.95} = \left\{ \mu_0 : u_{LR}^{(d)}(\mu_0) < \chi_1^2(\alpha) \right\} \doteq (-0.274, 0.216).$$

```

853 IS.dW <- priemer+c(-1,1)*t.krit.h*smerodch/sqrt(n) # -0.2790437 0.2210437
854 min.mu <- priemer-1*sd(xd)
855 max.mu <- priemer+1*sd(xd)
856 mu.0.i <- seq(min.mu, max.mu, by=0.0001)
857 tdW.obs.i <- (priemer-mu.0.i)/sd(xd)*sqrt(n)
858 udW.obs.i <- tdW.obs.i^2
859 udLR.i <- n*log(1+udW.obs.i/(n-1))
860 IS.dLR <- range(mu.0.i[which(udLR.i<lr.krit.hodn)]) # -0.2740373 0.2160627

```

5. **Štatistický záver** –

$$\text{Waldov test: p-hodnota} \doteq 2\Pr(T_W^{(d)} \geq | -0.235 | | H_0) \doteq 0.816.$$

$$\text{Test pomerom vierohodnosti: p-hodnota} \doteq \Pr(U_{LR}^{(d)} \geq 0.056 | H_0) \doteq 0.812.$$

```

861 p.hodn.dW <- 2*(1-pt(abs(tdW.obs), df=n-1)) # 0.8157534
862 p.hodn.dLR <- 1-pchisq(udLR.obs, df=1) # 0.8122721

```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\mu_0 = 0$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. **Slovný záver** – Nezamietame nulovú hypotézu o tom, že stredná hodnota rozdielu vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na ľavej a pravej strane je rovná nule.

7. **Antropologický slovný záver** – Napriek tomu, že na rozmeroch kľúčnej kosti sú popisované výrazné systematické stranové rozdiely (kľúčna kosť ľavej strany je v priemere dlhšia a graciejšia), v sledovanom rozmere sme žiadnu smerovú asymetriu nedokázali. Pravdepodobne je v tomto rozmere, na rozdiel od iných, vzorec biomechanického zaťažovania na oboch stranách tela podobný.

Riešenie pomocou funkcie `t.test()`:

```
863 | Wd.test <- t.test(simd.xbar.R, simd.xbar.L, mu=0, paired=TRUE)
864 | Wd.test$estimate # -0.029
865 | Wd.test$conf.int # -0.2790437 0.2210437
866 | Wd.test$stat # -0.2345912
867 | Wd.test$sp.val # 0.8157534
```

Príklad 190 (programovanie TEM, TEM_{rel} a CR) Naprogramujte v \mathbb{R} vzorce na výpočet

- technickej chyby merania TEM
- relatívnej technickej chyby merania TEM_{rel} a
- koefficientu reliability merania CR.

Riešenie

TEM = $\sqrt{\frac{\sum_{i=1}^n x_{d,i}^2}{2n}}$, kde $x_{d,i} = x_{i1} - x_{i2}$ je rozdiel medzi meraniami,

TEM_{rel} = $\frac{TEM}{\bar{x}}$ × 100, kde \bar{x} je celková priemerná hodnota,

CR = $(1 - \frac{TEM^2}{s^2})$ × 100, kde s je celková smerodajná odchýlka.

```
868 | "tem" <- function(x1, x2) sqrt(sum((x1-x2)^2)/(2*length(x1)))
869 | "tem.rel" <- function(x1, x2) tem(x1, x2)/mean(c(x1, x2))
870 | "cr" <- function(x1, x2) (1-(tem(x1, x2))^2/var(c(x1, x2)))
```

Príklad 191 (výpočet TEM, TEM_{rel} a CR) Majme dáta `paired-means-clavicle.txt` a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v podobe jej prvého (`simd.1`) a druhého (`simd.2`) merania v mm na pravej strane (`side` je rovná R). Zaujímá nás rozdiel prvého a druhého merania na pravej strane. Vypočítajte (a) intraindividuálnu technickú chybu merania TEM, (b) intraindividuálnu relatívnu technickú chybu merania TEM_{rel} a (c) intraindividuálny koefficient reliability merania CR.

Riešenie v \mathbb{R}

```
871 | DATA <- read.table("paired-means-clavicle.txt", header=TRUE)
872 | attach(DATA)
873 | tem(simd.1[side=="R"], simd.2[side=="R"]) # 0.1401205
874 | tem.rel(simd.1[side=="R"], simd.2[side=="R"])*100 # 1.469326
875 | cr(simd.1[side=="R"], simd.2[side=="R"])*100 # 99.14755
```

Technická chyba merania predstavuje 0.14 mm na jedno meranie, čo zodpovedá 1.47 % aritmetického priemeru vertikálneho priemeru v strede dĺžky tela kľúčnej kosti na pravej strane. Koefficient reliability je rovný 99.15 %, čo zodpovedá vysokej presnosti a opakovateľnosti merania tohoto výskumníka.

Príklad 192 (výpočet TEM, TEM_{rel} a CR) Majme dáta `paired-means-clavicle.txt` a premennú vertikálny priemer v strede dĺžky tela kľúčnej kosti v mm (priemer prvého a druhého merania `simd.1` a `simd.2`) na ľavej (`side` sa rovná L) a pravej (`side` sa rovná R). Tieto merania vykonal prvý výskumník. Druhý výskumník zmeral vertikálny priemer v strede dĺžky tela kľúčnej kosti jedenkrát (`simd`). Zaujímá nás rozdiel meraní oboch výskumníkov na pravej strane. Vypočítajte (a) interindividuálnu technickú chybu merania TEM, (b) interindividuálnu relatívnu technickú chybu merania TEM_{rel} a (c) interindividuálny koefficient reliability merania CR.

Riešenie v \mathbb{R}

```

876 DATA <- read.table("paired-means-clavicle.txt", header=TRUE)
877 attach(DATA)
878 id <- !is.na(simd[side=="R"])
879 simd2 <- apply(cbind(simd.1[side=="R"], simd.2[side=="R"]), 1, mean)
880 simd2 <- simd2[id]
881 simd1 <- simd[side=="R"]
882 simd1 <- simd1[id]
883
884 tem(simd1, simd2) # 0.6705055
885 tem.rel(simd1, simd2)*100 # 6.834918
886 cr(simd1, simd2)*100 # 83.29

```

Technická chyba merania predstavuje 0.67 mm na jedno meranie, čo zodpovedá 6.83 % aritmetického priemeru vertikálneho priemeru v strede dĺžky tela klúčnej kosti na pravej strane. Relatívna technická chyba merania je teda vyššia ako odporúčaných 5 %. Koefficient reliability je rovný 83.29 %, čo zodpovedá nízkej presnosti a veľkým rozdielom medzi oboma výskumníkmi. Koefficient reliability je teda oveľa nižší ako odporúčaných 95 %. Súbor nameraný druhým výskumníkom nie je možné použiť ako zdrojové dáta v antropologickom výskume.

6.2 Asymptotické testy o rozptyle

V biologickej antropológii je niekedy potrebné zistiť, aký je rozptyl sledovanej veličiny v danej vzorke, a či je zhodný s rozptylom v referenčnom súbore alebo publikovaným údajom v porovnávacej populácii. Rozdiely medzi populáciami v rozptyle môžu mať celý rad vysvetlení. Rozptyl biologického znaku, napr. veku menarché, dĺžky hlavy alebo stranových rozdielov v prípade bilaterálne symetrických znakov, je odrazom variability premenných (genetických i environmentálnych), ktorých odlišnosti spôsobia, že sa populácie v rozptyle tohto znaku líšia. Populácie s väčším rozptylom daného znaku môžu byť, napr. vo veľkej, reprodukčne málo obmedzenej populácii, ovplyvnené väčšou mierou genetického polymorfizmu a väčšou genetickou variabilitou. Väčší rozptyl stranových rozdielov párových znakov (vyššia miera fluktuáčnej asymetrie) zas môže na úrovni populácie indikovať vyššiu vývinovú nestabilitu jedinca a horšie životné podmienky celej populácie. Znaky s malým rozptylom boli v evolúcii – alebo ešte aktuálne sú – pod silným vplyvom stabilizujúcej selekcie (u človeka napr. znaky súvisiace s bipédiou). Ak napríklad populácia žije v prostredí so špecifickými, úzko definovanými zdrojmi, ktoré obmedzujú výber jedincov na tých s vlastnosťami najvýhodnejšie prispôbenými danému prostrediu, či už mechanizmom selekcie sociálnej (pohrebisko vojakov vyberaných do jednotky na základe výšky postavy), selekcie prírodnej alebo migrácie (migrujú len jedinci s určitými vlastnosťami), stredná hodnota sledovaného znaku sa posunúť nemusí, hodnota rozptylu sa však zníži. Podobným spôsobom ako uvedené systematické vplyvy môže rozptyl znížiť aj náhodné zmenšenie veľkosti populácie (evolučné javy známe ako efekt zakladateľa (*founder effect*), efekt hrdla fľaše (*bottleneck effect*)).

Okrem biologických premenných však rozptyl veľmi ovplyvňuje tiež spôsob vzniku vzorky (náhodný výber) a rôzne nenáhodné vplyvy vzorkovania. Ak je napríklad kostrové pohrebisko usporiadané na základe príbuzenských princípov, je možné, že vzorka záchranného výskumu z jednej obmedzenej časti pohrebiska bude obsahovať veľký podiel príbuzných jedincov s menším rozptylom silno dedičných znakov. Vzhľadom na to, že informácie o všetkých faktoroch (biologických a metodických) potenciálne ovplyvňujúcich výsledný rozptyl bývajú pri popise vzorky publikovanej zriedkavo, interpretácia testom zistených rozdielov v rozptyle býva neľahká. Môže totiž ísť buď o jasné biologické rozdiely medzi populáciami, alebo metodické nezrovnalosti, alebo, a to je v reálnej situácii najpravdepodobnejšie, o nejakú kombináciu oboch skupín príčin.

Nech $X \sim N(\mu, \sigma^2)$. Majme dvojice hypotéz $H_{01} : \sigma^2 = \sigma_0^2$ oproti $H_{11} : \sigma^2 \neq \sigma_0^2$, $H_{02} : \sigma^2 \leq \sigma_0^2$ oproti $H_{12} : \sigma^2 > \sigma_0^2$, $H_{03} : \mu \geq \sigma_0^2$ oproti $H_{13} : \sigma^2 < \sigma_0^2$, ktoré chceme testovať.

Ak H_0 platí, potom

$$F_W = \frac{(n-1)S^2}{\sigma_0^2} \stackrel{\mathcal{D}}{\sim} \chi_{n-1}^2,$$

kde $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ a rozdelenie χ_{df}^2 , kde $df = n - 1$, sa nazýva **centrálne χ^2 -rozdelenie** s $df = n - 1$ stupňami voľnosti. F_W sa nazýva **Waldova testovacia štatistika** (alebo **χ^2 -štatistika**) a test **jednovýberový χ^2 -test o rozptyle σ^2** .

Chceme nájsť kritickú hodnotu d_S^* za platnosti H_{02} , tak aby platilo $\Pr(S^2 < d_S^* | H_{02}) = \alpha$. Teda

$$\alpha = \Pr\left(\frac{(n-1)S^2}{\sigma_0^2} < d_S^* \frac{n-1}{\sigma_0^2} | H_{02}\right) = \Pr\left(F_W < d_S^* \frac{n-1}{\sigma_0^2} | H_{02}\right)$$

a z toho vyplýva, že $d_S^* = \chi_{n-1}^2(1-\alpha) \frac{\sigma_0^2}{n-1}$. Ak H_{02} neplatí, t.j. skutočný rozptyl je σ_1^2 (platí H_{12}), potom chceme nájsť pravdepodobnosť zamietnutia H_{02} (silu testu). To je pravdepodobnosť, že S^2 neprekročí d_S^* , teda

$$\Pr(S^2 < d_S^* | H_{12}) = \Pr\left(\frac{(n-1)S^2}{\sigma_1^2} < d_S^* \frac{n-1}{\sigma_1^2} | H_{12}\right) = \Pr\left(F_W^{(alt)} < \frac{\sigma_0^2}{\sigma_1^2} \chi_{n-1}^2(1-\alpha) | H_{12}\right),$$

kde $F_W^{(alt)} = \frac{(n-1)S^2}{\sigma_1^2}$.

Chceme nájsť kritickú hodnotu h_S^* za platnosti H_{03} , tak aby platilo $\Pr(S^2 < h_S^* | H_{03}) = 1 - \alpha$. Teda

$$1 - \alpha = \Pr\left(\frac{(n-1)S^2}{\sigma_0^2} < h_S^* \frac{n-1}{\sigma_0^2} | H_{03}\right) = \Pr\left(F_W < h_S^* \frac{n-1}{\sigma_0^2} | H_{03}\right)$$

a z toho vyplýva, že $h_S^* = \chi_{n-1}^2(\alpha) \frac{\sigma_0^2}{n-1}$. Ak H_{03} neplatí, t.j. skutočný rozptyl je σ_1^2 (platí H_{13}), potom chceme nájsť pravdepodobnosť zamietnutia H_{03} (silu testu). To je pravdepodobnosť, že S^2 prekročí h_S^* , teda

$$\Pr(S^2 > h_S^* | H_{13}) = \Pr\left(\frac{(n-1)S^2}{\sigma_1^2} > h_S^* \frac{n-1}{\sigma_1^2} | H_{13}\right) = \Pr\left(F_W^{(alt)} > \frac{\sigma_0^2}{\sigma_1^2} \chi_{n-1}^2(\alpha) | H_{13}\right).$$

Ak by sme chceli nájsť kritické hodnoty d_S a h_S pre test H_{01} oproti H_{11} , použili by sme podobnú úvahu ako vyššie.

Príklad 193 *Ovôdte vzorec na výpočet kritických hodnôt d_S a h_S pre H_{01} .*


Definícia 55 (Kritický obor a silofunkcia F_W testu o σ^2) *Kritický obor a silofunkcia sú definované (za platnosti $d_{\alpha/2} = \chi_{n-1}^2(1-\alpha/2)$, $h_{\alpha/2} = \chi_{n-1}^2(\alpha/2)$, $d_\alpha = \chi_{n-1}^2(1-\alpha)$ a $h_\alpha = \chi_{n-1}^2(\alpha)$) nasledovne:*

H_0	H_1	\mathcal{W}	$1 - \beta(\sigma^2)$
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$\mathcal{W}_1 = \{F_W; F_W \notin (d_{\alpha/2}, h_{\alpha/2})\}$	$1 - \Pr\left(\frac{\sigma_0^2}{\sigma^2} d_{\alpha/2} < F_W^{(alt)} < \frac{\sigma_0^2}{\sigma^2} h_{\alpha/2}\right)$
$\sigma^2 \leq \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$\mathcal{W}_2 = \{F_W; F_W \geq h_\alpha\}$	$\Pr\left(F_W^{(alt)} \geq \frac{\sigma_0^2}{\sigma^2} h_\alpha\right)$
$\sigma^2 \geq \sigma_0^2$	$\sigma^2 < \sigma_0^2$	$\mathcal{W}_3 = \{F_W; F_W \leq d_\alpha\}$	$\Pr\left(F_W^{(alt)} \leq \frac{\sigma_0^2}{\sigma^2} d_\alpha\right)$

Príklad 194 (silofunkcia) *Nakreslite v \mathbb{R} do jedného obrázka silofunkcie $1 - \beta(\sigma^2)$ pri $\alpha = 0.05$ a $n = 10, 20, 30, 40$ a 50 . Rozumne zvolte podiel σ^2/σ_0^2 , ktorý bude na osi x . Obrázky vytvorte pre (a) H_{11} , (b) H_{12} a (c) H_{13} . Riešenie pozri na obrázku 6.6.*

Definícia 56 (p-hodnota F_W testu o σ^2) *Nech F_W je nejaká testovacia štatistika a $F_{obs} = \frac{(n-1)s^2}{\sigma_0^2}$ je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:*

$$p\text{-hodnota} = \begin{cases} 2 \min(\Pr(F_W \leq F_{obs} | H_{01}), \Pr(F_W \geq F_{obs} | H_{01})), & \text{ak } H_{11} : \sigma^2 \neq \sigma_0^2 \\ \Pr(F_W \geq F_{obs} | H_{02}), & \text{ak } H_{12} : \sigma^2 > \sigma_0^2 \\ \Pr(F_W \leq F_{obs} | H_{03}), & \text{ak } H_{13} : \sigma^2 < \sigma_0^2 \end{cases}$$



Obr. 6.6: Silofunkcie asymptotického testu o σ^2 pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 57 (Waldove $100 \times (1 - \alpha)\%$ empirické IS pre σ^2) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre σ^2 pre všetky tri typy hypotéz majú nasledovný tvar:

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$CS_{1-\alpha} = \left\{ \sigma_0^2 : \sigma_0^2 \in \left(\frac{(n-1)s^2}{H_{\alpha/2}}, \frac{(n-1)s^2}{D_{\alpha/2}} \right) \right\}$
$\sigma^2 \leq \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$CS_{1-\alpha} = \left\{ \sigma_0^2 : \sigma_0^2 \in \left(\frac{(n-1)s^2}{H_\alpha}, \infty \right) \right\}$
$\sigma^2 \geq \sigma_0^2$	$\sigma^2 < \sigma_0^2$	$CS_{1-\alpha} = \left\{ \sigma_0^2 : \sigma_0^2 \in \left(0, \frac{(n-1)s^2}{D_\alpha} \right) \right\}$

Príklad 195 (horná hranica IS pre σ^2) Nech $X \sim N(\mu, \sigma^2)$, $\mu = 0$ a $\sigma^2 = 4$. Vypočítajte v \mathbb{R} hornú hranicu pravostranného (horného) 95% JIS pre σ^2 , t.j. $\frac{(n-1)s^2}{\chi_{n-1}^2(1-\alpha)}$, ak $n = 20$ a $s^2 = 4$.

Riešenie (aj v \mathbb{R})

$\Pr \left(\frac{(n-1)S^2}{\chi_{n-1}^2(1-\alpha)} < \frac{(n-1)s^2}{\chi_{n-1}^2(1-\alpha)} \right) = 1 - \alpha$, kde $\chi_{n-1}^2(1-\alpha) = 10.117$, $n = 20$ a $\alpha = 0.05$. Potom $\frac{(n-1)s^2}{\chi_{n-1}^2(1-\alpha)} = 7.512$.

```
887 | n <- 20
888 | alfa <- .05
889 | HH <- (n-1)*4/qchisq(alfa, df=n-1) # 7.512099
```

Príklad 196 (MC odhad koeficientu spoľahlivosti $1 - \alpha$) Vypočítajte v \mathbb{R} MC odhad koeficientu spoľahlivosti (pravdepodobnosti pokrytia) pre pravostranný (horný) 95% JIS pre σ^2 pri $M = 1000$ a $n = 20$. Tento JIS je ekvivalentný s testom H_{02} oproti H_{12} . (a) Nech $X \sim N(0, 4)$, (b) $X \sim \chi^2(2)$ a (c) $X \sim [pN(0, 4) + (1 - p)N(0, 9)]$, kde $p = 0.9$.

Riešenie v \mathbb{R}

(a)

```
890 | M <- 1000
891 | n <- 20
892 | alfa <- .05
893 | HH <- replicate(M, expr={
894 |   x <- rnorm(n, mean=0, sd=2)
895 |   (n-1) * var(x)/qchisq(alfa, df=n-1)
896 | })
897 | sum(HH>4) # 953
898 | alfa.hat <- mean(HH>4) # 0.953
899 | SE.alfa.hat <- sqrt(alfa.hat*(1-alfa.hat)/M) # 0.006692608
900 | alfa.hat+c(-1,1)*qnorm(0.975)*SE.alfa.hat # 0.9398827 0.9661173
```

(a) Empirický koeficient spoľahlivosti $1 - \hat{\alpha} = 0.953$ a $SE[1 - \hat{\alpha}] = \sqrt{\hat{\alpha}(1 - \hat{\alpha})/M} = 0.0067$. 95% DIS pre $1 - \alpha$ je rovný $(d, h) = (0.940, 0.966)$. Tento DIS obsahuje skutočnú hodnotu $1 - \alpha = 0.95$.

(b) Empirický koeficient spoľahlivosti $1 - \hat{\alpha} = 0.788$ a $SE[1 - \hat{\alpha}] = \sqrt{\hat{\alpha}(1 - \hat{\alpha})/M} = 0.013$. 95% DIS

pre $1 - \alpha$ je rovný $(d, h) = (0.763, 0.813)$. Tento DIS neobsahuje skutočnú hodnotu $1 - \alpha = 0.95$.

(c) Empirický koeficient spoľahlivosti $1 - \hat{\alpha} = 0.966$ a $SE[\widehat{1 - \hat{\alpha}}] = \sqrt{\hat{\alpha}(1 - \hat{\alpha})/M} = 0.0057$. 95% DIS pre $1 - \alpha$ je rovný $(d, h) = (0.955, 0.977)$. Tento DIS neobsahuje skutočnú hodnotu $1 - \alpha = 0.95$.

Minimálny rozsah n pre nejaký podiel $\frac{\sigma_0^2}{\sigma^2}$ (pri nejakom α a β) vypočítame iteratívne pomocou nasledovných rovností:

$$\begin{aligned} \frac{\chi_{n-1}^2(1-\beta)}{\chi_{n-1}^2(\alpha/2)} &\approx \frac{\sigma_0^2}{\sigma^2} \text{ za platnosti } H_{11}; \\ \frac{\chi_{n-1}^2(1-\beta)}{\chi_{n-1}^2(\alpha)} &= \frac{\sigma_0^2}{\sigma^2} \text{ za platnosti } H_{12}; \\ \frac{\chi_{n-1}^2(\beta)}{\chi_{n-1}^2(1-\alpha)} &= \frac{\sigma_0^2}{\sigma^2} \text{ za platnosti } H_{13}. \end{aligned}$$

Pri obojstrannej alternatíve ide o približný výpočet, kedy sa zanedbáva časť sily, ktorá predstavuje obsah pod dolnou kritickou hodnotou.

Príklad 197 (minimálny rozsah súboru) Vypočítajte v \mathbb{R} minimálny rozsah náhodného výberu pre test $H_{03} : \sigma^2 \geq \sigma_0^2$ oproti $H_{13} : \sigma^2 < \sigma_0^2$ pri $\alpha = 0.05$ a $1 - \beta = 0.8$, ak podiel $\frac{\sigma_0^2}{\sigma^2}$ je rovný (a) 1.1, (b) 1.5 a (c) 5.

Test pomerom vierohodnosti pre σ^2 .

Majme H_{01} oproti H_{11} . Nech $X \sim N(\mu, \sigma^2)$, kde $\boldsymbol{\theta} = (\mu, \sigma^2)^T$. Funkcia vierohodnosti je rovná

$$L(\boldsymbol{\theta}|\mathbf{x}) = (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$

MLE $\boldsymbol{\theta}$ je rovný

$$\hat{\boldsymbol{\theta}} = (\bar{x}, \hat{\sigma}^2)^T = \left(\frac{1}{n} \sum_{i=1}^n x_i, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right),$$

t.j. $\Theta_1 = \{\boldsymbol{\theta} : \sigma^2 \neq \sigma_0^2\}$. Za platnosti H_{01} je $\boldsymbol{\theta}_0 = (\bar{x}, \sigma_0^2)^T$, t.j. $\Theta_0 = \{\boldsymbol{\theta} : \sigma^2 = \sigma_0^2\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x})) &= l(\hat{\boldsymbol{\theta}}|\mathbf{x}) - l(\boldsymbol{\theta}_0|\mathbf{x}) \\ &= \left(-\frac{n}{2}(\ln(2\pi) + \ln \hat{\sigma}^2 + \frac{\hat{\sigma}^2}{\hat{\sigma}^2})\right) - \left(-\frac{n}{2}(\ln(2\pi) + \ln \sigma_0^2 + \frac{\hat{\sigma}^2}{\sigma_0^2})\right) \\ &= \frac{n}{2} \left(\frac{\hat{\sigma}^2}{\sigma_0^2} - 1 - \ln\left(\frac{\hat{\sigma}^2}{\sigma_0^2}\right)\right). \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X})) \stackrel{\mathcal{D}}{\sim} \chi_1^2$, kde H_0 bude zamietnutá pre malé alebo veľké hodnoty podielu $\frac{\hat{\sigma}^2}{\sigma_0^2}$.

Dá sa ukázať, že podiel $\frac{\hat{\sigma}^2}{\sigma_0^2}$ je rastúcou funkciou $F_{\text{obs}} = \frac{n\hat{\sigma}^2}{\sigma_0^2}$ a potom

$$u_{LR} = -2 \ln(\lambda(\mathbf{x})) \approx F_{\text{obs}} - n \left(1 + \ln\left(\frac{F_{\text{obs}}}{n}\right)\right).$$

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre σ^2 bude mať tvar

$$CS_{1-\alpha} = \{\sigma_0^2 : U_{LR} < \chi_1^2(\alpha)\}.$$

Majme H_{02} oproti H_{12} . Potom $u_{LR} = 0$ ak $\frac{\hat{\sigma}_0^2}{\sigma_0^2} \leq 1$ a $u_{LR} \approx F_{\text{obs}} - n(1 + \ln(\frac{F_{\text{obs}}}{n}))$ pre $\frac{\hat{\sigma}_0^2}{\sigma_0^2} > 1$.

Majme H_{03} oproti H_{13} . Potom $u_{LR} = 0$ ak $\frac{\hat{\sigma}_0^2}{\sigma_0^2} \geq 1$ a $u_{LR} \approx F_{\text{obs}} - n(1 + \ln(\frac{F_{\text{obs}}}{n}))$ pre $\frac{\hat{\sigma}_0^2}{\sigma_0^2} < 1$.

Príklad 198 (test rozptylu σ^2) Majme dáta *one-sample-variance-skull-mf.txt* a premennú dĺžku lebky *skull.L* v mm starovekej egyptskej mužskej populácie, o ktorej predpokladáme, že má normálne rozdelenie $N(\mu, \sigma^2)$. (a) Otestujte hypotézu o zhode rozptylu dĺžky lebky tejto populácie s rozptylom dĺžky lebky novovekej egyptskej mužskej populácie 7.526^2 na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre rozptyl dĺžky lebky, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku F_W , (2) testovaciu štatistiku pomeru vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2).

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : rozptyl dĺžky lebky starovekej egyptskej mužskej populácie je zhodný s rozptylom dĺžky lebky novovekej egyptskej mužskej populácie oproti H_1 : rozptyl dĺžky lebky starovekej egyptskej mužskej populácie nie je zhodný s rozptylom dĺžky lebky novovekej egyptskej mužskej populácie.
- **matematická formulácia** – $H_0 : \sigma^2 = \sigma_0^2$ oproti $H_1 : \sigma^2 \neq \sigma_0^2$, kde $\sigma_0 = 7.526^2$.

2. **Testovacia štatistika** – Rozptyl σ^2 nepoznáme, a preto ho musíme odhadnúť. Jeho odhadom je $s^2 = 40.582$ (smerodajná odchýlka $s = 6.370$).

```
901 | DATA <- read.table("one-sample-variance-skull-mf.txt", header=TRUE)
902 | attach(DATA)
903 | x <- na.omit(skull.L[sex=="m"])
904 | n <- length(x) # 217
905 | rozptyl <- var(x) # 40.58197
906 | smerodch <- sd(x) # 6.370398
```

Pozorované testovacie štatistiky:

$$\text{Waldova testovacia štatistika } F_{\text{obs}} = \frac{(n-1)s^2}{\sigma_0^2} \doteq \frac{217 \times 6.370^2}{7.526^2} \doteq 154.76.$$

Testovacia štatistika pomerom vierohodnosti $u_{LR} = F_{\text{obs}} - n(1 + \ln(\frac{F_{\text{obs}}}{n}))$, kde $F_{\text{obs}} = \frac{n s^2}{\sigma_0^2}$, t.j.

keďže $F_{\text{obs}} \doteq \frac{217 \times 6.370^2}{7.526^2} \doteq 155.476$, potom $u_{LR} \doteq 155.476 - 217(1 + \ln(\frac{155.476}{n})) \doteq 10.825$.

```
907 | sigma0.sq <- 7.526^2 # 56.64068
908 | F.obs <- (n-1)*rozptyl/sigma0.sq # 154.7599
909 | Fstar.obs <- n*rozptyl/sigma0.sq # 155.4764
910 | uLR.obs <- Fstar.obs - n*(1+log(Fstar.obs/n)) # 10.82495
```

3. Zamietacia oblasť –

Waldov test:

kritické hodnoty $\chi^2(1 - \alpha) \doteq 177.189$ a $\chi^2(\alpha) \doteq 258.597$;

kritický obor $\mathcal{W}_1 = (-\infty, -1.971) \cup (1.971, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (3.841, \infty)$.

```
911 | chisq.krit.d <- qchisq(0.025, df=n-1) # 177.189
912 | chisq.krit.h <- qchisq(0.975, df=n-1) # 258.5971
913 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. Empirický dvostranný interval spoľahlivosti –

Waldov $100 \times (1 - \alpha)\%$ empirický DIS = 95% empirický DIS pre σ^2 :

$$(d, h) = \left(\frac{(n-1)s^2}{\chi_{n-1}^2(\alpha/2)}, \frac{(n-1)s^2}{\chi_{n-1}^2(1-\alpha/2)} \right) \doteq (33.897, 49.471).$$

Vierohodnostný 95% empirický DIS pre σ^2 :

$$\mathcal{CS}_{0.95} = \{ \sigma_0^2 : u_{LR}(\sigma_0^2) < \chi_1^2(\alpha) \} \doteq (33.815, 49.280).$$


```

914 | DH.W <- (n-1)*rozptyl/chisq.krit.h # 33.89715
915 | HH.W <- (n-1)*rozptyl/chisq.krit.d # 49.47094
916 | min.sigma.sq <- 0.01
917 | max.sigma.sq <- 2
918 | podiel.i <- seq(min.sigma.sq,max.sigma.sq,by=0.0001)
919 | sigma0.sq.i <- rozptyl/podiel.i
920 | Fstar.obs.i <- n*podiel.i
921 | uLR.i <- Fstar.obs.i-n*(1+log(Fstar.obs.i/n))
922 | IS.LR <- range(sigma0.sq.i[which(uLR.i<lr.krit.hodn)]) # 33.81549 49.27986

```

5. Štatistický záver –

Waldov test: $p\text{-hodnota} \doteq 2\Pr(F \geq F_{\text{obs}}|H_0) = 2\Pr(F \geq 154.760|H_0) \doteq 0.001$.

Test pomerom vierohodnosti: $p\text{-hodnota} \doteq \Pr(U_{LR} \geq 10.825|H_0) \doteq 0.001$.

```

923 | p.hodn.W <- 2*(pchisq(F.obs, df=n-1)) # 0.00115558
924 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 0.001001415

```

H_0 na hladine významnosti zamietame, pretože (1) testovacia štatistika patrí kritickému oboru, (2) $\sigma_0^2 = 56.641$ nepatrí DIS a nakoniec (3) p -hodnota je menšia ako 0.05.

6. Slovný záver –

Zamietame nulovú hypotézu o tom, že rozptyl dĺžky lebky starovekej egyptskej mužskej populácie je zhodný s rozptylom dĺžky lebky novovekej egyptskej mužskej populácie.

7. Antropologický záver –

Hodnota rozptylu dĺžky lebky novovekej egyptskej populácie je štatisticky významne vyššia než v starovej egyptskej populácii. Rozdiely v rozptyloch môžu byť dôsledkom skutočných biologických rozdielov vo variabilite v dĺžke lebky v dôsledku odlišného zloženia populácie v priebehu času – ak staroveká populácia bola celkovo menšia a v menších skupinách sú si jedinci podobnejší, tak variabilita je nižšia. Nulová hypotéza však môže byť zamietnutá aj z dôvodu odlišného vzorkovania a v prípade kostrových sérií aj z dôvodu obmedzenej reprezentatívneho a celistvosti dát a ďalších okolností, ktoré sa spájajú s výskumom minulých populácií z kostrových pozostatkov.

Príklad 199 (test rozptylu σ^2) *Majme dáta one-sample-variance-skull-mf.txt a premennú šírku lebky skull.B v mm starovekej egyptskej mužskej populácie, o ktorej predpokladáme, že má normálne rozdelenie $N(\mu, \sigma^2)$. (a) Otestujte hypotézu o zhode rozptylu šírky lebky tejto populácie s rozptylom šírky lebky novovekej egyptskej mužskej populácie 6.411² na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre rozptyl šírky lebky, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku F_W , (2) testovaciu štatistiku pomeru vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2).*

6.3 Asymptotické testy o korelačnom koeficiente

Korelačná analýza slúži na hodnotenie sily závislosti medzi dvoma spojitými premennými. Korelačný koeficient vyjadruje mieru asociácie. Vyjadruje však iba mieru lineárneho vzťahu, a pokiaľ je závislosť medzi premennými nelineárna, nemusí vzťah popisovať správne alebo ho neodhalí vôbec. V biologickej antropológii existuje celý rad situácií, v ktorých je potrebné zistiť existenciu, mieru (veľkosť) a smer (kladná, záporná) lineárnej závislosti medzi dvoma premennými. Klasickou situáciou je sledovanie vzťahu celku a jeho častí (napr. zistenie vzťahu výšky postavy a dĺžky končatiny), hľadanie väzby medzi faktorom považovaným za efektor metabolického alebo ontogenetického procesu a jeho produktom/dopadom (hladina prenatálneho testosterónu a miera agresivity v dospelosti) alebo hľadanie súvislosti medzi nejakým faktorom prostredia a veľkosťou, tvarom a zložením ľudského tela (napr. medzi energetickým obsahom stravy a indexom telesnej hmotnosti (BMI)). Korelácia hodnoteného znaku medzi dvojčatami je tiež základom výpočtu heritability (dedivosti). Korelačné koeficienty týchto súvislostí sú často publikovanými ukazovateľmi a možno ich využiť na štatistické porovnanie publikovaných výsledkov s koreláciami nášho výskumu. Pri použití korelačného koeficientu je potrebné pamätať na to, že vyjadruje mieru štatistickej závislosti a nie mieru biologickej príčinnej (kauzálnej) závislosti. Bez ďalších údajov nie je možné z korelačného koeficientu vypočítaného z dát získaných pozorovaním (neexperimentálne) zistiť mechanizmus, či spolu korelované znaky priamo súvisia, alebo ich korelácia vzniká pod vplyvom neznámej vlastnosti tretej (mäťúcej premennej), ktorou často býva nejaká generalizovaná, všetko ovplyvňujúca vlastnosť, napr. veľkosť tela. Pokiaľ spolu vlastnosti priamo

súvisia, nie je možné len na základe korelačného koeficientu zistiť, v akom zmysle, t.j. ktorý znak je príčina a ktorý dôsledok. Tiež treba mať na pamäti, že celý rad prírodných biologických väzieb a procesov v ľudskom tele prebieha nelineárne. Napríklad procesy vývoja a rastu ľudského tela sú zložitým reťazcom mnohých odlišne prebiehajúcich fáz a sledovanie súvislostí dvoch znakov v priebehu rastu pomocou lineárneho koeficientu korelácie môže poskytnúť falošnú predstavu o miere závislosti.

Korelačný koeficient $\rho \in \langle -1, 1 \rangle$ meria silu nekauzálneho lineárneho vzťahu (asociácie, závislosti) dvoch spojitých premenných X a Y pochádzajúcich z dvojrozmerného normálneho rozdelenia, t.j. $(X, Y)^T \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde tieto predstavujú (1) dve rôzne premenné, (2) párovú premennú alebo (3) jednu premennú z dvoch rôznych časových bodov. Pri interpretácii tohoto vzťahu je dôležité zamerať sa nielen na veľkosť ale aj znamienko ρ , kde

- 0 predstavuje nulovú (žiadnu) asociáciu medzi dvoma premennými,
- ± 1 predstavuje perfektnú asociáciu medzi dvoma premennými,
- kladné číslo predstavuje pozitívnu asociáciu (keď rastú hodnoty jednej premennej, rastú aj hodnoty druhej premennej),
- záporné číslo predstavuje negatívnu asociáciu (keď rastú hodnoty jednej premennej, hodnoty druhej premennej klesajú).

V prírodných vedách sa zaužívala nasledovná interpretácia $|\rho|$:

- $|\rho| \in \langle 0, 0.4 \rangle$ – žiadna alebo takmer žiadna asociácia,
- $|\rho| \in \langle 0.4, 0.6 \rangle$ – slabá asociácia,
- $|\rho| \in \langle 0.6, 0.8 \rangle$ – mierna asociácia,
- $|\rho| \in \langle 0.8, 1 \rangle$ – silná asociácia.

V sociálnych vedách sa zaužívala nasledovná interpretácia $|\rho|$:

- $|\rho| \in \langle 0, 0.15 \rangle$ – žiadna alebo takmer žiadna asociácia,
- $|\rho| \in \langle 0.15, 0.3 \rangle$ – slabá asociácia,
- $|\rho| \in \langle 0.3, 0.5 \rangle$ – mierna asociácia,
- $|\rho| \in \langle 0.5, 0.6 \rangle$ – dosť (celkom) silná asociácia,
- $|\rho| \in \langle 0.6, 0.8 \rangle$ – silná asociácia,
- $|\rho| \in \langle 0.8, 1 \rangle$ – veľmi silná asociácia.

Označme odhad ρ ako $\hat{\rho} = r$. Potom rozlišujeme tri typy korelačných koeficientov $r = r(x, y)$ podľa typu premenných (Mardia, 1976; Mardia a Jupp, 2000; Jammalamadaka a Lund, 2006)

1. **klasický/lineárny Pearsonov korelačný koeficient (lineárna–lineárna premenná)**, kde

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)s_x s_y} = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right),$$

$$\text{kde } s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \text{ a } s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2.$$

2. **lineárno-uhlový Pearsonov korelačný koeficient (lineárna–uhlová premenná)**, kde

$$r = \sqrt{\frac{r_{xc}^2 + r_{xs}^2 - 2r_{xc}r_{xs}r_{cs}}{1 - r_{cs}^2}},$$

x je lineárna a y uhlová premenná meraná v radiánoch ($1 \text{ rad} \doteq \frac{180}{\pi} = 57.3$ stupňa; uhol v radiánoch = uhol v stupňoch $\times \pi/180$), $r_{xc} = r(x, \cos y)$, $r_{xs} = r(x, \sin y)$ a $r_{sc} = r(\cos y, \sin y)$;

3. uhlový Pearsonov korelačný koeficient (uhlová–uhlová premenná), kde

$$r = \frac{\sum_{i=1}^n \sin(x_i - \bar{x}) \sin(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n \sin^2(x_i - \bar{x}) \sin^2(y_i - \bar{y})}},$$

x a y sú uhlové premenné merané v radiánoch¹, kvadrant špecifický priemerný uhol

$$\bar{x} = \begin{cases} \arctan\left(\frac{\sum_{i=1}^n \sin x_i}{\sum_{i=1}^n \cos x_i}\right), & \text{ak } \sum_{i=1}^n \cos x_i \geq 0, \\ \arctan\left(\frac{\sum_{i=1}^n \sin x_i}{\sum_{i=1}^n \cos x_i}\right) + \pi, & \text{ak } \sum_{i=1}^n \cos x_i < 0, \\ \text{nedefinované,} & \text{ak } \sqrt{(\sum_{i=1}^n \sin x_i)^2 + (\sum_{i=1}^n \cos x_i)^2} = 0. \end{cases}$$

Podobne definujeme aj \bar{y} .

Korelačný koeficient má asymptoticky normálne rozdelenie, t.j. $R \sim N\left(\rho, (1 - \rho^2)^2 / (n - 1)\right)$. Konvergencia k normalite je však pomalá, preto sa používa **Fisherova Z-premenná** (rýchlejšie konvergujúca k normalite)

$$Z_R = \frac{1}{2} \ln \frac{1 + R}{1 - R}, Z_R \stackrel{\mathcal{D}}{\sim} N\left(\frac{1}{2} \ln \frac{1 + \rho}{1 - \rho}, \frac{1}{n - 3}\right),$$

kde $n > 3$. Odporúča sa uvažovať o Z_R ako o normálnej premennej už pre $n \geq 10$, ak ρ nie je blízko ± 1 .

Majme dvojice hypotéz $H_{01} : \rho = \rho_0$ oproti $H_{11} : \rho \neq \rho_0$, $H_{02} : \rho \leq \rho_0$ oproti $H_{12} : \rho > \rho_0$, $H_{03} : \rho \geq \rho_0$ oproti $H_{13} : \rho < \rho_0$, ktoré chceme testovať.

Ak H_0 platí, potom

$$Z_W = \sqrt{n - 3} (Z_R - \xi_0) \stackrel{\mathcal{D}}{\sim} N(0, 1),$$

kde $\xi_0 = \frac{1}{2} \ln \frac{1 + \rho_0}{1 - \rho_0}$. Z_W sa nazýva **Waldova testovacia štatistika** a test **jednovýberový Z-test o korelačnom koeficiente** ρ .

Definícia 58 (Kritický obor a silofunkcia Z_W testu o ρ) Kritický obor a silofunkcia (za platnosti $\xi = \frac{1}{2} \ln \frac{1 + \rho}{1 - \rho}$) sú definované nasledovne (pozri obrázok 6.7):

H_0	H_1	\mathcal{W}	$1 - \beta(\xi)$
$\rho = \rho_0$	$\rho \neq \rho_0$	$\mathcal{W}_1 = \{Z_W; Z_W \geq u_{\alpha/2}\}$	$1 - \Phi\left(u_{\alpha/2} - \sqrt{n - 3} \xi_0 - \xi \right)$
$\rho \leq \rho_0$	$\rho > \rho_0$	$\mathcal{W}_2 = \{Z_W; Z_W \geq u_{\alpha}\}$	$1 - \Phi\left(u_{\alpha} + \sqrt{n - 3} (\xi_0 - \xi)\right)$
$\rho \geq \rho_0$	$\rho < \rho_0$	$\mathcal{W}_3 = \{Z_W; Z_W \leq -u_{\alpha}\}$	$1 - \Phi\left(u_{\alpha} - \sqrt{n - 3} (\xi_0 - \xi)\right)$

Definícia 59 (p-hodnota Z_W testu o ρ) Nech Z_W je **nejaká testovacia štatistika** a z_W je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : \rho \neq \rho_0 \\ \Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : \rho > \rho_0 \\ \Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : \rho < \rho_0 \end{cases}$$


Definícia 60 (Waldov $100 \times (1 - \alpha)\%$ empirický DIS pre ξ a IS pre ρ) Keďže

$\Pr(\sqrt{n - 3} |Z_R - \xi| \leq u(\alpha/2)) = 1 - \alpha$, potom Waldov $100 \times (1 - \alpha)\%$ empirický DIS pre ξ má tvar

$$CS_{1-\alpha} = \left\{ \xi_0; \xi_0 \in \left(z_R - \frac{u_{\alpha/2}}{\sqrt{n - 3}}, z_R + \frac{u_{\alpha/2}}{\sqrt{n - 3}} \right) \right\}.$$

Vieme, že $\rho = \tanh(\xi)$ je monotónna funkcia ξ . Potom môžeme písať spätne transformované Waldove $100 \times (1 - \alpha)\%$ empirické IS pre ρ ako:

¹Rozptyl uhlovej premennej definujeme ako $1 - \frac{1}{n} \sqrt{(\sum_{i=1}^n \sin x_i)^2 + (\sum_{i=1}^n \cos x_i)^2} \in (0, 1)$.



Obr. 6.7: Silofunkcie asymptotického testu o ρ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\rho = \rho_0$	$\rho \neq \rho_0$	$\mathcal{CS}_{1-\alpha} = \left\{ \rho_0 : \rho_0 \in \left(\tanh \left[z_R - \frac{u_{\alpha/2}}{\sqrt{n-3}} \right], \tanh \left[z_R + \frac{u_{\alpha/2}}{\sqrt{n-3}} \right] \right) \right\}$
$\rho \leq \rho_0$	$\rho > \rho_0$	$\mathcal{CS}_{1-\alpha} = \left\{ \rho_0 : \rho_0 \in \left(\tanh \left[z_R - \frac{u_{\alpha}}{\sqrt{n-3}} \right], 1 \right) \right\}$
$\rho \geq \rho_0$	$\rho < \rho_0$	$\mathcal{CS}_{1-\alpha} = \left\{ \rho_0 : \rho_0 \in \left(-1, \tanh \left[z_R + \frac{u_{\alpha/2}}{\sqrt{n-3}} \right] \right) \right\}$

Príklad 200 (DIS pre ρ použitím Fisherovej Z -premennej) Naprogramujte DIS pre ρ .

Riešenie v R

```

925 "ISkor" <- function(x,y, conf.level=0.95){
926   z <- atanh(cor(x,y))
927   n <- length(x)
928   a <- qnorm(1-(1-conf.level)/2)/(n-3)^0.5
929   IS.xi <- c(z-a, z+a)
930   IS <- tanh(IS.xi)
931   return(IS)
932 }

```

Majme H_{11} . Použitím Fisherovej Z -premennej pre nejaký rozdiel $\xi - \xi_0$, α a β bude **minimálny rozsah** n definovaný ako

$$n \geq 3 + \left(\frac{u_{\alpha/2} + u_{\beta}}{\xi - \xi_0} \right)^2.$$

Pre H_{12} a H_{13} zameníme $u_{\alpha/2}$ za u_{α} .

Príklad 201 (minimálny rozsah n) Vypočítajte minimálny rozsah n pre $\rho = 0.1, 0.2, \dots, 0.9$, $\rho_0 = 0$ pri $\alpha = 0.05$, $1 - \beta = 0.8$ a obojstrannej alternatíve H_{11} .

Riešenie (pozri tabuľku 6.1)

Tabuľka 6.1: Minimálne rozsahy n pri vybraných rozdieloch ρ a ρ_0 , kde $\rho_0 = 0$

ρ	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
n	783	194	85	47	30	20	14	10	7

Príklad 202 (minimálny rozsah n) Vypočítajte minimálny rozsah n pre $\rho = 0.1, 0.2, \dots, 0.9$, ρ_0 vždy o 0.1 menšie ako ρ , pri $\alpha = 0.05$, $\beta = 0.8$ a obojstrannej alternatíve H_{11} .

Tabuľka 6.2: Minimálne rozsahy n pri vybraných rozdieloch ρ a ρ_0 spolu s rozdielom $z_R - \xi_0$, ktorý je funkciou ρ a ρ_0

ρ	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
ρ_0	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8
$z_R - \xi_0$	0.1003	0.1024	0.1068	0.1141	0.1257	0.1438	0.1742	0.2313	0.3736
n	783	752	692	606	501	383	262	150	60

Riešenie (pozri tabuľku 6.2)

Jednovýberový t -test o korelačnom koeficiente ρ v \mathbb{R} (funkcia **cor.test()**).

Argumenty (vstupy) funkcie:

1. dáta x a y ;
2. spoľahlivosť $\text{conf.level}=p$, prednastavené je $\text{conf.level}=.95$;
3. metóda $\text{method}="pearson"$ (prednastavené);
4. formulácia alternatívy $\text{alternative}="two.sided"$ je prednastavené, ďalšie voľby sú "greater", "less".

Výstupy funkcie:

1. názov použitého testu method ;
2. testovacia štatistika statistic ;
3. stupne voľnosti df parameter;
4. p -hodnota $p.value$;
5. alternatívna hypotéza $\text{alternative hypothesis}$;
6. interval spoľahlivosti conf.int (vypočítaný na základe Fisherovej Z -premennej);
7. bodový odhad (korelačný koeficient) estimate .

Test pomerom vierohodnosti pre ρ .

Majme H_{01} oproti H_{11} . Nech $(X, Y)^T \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$. Logaritmus funkcie vierohodnosti bude mať tvar

$$l(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}) = -n \ln \left(2\pi\sigma_1\sigma_2\sqrt{1-\rho^2} \right) - \frac{1}{2(1-\rho^2)} \left(\frac{\sum_{i=1}^n (x_i - \mu_1)^2}{\sigma_1^2} - 2\rho \frac{\sum_{i=1}^n (x_i - \mu_1)(y_i - \mu_2)}{\sigma_1\sigma_2} + \frac{\sum_{i=1}^n (y_i - \mu_2)^2}{\sigma_2^2} \right).$$

MLE $\hat{\boldsymbol{\theta}} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \hat{\rho})^T$, kde

$$\hat{\mu}_1 = \bar{x}, \hat{\mu}_2 = \bar{y}, \hat{\sigma}_1^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2, \hat{\sigma}_2^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2, \hat{\rho} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n\hat{\sigma}_1\hat{\sigma}_2}.$$

t.j. $\Theta_1 = \{\boldsymbol{\theta} : \rho \neq 0\}$. Za platnosti H_{01} je $\boldsymbol{\theta}_0 = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, 0)^T$, t.j. $\Theta_0 = \{\boldsymbol{\theta} : \rho = 0\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x}, \mathbf{y})) &= l(\hat{\boldsymbol{\theta}}|\mathbf{x}, \mathbf{y}) - l(\boldsymbol{\theta}_0|\mathbf{x}, \mathbf{y}) \\ &= \left(-n \ln(2\pi\hat{\sigma}_1\hat{\sigma}_2) - \frac{n}{2} \ln(1-\hat{\rho}^2) - n \right) - \left(-n \ln(2\pi\hat{\sigma}_1\hat{\sigma}_2) - n \right) \\ &= -\frac{n}{2} \ln(1-\hat{\rho}^2). \end{aligned}$$

Z vyššie uvedeného je vidieť, že $-\ln(\lambda(\mathbf{x}, \mathbf{y}))$ rastúcou funkciou $\hat{\rho}^2$. Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X}, \mathbf{Y})) \stackrel{\mathcal{D}}{\sim} \chi_1^2$, kde H_0 bude zamietnutá pre veľké hodnoty $|\hat{\rho}|$.

Keďže platí

$$T_W = \frac{\sqrt{n-2}R}{\sqrt{1-R^2}} \stackrel{\mathcal{D}}{\sim} t_{n-2},$$

môžeme zapísať u_{LR} pomocou t_W . $|t_W|$ je rastúcou funkciou $|\hat{\rho}|$, preto

$$u_{LR} = -2 \ln(\lambda(\mathbf{x}, \mathbf{y})) = -n \ln(1 - \hat{\rho}^2) = -n \ln\left(1 - \frac{t_W^2}{t_W^2 + (n-2)}\right).$$

T_W sa nazýva **Waldova testovacia štatistika** a test **jednovýberový t -test o korelačnom koeficiente** ρ . Ak H_0 neplatí, rozdelenie T_W ako aj $\hat{\rho}$, neexistuje v jednoduchšej forme, a preto sa používa normálna aproximácia pomocou Fisherovej Z -premennej spomenutá vyššie. Tiež je dôležité upozorniť na fakt, že ak sa ρ výrazne líši od 0, konverguje jeho rozdelenie k normálnemu rozdeleniu veľmi pomaly. Ďalšou nevýhodou je, že rozptyl ρ závisí na hodnote ρ (rozptyl ρ je funkciou ρ).

Ak $\rho_0 \neq 0$, T_W nie je možné použiť. Rovnako nie je možné použiť U_{LR} na vytvorenie vierohodnostného IS. Preto musíme vypočítať U_{LR} pre nejaké ρ_0 . Nech $\boldsymbol{\theta}_0 = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \rho_0)^T$, kde $\tilde{\sigma}_j^2 = \frac{\hat{\sigma}_j^2(1-\rho_0\hat{\rho})}{1-\rho_0^2}$, $j = 1, 2$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x}, \mathbf{y})) &= l(\hat{\boldsymbol{\theta}}|\mathbf{x}, \mathbf{y}) - l(\boldsymbol{\theta}_0|\mathbf{x}, \mathbf{y}) = -\frac{n}{2} \ln(1 - \hat{\rho}^2) - \frac{n}{2} \ln(\hat{\sigma}_1^2 \hat{\sigma}_2^2) + \frac{n}{2} \ln(1 - \rho_0^2) + \frac{n}{2} \ln(\tilde{\sigma}_1^2 \tilde{\sigma}_2^2) \\ &= -\frac{n}{2} \left(\ln(1 - \hat{\rho}^2) + \ln(\hat{\sigma}_1^2 \hat{\sigma}_2^2) - \ln\left(\hat{\sigma}_1^2 \hat{\sigma}_2^2 \left(\frac{1 - \rho_0 \hat{\rho}}{1 - \rho_0^2}\right)^2\right) - \ln(1 - \hat{\rho}_0^2) \right) \end{aligned}$$

a

$$u_{LR} = -2 \ln(\lambda(\mathbf{x}, \mathbf{y})) = n \left(\ln \frac{(1 - \rho_0 \hat{\rho})^2}{(1 - \rho_0^2)(1 - \hat{\rho}^2)} \right).$$

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre ρ bude mať tvar

$$CS_{1-\alpha} = \{\rho_0 : U_{LR} < \chi_1^2(\alpha)\}.$$

Príklad 203 (konvergencia ρ a ξ k normálnemu rozdeleniu) Urobte v \mathbb{R} simuláciu pseudonáhodných čísel z $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1$ (pozri príklad 87), kde $n = 5, 10, 20, 50$ a 100 , $M = 10000$. Použite (a) $\rho = 0$, (b) $\rho = 0.50$ a (c) $\rho = 0.9$. Pre každé $m = 1, 2, \dots, M$, vypočítajte Pearsonov korelačný koeficient r_m a Fisherovu Z -premennú $z_{R,m}$. Zobrazte histogramy simulovaných r_m a $z_{R,m}$ a superponujte ich teoretickými hustotami prislúchajúcich normálnych rozdelení.

Príklad 204 (test o korelačnom koeficiente ρ) Majme dáta *one-sample-correlation-skull-mf.txt* a premenné najväčšia výška mozgovne skull.pH a morfologická výška tváre face.H (obe v mm) starovekej egyptskej mužskej populácie, o ktorých predpokladáme, že majú dvojrozmerné normálne rozdelenie $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. (a) Otestujte hypotézu o tom, že korelačný koeficient najväčšej výšky mozgovne a morfologickej výšky tváre je rovný 0.251. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre korelačný koeficient, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku Z_W , (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2). Výsledky Waldovho testu skontrolujte pomocou funkcie *cor.test()*. Porovnajme empirický DIS vypočítaný funkciou *cor.test()* s výsledkom vypočítaným funkciou *IScor()*.

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : korelačný koeficient najväčšej výšky mozgovne a morfolologickej výšky tváre v starovekej egyptskej mužskej populácii je rovný korelačnému koeficientu 0.251 týchto dvoch premenných v novovekej egyptskej mužskej populácii oproti H_1 : korelačný koeficient najväčšej výšky mozgovne a morfolologickej výšky tváre v starovekej egyptskej mužskej populácii nie je rovný korelačnému koeficientu 0.251 týchto dvoch premenných v novovekej egyptskej mužskej populácii.
- **matematická formulácia** – $H_0 : \rho = \rho_0$ oproti $H_1 : \rho \neq \rho_0$, kde $\rho_0 = 0.251$.

2. **Testovacia štatistika** – Korelačný koeficient ρ je neznámy, preto ho musíme odhadnúť. Jeho odhadom je $\hat{\rho} = 0.331$.

```

933 | DATA <- read.table("one-sample-correlation-skull.txt", header=TRUE)
934 | DATA <- na.omit(DATA)
935 | attach(DATA)
936 | n <- dim(DATA)[1] # 164
937 | rho.hat <- cor(skull.pH, face.H) # 0.3306431

```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $z_W = \sqrt{n-3}(z_R - \xi_0) \doteq 1.105$.

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 4.459$ (ak $H_0 : \rho = 0$).

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 1.242$ (ak $H_0 : \rho = \rho_0$).

```

938 | zR <- 1/2*log((1+rho.hat)/(1-rho.hat)) # 0.3435501
939 | rho0 <- 0.251
940 | xi0 <- 1/2*log((1+rho0)/(1-rho0)) # 0.2564798
941 | zW.obs <- sqrt(n-3)*(zR-xi0) # 1.104799
942 | w.obs <- sqrt(n-2)*rho.hat/(sqrt(1-rho.hat^2)) # 4.459204
943 | uLR.obs <- -n*log(1-tW.obs^2/(tW.obs^2+(n-2))) # 18.98718
944 | # tW.obs a ani uLR.obs nie je mozne pouzít, lebo rho0 sa nerovna 0
945 | uLR.obs <- -n*(log((1-rho0^2)*(1-rho.hat^2)/(1-rho0*rho.hat^2))) # 1.241757

```

3. Zamietacia oblasť –

Waldov test:

kritické hodnoty $u(1-\alpha/2) \doteq -1.960$ a $u(\alpha/2) \doteq 1.960$;

kritický obor $\mathcal{W}_1 = (z_{\min}, u(1-\alpha/2)) \cup (u(\alpha/2), z_{\max}) \doteq (-\infty, -1.960) \cup (1.960, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty)$.

```

946 | z.krit.d <- qnorm(0.025) # -1.959964
947 | z.krit.h <- qnorm(0.975) # 1.959964
948 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459

```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov 100(1- α)% empirický DIS = 95% empirický DIS pre ρ :

$(d, h) \doteq (0.187, 0.461)$.

Vierohodnostný 95% empirický DIS pre ρ :

$\mathcal{CS}_{0.95} = \{\rho_0 : u_{LR}(\rho_0) < \chi_1^2(\alpha)\} \doteq (0.188, 0.460)$.

```

949 | ISz <- IScor(skull.pH, face.H) # 0.1868617 0.4605561
950 | rho.oi <- seq(-0.999, 0.999, by=0.0001)
951 | uLR.i <- -n*(log((1-rho0i^2)*(1-rho.hat^2)/(1-rho0i*rho.hat^2)))
952 | IS.LR <- range(rho.oi[which(uLR.i < lr.krit.hodn)]) # 0.1880 0.4596

```

5. Štatistický záver –

Waldov test: p-hodnota $\doteq 2\Pr(Z_W \geq |10.334| | H_0) \doteq 0.269$.

Test pomerom vierohodnosti: p-hodnota = $\Pr(U_{LR} \geq 1.242 | H_0) \doteq 0.265$.

```

953 | p.hodn.zW <- 2*(1-pnorm(abs(zW.obs))) # 0.2692467
954 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 0.2651328

```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\rho_0 = 0.251$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. **Slovný záver** – Nezamietame nulovú hypotézu o tom, že korelačný koeficient najväčšej výšky mozgovne a morfologickej výšky tváre v starovekej egyptskej mužskej populácii je rovný korelačnému koeficientu 0.251 týchto dvoch premenných v novovekej egyptskej mužskej populácii.
7. **Antropologický záver** – Vo vzťahu týchto dvoch premenných sa staroveká a novoveká egyptská populácia nelíšia. Ani v jednej z nich sledované rozmery mozgovej a tvárovej časti lebky spolu nesúvisia, čo naznačuje, že ide o samostatné vývinové moduly riadené počas ontogenézy inými faktormi.

Riešenie pomocou funkcie `cor.test()` – touto funkciou nie je možné testovať inú H_0 ako $\rho = 0$ (pri všetkých troch alternatívach). Môžeme ale pomocou nej vypočítať empirický DIS pre ρ , ktorý je identický s nami vypočítaným DIS (Waldov princíp).

```
955 | Ttest <- cor.test(skull.pH, face.H)
956 | Ttest$conf.int # 0.1868617 0.4605561
```

Príklad 205 (test o lineárno-uhlovom ρ) Naprogramujte v \mathbb{R} funkcie na výpočet (a) odhadu lineárno-uhloveho korelačného koeficientu a (b) $100 \times (1 - \alpha)\%$ intervalu spoľahlivosti lineárno-uhloveho ρ .

Riešenie v \mathbb{R}

```
957 | "lin.uhl.r" <- function(x,y){
958 | # x ... linearna premenna
959 | # y ... uhlova premenna v stupnoch
960 | y.rad <- (y*pi)/180
961 | y.cos <- cos(y.rad)
962 | y.sin <- sin(y.rad)
963 | r.xc <- cor(x,y.cos)
964 | r.xs <- cor(x,y.sin)
965 | r.cs <- cor(y.cos,y.sin)
966 | citatel <- r.xc^2+r.xs^2-2*r.xc*r.xs*r.cs
967 | menovatel <- 1-r.cs^2
968 | r.xy <- sqrt(citatel/menovatel)
969 | return(r.xy)
970 | }
971 | "ISkor.uhl" <- function(r.xy,n, conf.level = 0.95){
972 | z <- atanh(r.xy)
973 | a <- qnorm(1 - (1 - conf.level)/2)/(n - 3)^0.5
974 | IS.xi <- c(z - a, z + a)
975 | IS <- tanh(IS.xi)
976 | return(IS)
977 | }
```

Príklad 206 (test o lineárno-uhlovom ρ) Majme dáta `lin-uhl-fm.txt` a premenné *basion-bregmatická výška lebky skull.H* (v mm) a *uhol*, ktorý zvierajú línie prechádzajúce bodom *basion* a pravostranným a ľavostranným bodom *porion base.A* (v stupňoch) u mužov. (a) Otestujte hypotézu o tom, že korelačný koeficient *basion-bregmatickej výšky lebky a vyššie spomenutého uhla* je rovný nule. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre korelačný koeficient, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku Z_W , (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2).

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : korelačný koeficient *basion-bregmatickej výšky lebky a uhla*, ktorý zvierajú línie prechádzajúce bodom *basion* a pravostranným a ľavostranným bodom *porion* u mužov je rovný nule oproti H_1 : korelačný koeficient *basion-bregmatickej výšky lebky a uhla*, ktorý zvierajú línie prechádzajúce bodom *basion* a pravostranným a ľavostranným bodom *porion* u mužov nie je rovný nule.
- **matematická formulácia** – $H_0 : \rho = \rho_0$ oproti $H_1 : \rho \neq \rho_0$, kde $\rho_0 = 0$.

2. **Testovacia štatistika** – Korelačný koeficient ρ je neznámy, preto ho musíme odhadnúť. Jeho odhadom je $\hat{\rho} \doteq 0.662$.


```

978 | DATA <- read.table("lin-uhl-fm.txt", header=TRUE)
979 | attach(DATA)
980 | n.m <- length(skull.H[sex=="m"]) # 40
981 | rho.hat <- lin.uhl.r(skull.H[sex=="m"], base.A[sex=="m"]) # 0.6618232

```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $z_W \doteq 4.842$.

Testovacia štatistika t -testu $t_W \doteq 5.442$.

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 23.050$.

```

982 | zR <- 1/2*log((1+rho.hat)/(1-rho.hat)) # 0.7960509
983 | rho0 <- 0
984 | xi0 <- 1/2*log((1+rho0)/(1-rho0)) # 0
985 | zW.obs <- sqrt(n.m-3)*(zR-xi0) # 4.842188
986 | tW.obs <- sqrt(n.m-2)*rho.hat/(sqrt(1-rho.hat^2)) # 5.442137
987 | uLR.obs <- -n.m*log(1-tW.obs^2/(tW.obs^2+(n-2))) # 23.05084

```

3. Zamietacia oblasť –

Waldov test:

kritické hodnoty $u(1 - \alpha/2) \doteq -1.960$ a $u(\alpha/2) \doteq 1.960$;

kritický obor $\mathcal{W}_1 = (z_{\min}, u(1 - \alpha/2)) \cup (u(\alpha/2), z_{\max}) \doteq (-\infty, -1.960) \cup (1.960, \infty)$.

t -test:

kritické hodnoty $t_{n-2}(1 - \alpha/2) = t_{38}(1 - 0.025) \doteq -2.024$ a $t_{n-2}(\alpha/2) = t_{38}(0.025) \doteq 2.024$;

kritický obor $\mathcal{W}_1 = (t_{\min}, t_{n-2}(1 - \alpha/2)) \cup (t_{n-2}(\alpha/2), t_{\max}) = (-\infty, -2.024) \cup (2.024, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty)$.

```

988 | z.krit.d <- qnorm(0.025) # -1.959964
989 | z.krit.h <- qnorm(0.975) # 1.959964
990 | t.krit.d <- qt(0.025, df=n.m-2) # -2.024394
991 | t.krit.h <- qt(0.975, df=n.m-2) # 2.024394
992 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459

```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov $100(1 - \alpha)\%$ empirický DIS = 95% empirický DIS pre ρ :

$(d, h) \doteq (0.441, 0.807)$.

Vierohodnostný 95% empirický DIS pre ρ :

$\mathcal{CS}_{0.95} = \{\rho_0 : u_{LR}(\rho_0) < \chi_1^2(\alpha)\} \doteq (0.449, 0.804)$.

```

993 | ISz.xy <- IScor.uhl(rho.hat, n.m) # 0.4412925 0.8069653
994 | rho.0i <- seq(-0.999, 0.999, by=0.0001)
995 | uLR.i <- -n.m*(log((1-rho.0i^2)*(1-rho.hat^2))/(1-rho.0i*rho.hat)^2))
996 | IS.LR <- range(rho.0i[which(uLR.i < lr.krit.hodn)]) # 0.4492 0.8035

```

5. Štatistický záver –

Waldov test: p -hodnota = $2\Pr(Z_W \geq |6.010| | H_0) < 0.0001$

t -test: p -hodnota = $2\Pr(T_W \geq |6.723| | H_0) < 0.0001$.

Test pomerom vierohodnosti: p -hodnota = $\Pr(U_{LR} \geq 23.050 | H_0) < 0.0001$.

```

997 | p.hodn.zW <- 2*(1-pnorm(abs(zW.obs))) # 1.854635e-09
998 | p.hodn.tW <- 2*(1-pnorm(abs(tW.obs))) # 1.774803e-11
999 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 4.098731e-09

```

H_0 na hladine významnosti zamietame, pretože (1) testovacia štatistika patrí kritickému oboru, (2) $\rho_0 = 0$ nepatrí DIS a nakoniec (3) p -hodnota je menšia ako 0.05.

- Slovný záver** – Zamietame nulovú hypotézu o tom, že korelačný koeficient basion-bregmatickej výšky lebky a uhla, ktorý zvierajú línie prechádzajúce bodom *basion* a pravostranným a ľavostranným bodom *porion* u mužov, je rovný nule.
- Antropologický záver** – Veľkosť uhla s basion-bregmatickou výškou lebky pozitívne koreluje ($r=0.66$), t. j. so zväčšujúcou sa basion-bregmatickou výškou lebky sa zväčšuje aj veľkosť sledovaného uhla. Je otázku, či je to v dôsledku veľkostných zmien a vyššie lebky sú súčasne aj širšie (oba body *porion* sú od seba vzdialenejšie) alebo sa so zvyšujúcou sa basion-bregmatickou výškou lebky znižuje výška lebečnej bázy (minimálna vzdialenosť bodu *basion* k spojnici pravostranného a ľavostranného bodu *porion*), vylúčená nie je ani kombinácia týchto faktorov.

Príklad 207 (test o uhlovom ρ) Naprogramujte v \mathbb{R} funkcie na výpočet odhadu uhlového korelačného koeficientu.

Riešenie v \mathbb{R}

```

1000 "priem.uhol" <- function(x.cos,x.sin){
1001 # x.cos ... kosinus uhlovej premennej
1002 # x.sin ... sinus uhlovej premennej
1003 sum.x.cos <- sum(x.cos)
1004 sum.x.sin <- sum(x.sin)
1005 if (sum.x.cos>0) x.bar <- atan(sum.x.sin/sum.x.cos)
1006 if (sum.x.cos<0) x.bar <- atan(sum.x.sin/sum.x.cos)+pi
1007 if (sqrt(sum.x.sin^2+sum.x.cos^2)==0) x.bar <- NaN
1008 return(x.bar)
1009 }
1010 "sin.cos.uhla" <- function(x){
1011 x.rad <- (x*pi)/180
1012 x.cos <- cos(x.rad)
1013 x.sin <- sin(x.rad)
1014 VVSL <- list(x.cos=x.cos,x.sin=x.sin)
1015 return(VVSL)
1016 }
1017 "uhl.uhl.r" <- function(x,y){
1018 # x ... uhlova premenna v stupnoch
1019 # y ... uhlova premenna v stupnoch
1020 sin.cos.x <- sin.cos.uhla(x)
1021 x.cos <- sin.cos.x$x.cos
1022 x.sin <- sin.cos.x$x.sin
1023 x.bar <- priem.uhol(x.cos,x.sin)
1024 x.sin.centri <- sin(x.rad-x.bar)
1025 sin.cos.y <- sin.cos.uhla(y)
1026 y.cos <- sin.cos.y$x.cos
1027 y.sin <- sin.cos.y$x.sin
1028 y.bar <- priem.uhol(y.cos,y.sin)
1029 y.sin.centri <- sin(y.rad-y.bar)
1030 citatel <- sum(x.sin.centri*y.sin.centri)
1031 menovatel <- sqrt(sum((x.sin.centri^2))*sqrt(sum((y.sin.centri^2)))
1032 r.xy <- citatel/menovatel
1033 return(r.xy)
1034 }

```

Príklad 208 (test o uhlovom ρ) Majme dáta *uhl-uhl-fm.txt* a premenné *uhol* v bode *nasion* a *uhla* tvárového trojuholníka v bode *prosthion* u žien. (a) Otestujte hypotézu o tom, že korelačný koeficient týchto dvoch uhlov je rovný nule. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre korelačný koeficient, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku Z_W , (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} a DIS prislúchajúce (1) a (2). Výsledky Waldovho testu skontrolujte pomocou funkcie `cor.test()`.

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : korelačný koeficient uhla v bode *nasion* a uhla tvárového trojuholníka v bode *prosthion* u žien je rovný nule oproti H_1 : korelačný koeficient uhla v bode *nasion* a uhla tvárového trojuholníka v bode *prosthion* u žien nie je rovný nule.
- **matematická formulácia** – $H_0 : \rho = \rho_0$ oproti $H_1 : \rho \neq \rho_0$, kde $\rho_0 = 0$.

2. **Testovacia štatistika** – Korelačný koeficient ρ je neznámy, preto ho musíme odhadnúť. Jeho odhadom je $\hat{\rho} \doteq 0.335$.

```

1035 DATA <- read.table("uhl-uhl-fm.txt",header=TRUE)
1036 attach(DATA)
1037 n.f <- length(front.A[sex=="f"]) # 20
1038 rho.hat <- uhl.uhl.r(front.A[sex=="f"],prog.A[sex=="f"]) # 0.3347396

```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $z_W \doteq 1.435$.

Testovacia štatistika t -testu $t_W \doteq 1.507$.

Testovacia štatistika pomerom vierohodnosti $U_{LR} \doteq 2.377$.

```

1039 | zR <- 1/2*log((1+rho.hat)/(1-rho.hat)) # 0.3481565
1040 | rho0 <- 0
1041 | xi0 <- 1/2*log((1+rho0)/(1-rho0)) # 0
1042 | zW.obs <- sqrt(n.f-3)*(zR-xi0) # 1.435486
1043 | tW.obs <- sqrt(n.f-2)*rho.hat/(sqrt(1-rho.hat^2)) # 1.507125
1044 | uLR.obs <- -n.f*(log((1-rho0^2)*(1-rho.hat^2)/(1-rho0*rho.hat^2)))
1045 | # 2.376811

```

3. Zamietacia oblasť –

Waldov test:

kritické hodnoty $u(1 - \alpha/2) \doteq -1.960$ a $u(\alpha/2) \doteq 1.960$;

kritický obor $\mathcal{W}_1 = (z_{\min}, u(1 - \alpha/2)) \cup (u(\alpha/2), z_{\max}) \doteq (-\infty, -1.960) \cup (1.960, \infty)$.

t -test:

kritické hodnoty $t_{n-2}(1 - \alpha/2) = t_{18}(1 - 0.025) \doteq -2.101$ a $t_{n-2}(\alpha/2) = t_{18}(0.025) \doteq 2.101$;

kritický obor $\mathcal{W}_1 = (t_{\min}, t_{n-2}(1 - \alpha/2)) \cup (t_{n-2}(\alpha/2), t_{\max}) \doteq (-\infty, -2.101) \cup (2.101, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty)$.

```

1046 | z.krit.d <- qnorm(0.025) # -1.959964
1047 | z.krit.h <- qnorm(0.975) # 1.959964
1048 | t.krit.d <- qt(0.025, df=n.f-2) # -2.100922
1049 | t.krit.h <- qt(0.975, df=n.f-2) # 2.100922
1050 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459

```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov 100(1 - α)% empirický DIS = 95% empirický DIS pre ρ :

$(d, h) \doteq (-0.127, 0.677)$.

Vierohodnostný 95% empirický DIS pre ρ :

$\mathcal{CS}_{0.95} = \{\rho_0 : u_{LR}(\rho_0) < \chi_1^2(\alpha)\} \doteq (-0.097, 0.660)$.

```

1051 | ISz.xy <- lScor.uhl(rho.hat, n.f) # -0.1265229 0.6769799
1052 | rho.oi <- seq(-0.999, 0.999, by=0.0001)
1053 | uLR.i <- -n.f*(log((1-rho.oi^2)*(1-rho.hat^2)/(1-rho.oi*rho.hat^2)))
1054 | IS.LR <- range(rho.oi[which(uLR.i < lr.krit.hodn)]) # -0.0968 0.6603

```

5. Štatistický záver –

Waldov test: p -hodnota $\doteq 2\Pr(Z \geq |1.435| | H_0) \doteq 0.151$

t -test: p -hodnota $\doteq 2\Pr(T \geq |1.507| | H_0) \doteq 0.132$.

Test pomerom vierohodnosti: p -hodnota $= \Pr(U \geq 2.377 | H_0) \doteq 0.123$.

```

1055 | p.hodn.zW <- 2*(1-pnorm(abs(zW.obs))) # 0.1511486
1056 | p.hodn.tW <- 2*(1-pnorm(abs(tW.obs))) # 0.1317786
1057 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 0.1231487

```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\rho_0 = 0$ patrí DIS a nakoniec (3) p -hodnota je väčšia ako 0.05.

6. Slovný záver –

Nezamietame nulovú hypotézu o tom, že korelačný koeficient medzi veľkosťou uhla v bode *nasion* a veľkosťou uhla tvárového trojuholníka v bode *prosthion* je u žien rovný nule.

7. Antropologický záver –

Nedokázali sme súvislosť medzi tvarom lebky v oblasti bodu *nasion* a bodu *prosthion*. Sklon čela (zvislosť šupiny čelovej kosti) v mediosagitálnej rovine teda nesúvisí s analogicky definovaným uhlom v hornej časti tváre v bode *prosthion*, i keď korelácia je pozitívna a pri väčšej vzorke by sme závislosť nájsť mohli. Obe časti lebky (predná časť neurokrania a horná časť splanchnokrania) sú teda pomerne samostatnými jednotkami a ich tvar je ovplyvnený inými faktormi, napriek tomu, že spolu anatomicky úzko súvisia.

6.4 Asymptotické testy o pravdepodobnosti

Testy pravdepodobností (proporcií) sa v antropológii používajú pri hodnotení kvalitatívnych znakov u živých ľudí i na kostre človeka. Kvalitatívne znaky sú znaky, ktoré nehodnotíme meraním, ale posudzujeme ich prítomnosť či neprítomnosť. Populácie sa potom medzi sebou líšia proporciou prípadov s výskytom znaku a bez výskytu znaku. Medzi kvalitatívne znaky môžeme zaradiť napr.

krvné skupiny s jedným antigénom, v prípade ktorých ide o frekvenciu jedincov s prítomnosťou alebo neprítomnosťou danej protilátky. Kvalitatívne sa tradične popisuje počet jedincov každého pohlavia v populácii (pomer pohlaví), stranová asymetria (väčšia hodnota vpravo alebo väčšia hodnota vľavo) či stranové preferencie (praváci alebo ľaváci). Iným príkladom kvalitatívnych znakov sú epigenetické znaky na lebke (napr. metopizmus – perzistencia *sutura interfrontalis* v dospelosti), kde väčšinou jedinca zaradíme do jednej z dvoch kategórií (znak prítomný alebo neprítomný) alebo dermatoglyfické znaky, u ktorých jedincov radíme do dvoch kategórií (napr. prítomnosť či neprítomnosť digitálneho trirádia *c*). Dalším príkladom kvalitatívneho znaku môže byť chuťová vnímavosť fenylythiokarbamidu, kde jedincov rozdeľujeme do dvoch skupín podľa toho, či horkú chuť látok s touto zložkou vnímajú alebo nie. Kvalitatívnych znakov sa v antropológii rozlišuje veľké množstvo a výsledky ich hodnotenia sa ľahko publikujú v texte či tabuľkách, čo umožňuje rozsiahle porovnania s publikovanými výsledkami rôznych výskumov (na rozdiel od spojitých znakov, kde sa v súčasnosti primárne dáta/individuálne hodnoty väčšinou nepublikujú a pri porovnávaní musíme vychádzať zo sekundárnych dát). Veľmi jednoducho tak môžeme otestovať, či sa odporcie zistené v našom výskume (napr. pomer jedincov vnímajúcich a nevnímajúcich chuť fenylythiokarbamidu v českej populácii) a pomer zistený v publikovanej porovnávacej štúdií líši.

Nech $X \sim \text{Bin}(N, p)$. Majme dvojicu hypotéz $H_{01} : p = p_0$ oproti $H_{11} : p \neq p_0$, $H_{02} : p \leq p_0$ oproti $H_{12} : p > p_0$, $H_{03} : p \geq p_0$ oproti $H_{13} : p < p_0$, ktoré chceme testovať.

Ak H_0 platí, potom

$$Z_W = \frac{X/N - p_0}{\sqrt{X/N(1 - X/N)/N}} \stackrel{\mathcal{D}}{\sim} N(0, 1).$$

Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **jednovýberový Z-test o pravdepodobnosti p** .

Minimálny rozsah výberu pre normálnu aproximáciu stanovíme na základe *Haldovej podmienky* $Np(1 - p) > 9$ (pozri tabuľku 7.4).

Tabuľka 6.3: Minimálne rozsahy N pre rôzne p v súvislosti s Haldovou podmienkou


p	0.01	0.02	0.05	0.10	0.15	0.20	0.30	0.40	0.50
$1 - p$	0.99	0.98	0.95	0.90	0.85	0.80	0.70	0.60	0.50
N	910	460	190	100	71	57	43	38	36

Definícia 61 (Kritický obor a silofunkcia Z_W testu o p) Kritický obor a silofunkcia sú definované nasledovne (pozri obrázok 6.8):

$$\begin{array}{llll} H_0 & H_1 & \mathcal{W} & 1 - \beta(p) \\ p = p_0 & p \neq p_0 & \mathcal{W}_1 = \{Z_W; |Z_W| \geq u(\alpha/2)\} & 1 - \Phi\left(u_{\alpha/2} - \frac{|p_0 - p|}{\sqrt{p(1-p)/N}}\right) \\ p \leq p_0 & p > p_0 & \mathcal{W}_2 = \{Z_W; Z_W \geq u(\alpha)\} & 1 - \Phi\left(u_{\alpha} + \frac{p_0 - p}{\sqrt{p(1-p)/N}}\right) \\ p \geq p_0 & p < p_0 & \mathcal{W}_3 = \{Z_W; Z_W \leq -u(\alpha)\} & 1 - \Phi\left(u_{\alpha} - \frac{p_0 - p}{\sqrt{p(1-p)/N}}\right) \end{array}$$

Definícia 62 (p-hodnota Z_W testu o p) Nech Z_W je *nejaká testovacia štatistika* a $z_W = \frac{\hat{p} - p_0}{\sqrt{\hat{p}(1-\hat{p})/N}}$ je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p -hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : p \neq p_0 \\ \Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : p > p_0 \\ \Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : p < p_0 \end{cases}$$



Obr. 6.8: Silofunkcie asymptotického testu o p pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 63 (Waldove $100 \times (1 - \alpha)\%$ empirické IS pre p) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre p pre všetky tri typy hypotéz majú nasledovný tvar:

$$\begin{array}{lll}
 H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1 - \alpha)\% \text{ empirický IS} \\
 p = p_0 & p \neq p_0 & \mathcal{CS}_{1-\alpha} = \left\{ p_0 : p_0 \in \left(\hat{p} - u_{\alpha/2} \sqrt{\hat{p}(1-\hat{p})/N}, \hat{p} + u_{\alpha/2} \sqrt{\hat{p}(1-\hat{p})/N} \right) \right\} \\
 p \leq p_0 & p > p_0 & \mathcal{CS}_{1-\alpha} = \left\{ p_0 : p_0 \in \left(\hat{p} - u_{\alpha} \sqrt{\hat{p}(1-\hat{p})/N}, 1 \right) \right\} \\
 p \geq p_0 & p < p_0 & \mathcal{CS}_{1-\alpha} = \left\{ p_0 : p_0 \in \left(0, \hat{p} + u_{\alpha} \sqrt{\hat{p}(1-\hat{p})/N} \right) \right\}
 \end{array}$$

Majme H_{11} . Ak H_{01} neplatí, chceme túto skutočnosť odhaliť s pravdepodobnosťou (silou) aspoň $1 - \beta$. Ak $c = \frac{p-p_0}{\sigma}$, potom **minimálny rozsah** N definujeme nasledovne

$$N \geq \left(\frac{u_{\alpha/2} + u_{\beta}}{c} \right)^2 = \left(\frac{u_{\alpha/2} + u_{\beta}}{p - p_0} \right)^2 p(1 - p).$$

Pre H_{12} a H_{13} zameníme $u_{\alpha/2}$ za u_{α} .

Majme testovaciu štatistiku $Z_W^{(\text{alt})} = \frac{g(\hat{p}) - g(p_0)}{SE[g(\hat{p})]}$ a Waldov $100 \times (1 - \alpha)\%$ empirický IS rovný (d, h) pre tri transformácie nájdeme spätnou transformáciou (d_g, h_g) nasledovne:

- ak $g(p) = \frac{p}{1-p}$, potom $SE[\widehat{g(\hat{p})}] = \sqrt{\frac{\hat{p}}{N(1-\hat{p})^3}}$, $d = \frac{d_g}{1+d_g}$ a $h = \frac{h_g}{1+h_g}$
- ak $g(p) = \ln\left(\frac{p}{1-p}\right)$, potom $SE[\widehat{g(\hat{p})}] = \sqrt{\frac{1}{N\hat{p}(1-\hat{p})}}$, $d = \frac{\exp(d_g)}{1+\exp(d_g)}$ a $h = \frac{\exp(h_g)}{1+\exp(h_g)}$.
- ak $g(p) = \arcsin(\sqrt{p})$, potom $SE[\widehat{g(\hat{p})}] = \frac{1}{2\sqrt{N}}$, $d = \sin^2(d_g)$ a $h = \sin^2(h_g)$.

Príklad 209 (vylepšená vierohodnosť pomocou $g(\theta)$) Nakreslite (a) logaritmus funkcie vierohodnosti parametra $g(p) = \frac{p}{1-p}$ binomického rozdelenia $\text{Bin}(N, p)$, kde $N = 10$ a $n = 8$, superponovaný jeho kvadratickou aproximáciou. Nakreslite (b) logaritmus funkcie vierohodnosti $g(p) = \ln \frac{p}{1-p}$ (pri rovnakom zadaní N a n ako v (a)), superponovaný jeho kvadratickou aproximáciou. Nakreslite (c) logaritmus funkcie vierohodnosti $g(p) = \arcsin(\sqrt{p}) = \sin^{-1} \sqrt{p}$ (pri rovnakom zadaní N a n ako v (a)); táto transformácia stabilizuje rozptyl p , superponovaný jeho kvadratickou aproximáciou. Je funkcia vierohodnosti $g(p)$ regulárnejšia ako funkcia vierohodnosti pre p ? (d) Vypočítajte vierohodnostný $100 \times (1 - \alpha)\%$ empirický IS pre $g(p)$ z (a), (b) a (c). (e) Vypočítajte Waldov $100 \times (1 - \alpha)\%$ empirický IS pre $g(p)$ a transformujte ho späť do originálnej škály. (f) Ukážte, že vierohodnostný IS pre p v škále p je identický s vierohodnostným IS v škále $g(p)$ po jeho spätnej transformácii do originálnej škály.

Riešenie (čiastočné; odvodenie odhadu rozptylu $g(p) = \frac{p}{1-p}$)

$$Var(\widehat{g(\hat{p})}) = \frac{\left[\frac{\partial}{\partial p} \left(\frac{p}{1-p}\right)\right]^2}{-\frac{\partial^2}{\partial p^2} \ln L(p|\mathbf{x})} = \frac{\left[\frac{(1-p)+p}{(1-p)^2}\right]^2}{\frac{N}{p(1-p)}} \stackrel{p=\hat{p}}{=} \frac{\hat{p}}{N(1-\hat{p})^3}.$$

Skóre testovaciú štatistiku U_S odvodíme nasledovne

$$U_S = \frac{\left[\frac{\partial}{\partial \theta} \ln L(p|\mathbf{x})\right]^2}{\mathcal{I}(p)} = \frac{\left(\frac{X}{p} - \frac{N-X}{1-p}\right)^2}{\frac{N}{p(1-p)}} \stackrel{p=p_0}{=} \frac{(X/N - p_0)^2}{p_0(1-p_0)/N} \stackrel{\mathcal{D}}{\sim} \chi_1^2.$$

Skóre $100 \times (1 - \alpha)\%$ **empirický DIS pre** p má tvar $\mathcal{CS}_{1-\alpha} = \{|Z_S| \leq u_{\alpha/2}\}$, kde $Z_S = \frac{X/N - p_0}{\sqrt{p_0(1-p_0)/N}}$, čo je identické $\mathcal{CS}_{1-\alpha} = \{U_S \leq \chi_{\alpha/2}^2\}$. Po niekoľkých algebraických úpravách môžeme $\mathcal{CS}_{1-\alpha}$ prepísať do kvadratickej nerovnice

$$\mathcal{CS}_{1-\alpha} = \left\{ p_0 : \left(1 + \frac{u_{\alpha/2}^2}{N}\right) p_0^2 - \left(2\hat{p} + \frac{u_{\alpha/2}^2}{N}\right) p_0 + \hat{p}^2 \leq 0 \right\}.$$

Korene tejto nerovnice definujú hranice DIS (d, h) nasledovne (Wilson, 1927)

$$\frac{2\hat{p} + u_{\alpha/2}^2/N \pm \sqrt{\left(2\hat{p} + u_{\alpha/2}^2/N\right)^2 - 4\hat{p}^2 \left(1 + u_{\alpha/2}^2/N\right)}}{2 \left(1 + u_{\alpha/2}^2/N\right)}.$$

Po ďalších úpravách dostaneme DIS v tvare

$$\hat{p} \left(\frac{N}{N + u_{\alpha/2}^2} \right) + \frac{1}{2} \left(\frac{u_{\alpha/2}^2}{N + u_{\alpha/2}^2} \right) \pm u_{\alpha/2} \sqrt{\frac{1}{N + u_{\alpha/2}^2} \left[\hat{p}(1 - \hat{p}) \left(\frac{N}{N + u_{\alpha/2}^2} \right) + \frac{1}{4} \frac{u_{\alpha/2}^2}{N + u_{\alpha/2}^2} \right]}.$$

Stred tohoto IS je váženým priemerom dvoch členov a patrí intervalu s hranicami \hat{p} a $\frac{1}{2}$ s váhou pre \hat{p} kovergujúcou asymptoticky do jednotky. Tento stred posúva \hat{p} smerom ku 0.5, pričom s rastúcim N sa tento posun znižuje. Rozptyl je tiež váženým priemerom rozptylu \hat{p} a 0.5 použitím $N + u_{\alpha/2}^2$ namiesto rozsahu N (Agresti a Coull, 1998).

Jednovýberový skóre test o pravdepodobnosti p v \mathbb{R} (funkcia **prop.test()**).

Argumenty (vstupy) funkcie:

1. početnosť (úspechy n) x ;
2. rozsah (počet úspechov a neúspechov N) n ;
3. pravdepodobnosť p_0 za platnosti H_0 ($p_0 \in (0, 1)$);
4. formulácia alternatívy `alternative="two.sided"` je prednastavené, ďalšie voľby sú "greater", "less";
5. spoľahlivosť `conf.level=p`, prednastavené je `conf.level=.95`;
6. Yatesova korekcia na spojitosť (Newcombe, 1998), prednastavené `correct = TRUE`.

Výstupy funkcie:

1. testovacia štatistika `statistic` ($\chi^2 = Z_S^2$);
2. stupne voľnosti `df` (`parameter`; $df = 1$);

3. p-hodnota `p.value`;
4. odhad pravdepodobnosti \hat{p} estimate;
5. interval spoľahlivosti `conf.int` (skóre (Wilsonov) IS);
6. hodnota p_0 null value;
7. alternatívna hypotéza `alternative hypothesis`;
8. názov použitého testu `method`.

Funkcia `binconf()` s knižnice `Hmisc` počíta intervaly spoľahlivosti pre p . Argument `method="wilson"` znamená skóre interval spoľahlivosti a `method="asymptotic"` Waldov interval spoľahlivosti.

Test pomerom vierohodnosti pre p .

Mažeme H_{01} oproti H_{11} . Nech $X \sim \text{Bin}(N, p)$, kde $\theta = p$, potom logaritmus vierohodnostnej funkcie bude mať tvar

$$l(p|\mathbf{x}) = x \ln p + (N - x) \ln(1 - p).$$

MLE θ je rovný $\hat{p} = x/N$, t.j. $\Theta_1 = \{\theta : p \neq p_0\}$. Za platnosti H_{01} je $\theta_0 = p_0$, t.j. $\Theta_0 = \{\theta : p = p_0\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x})) &= l(\hat{p}|\mathbf{x}) - l(p_0|\mathbf{x}) = x \ln \hat{p} + (N - x) \ln(1 - \hat{p}) - x \ln p_0 - (N - x) \ln(1 - p_0) \\ &= x \ln \frac{\hat{p}}{p_0} + (N - x) \ln \frac{1 - \hat{p}}{1 - p_0} = x \ln \frac{x}{Np_0} + (N - x) \ln \frac{N - x}{N - Np_0}. \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{\text{LR}} = -2 \ln(\lambda(\mathbf{X})) \stackrel{\mathcal{D}}{\sim} \chi_1^2$. Preznačme p na p_1 a $q = 1 - p$ na p_2 , x na n_1 a $N - x$ na n_2 . Potom $\boldsymbol{\theta} = \mathbf{p} = (p_1, p_2)^T$, $\hat{\boldsymbol{\theta}} = \hat{\mathbf{p}} = (\hat{p}_1, \hat{p}_2)^T$, kde $\hat{p}_1 = \frac{n_1}{N}$, $\hat{p}_2 = \frac{n_2}{N}$, $p_1 + p_2 = 1$ a $n_1 + n_2 = N$; $\boldsymbol{\theta}_0 = \mathbf{p}_0 = (p_{01}, p_{02})^T$, kde $p_{01} = p_0$ a $p_{02} = 1 - p_0$. Potom dostaneme

$$u_{\text{LR}} = 2 \sum_{i=1}^2 n_i \ln \frac{\hat{p}_i}{p_{0i}} = 2 \sum_i \text{pozorované}_i \times \ln \frac{\text{pozorované}_i}{\text{očakávané}_i}.$$

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre p_1 bude mať tvar

$$\mathcal{CS}_{1-\alpha} = \{p_0 : U_{\text{LR}} \leq \chi_1^2(\alpha)\}.$$

Príklad 210 (porovnanie troch DIS v extrémnej situácii) Nech $N = 25$ študentov, ktorým sme položili otázku, či sú vegetariáni. Z nich $x = 0$ odpovedalo „áno“. Vypočítajte empirické $100 \times (1 - \alpha)\%$ DIS (a) Waldov DIS, (b) skóre DIS a (c) vierohodnostný DIS pre p ($1 - \alpha = 0.95$).

Riešenie (aj v \mathbb{R})

Ak $x = 0$, $\hat{p} = 0/25 = 0$.

(a) Waldov 95% empirický DIS pre p má tvar $0 \pm 1.96 \sqrt{(0 \times 1)/25}$, kde $(d, h) = (0, 0)$. Z toho vyplýva, že ak máme pravdepodobnosť na hraniciach výberového priestoru, Waldov DIS nie je vhodný.

```
1058 | N <- 25
1059 | phat <- 0/N
1060 | var.phat <- phat*(1-phat)/N
1061 | ISw <- phat+c(-1,1)*qnorm(0.975)*sqrt(var.phat) # 0 0
```

alebo

```
1062 | library(Hmisc)
1063 | binconf(x=0,n=25,method="asymptotic")
```

(b) Skóre 95% empirický DIS pre p má tvar

$$\frac{1}{2} \left(\frac{1.96^2}{25 + 1.96^2} \right) \pm 1.96 \sqrt{\frac{1.96^2}{4(25 + 1.96^2)^2}},$$

kde $(d, h) = (0.000, 0.133)$.

```
1064 | skoreLS <- prop.test(x=0,n=25,conf.level=0.95,correct=FALSE)$conf.int
1065 | # 0 0.1331923
```

alebo

```
1066 | binconf(x=0,n=25,method="wilson")
```

(c) Jadro funkcie vierohodnosti má tvar $L(p|\mathbf{x}) = p^0(1-p)^{25}$, potom $l(p|\mathbf{x}) = 25 \ln(1-p)$. Keďže $L(\hat{p}|\mathbf{x}) = 0$, bude U_{LR} rovná $-2[l(p_0|\mathbf{x}) - l(\hat{p}|\mathbf{x})] = -50 \ln(1-p_0)$ a 95% vierohodnostný IS je definovaný ako

$$\mathcal{CS}_{1-\alpha} = \{p_0 : U_{LR} \leq \chi_1^2(\alpha)\}, \text{ kde } \chi_1^2(\alpha) = 3.84.$$

Potom $h = 1 - \exp(-3.84/50) = 0.074$ a nakoniec 95% empirický DIS má tvar $(0.000, 0.074)$.

```
1067 | "LR.p" <- function(pi.0, x,N, alpha) {
1068 | -2*(x*log(pi.0)+(N-x)*log(1-pi.0))-qchisq(1-alpha, df=1)
1069 | }
1070 | uniroot(f=LR, interval=c(0.000001,.999999),x=0,N=25,alpha=.05)$root # 0.07395093
```

Spomenuté tri metódy dávajú rôzne výsledky. Ak je p blízko nuly, rozdelenie \hat{p} je vysoko zošikmené doprava pre malé N . V takejto situácii sa odporúča používať skóre alebo vierohodnostný DIS.

Príklad 211 (funkcia vierohodnosti v extrémnej situácii) *Nakreslite funkciu vierohodnosti pre situáciu v predchádzajúcom príklade.*

Príklad 212 (test o pravdepodobnosti p) *Majme dáta one-sample-probability-sexratio.txt a premennú pohlavie novorodenca sex, kde početnosť chlapcov $n_m = 729$ a početnosť dievčat $n_f = 674$. Nech početnosť chlapcov $X \sim \text{Bin}(N, p)$. (a) Otestujte $H_0 : p_m = p_0 = 0.5$ oproti $H_1 : p_m \neq 0.5$ a vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre pravdepodobnosť narodenia chlapca p_m , kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku $U_W = Z_W^2$, (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} , (3) skóre testovaciu štatistiku $U_S = Z_S^2$ a DIS prislúchajúce (1), (2) a (3). Výsledky skóre testu skontrolujte pomocou funkcie `prop.test()`. (b) Otestujte $H_0 : g(p_m) = g(p_0) = 1$ oproti $H_1 : g(p_m) \neq 1$ pomocou Z_W^{alt} , kde $g(p_m) = \frac{p_m}{1-p_m} = \frac{p_m}{p_f}$, $SE[g(\hat{p}_m)] = \sqrt{\frac{\hat{p}_m}{N(1-\hat{p}_m)^3}}$ a vypočítajte DIS pre pomer pohlaví (=šanca narodenia chlapca) a použitím spätnej transformácie DIS pre p_m .*

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia (a)** – testujeme H_0 : pravdepodobnosť narodenia chlapca je identická s pravdepodobnosťou narodenia dievčaťa oproti H_1 : pravdepodobnosť narodenia chlapca nie je identická s pravdepodobnosťou narodenia dievčaťa.
- **slovná formulácia (b)** – testujeme H_0 : pomer pohlaví (šanca narodenia chlapca) je rovný jednej oproti H_1 : pomer pohlaví nie je rovný jednej.
- **matematická formulácia (a)** – $H_0 : p_m = p_0$ oproti $H_1 : p_m \neq p_0$, kde $p_0 = 0.5$.
- **matematická formulácia (b)** – $H_0 : g(p_m) = g(p_0)$ oproti $H_1 : g(p_m) \neq g(p_0)$, kde $g(p_m) = \frac{p_m}{1-p_m} = \frac{p_m}{p_f}$ a $g(p_0) = 1$.

2. Testovacia štatistika – $\hat{p}_m = \frac{n_m}{n_m+n_f} = \frac{729}{729+674} = 0.52$, $\hat{p}_f = 0.48$, $SR_m = \frac{\hat{p}_m}{\hat{p}_f} = \frac{n_m}{n_f} = 1.08$.

```
1071 | DATA <- read.table("one-sample-probability-sexratio.txt",header=TRUE)
1072 | n <- as.numeric(table(DATA))
1073 | n.m <- n[2]
1074 | n.f <- n[1]
1075 | N <- sum(n) # 1403
1076 | p.m <- n.m/N # 0.5196009
1077 | p.f <- n.f/N # 0.4803991
1078 | p <- c(p.f, p.m)
1079 | SRm <- p.m/p.f # 1.081602
```


Pozorované testovacie štatistiky:

Waldova testovacia štatistika $z_W \doteq 1.469$ (pre $H_0 : p_m = p_0$).

Testovacia štatistika pomerom vierohodnosti $u_{LR} = 2.157$ (pre $H_0 : p_m = p_0$).

Skóre testovacia štatistika $z_S \doteq 1.468$ (pre $H_0 : p_m = p_0$).

Waldova testovacia štatistika $z_W \doteq 1.412$ (pre $H_0 : g(p_m) = g(p_0)$).

```
1080 | p0 <- 0.5
1081 | p0.vec <- c(p0,1-p0)
1082 | SR0 <- 1
1083 | zW.obs <- (p.m-p0)/sqrt(p.m*p.f/N) # 1.469494
1084 | uLR.obs <- 2*sum(n*log(p/p0.vec)) # 2.156647
1085 | zS.obs <- (p.m-p0)/sqrt(p0*(1-p0)/N) # 1.468364
1086 | zS.obs <- sqrt(prop.test(n.m,N,p=0.5,correct=FALSE)$stat) # 1.468364
1087 | zWg.obs <- (SRm-SR0)/sqrt(p.m/(N*(1-p.m)^3)) # 1.411887
```

3. Zamietacia oblasť –

Waldov a skóre test:

kritické hodnoty $u(1 - \alpha/2) \doteq -1.960$ a $u(\alpha/2) \doteq 1.960$;

kritický obor $\mathcal{W}_1 = (z_{\min}, u(1 - \alpha/2)) \cup (u(\alpha/2), z_{\max}) \doteq (-\infty, -1.960) \cup (1.960, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty)$.

```
1088 | z.krit.d <- qnorm(0.025) # -1.959964
1089 | z.krit.h <- qnorm(0.975) # 1.959964
1090 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov 100(1 - α)% empirický DIS = 95% empirický DIS pre p_m :
(d, h) \doteq (0.493, 0.546).

Vierohodnostný 95% empirický DIS pre p_m :

$\mathcal{CS}_{0.95} = \{p_0 : u_{LR}(p_0) < \chi_1^2(\alpha)\} \doteq$ (0.493, 0.546).

Skóre 95% empirický DIS pre p_m : (d, h) \doteq (0.493, 0.546).

Waldov 95% empirický DIS pre $g(p_m)$: (d, h) \doteq (0.968, 1.195).

Waldov 95% empirický DIS pre p_m : (d, h) \doteq (0.492, 0.544).

```
1091 | ISzW <- p.m+c(-1,1)*qnorm(0.975)*sqrt(p.m*p.f/N) # 0.4934579 0.5457438
1092 | p0i <- seq(0.000001,0.999999,by=0.000001)
1093 | uLR.i <- 2*(n[2]*log(p[2]/p0i)+n[1]*log(p[1]/(1-p0i)))
1094 | IS_LR <- range(p0i[which(uLR.i<lr.krit.hodn)]) # 0.49344 0.545696
1095 | ISzS <- prop.test(n.m,N,p=0.5,correct=FALSE)$conf.int # 0.4934400 0.5456547
1096 | ISzWg <- SRm+c(-1,1)*qnorm(0.975)*sqrt(p.m/(N*(1-p.m)^3))
1097 | # 0.968323 1.194882
1098 | ISzWtrans <- c(ISzWg[1]/(1+ISzWg[1]),ISzWg[2]/(1+ISzWg[2]))
1099 | # 0.4919533 0.5443946
```

5. Štatistický záver –

Waldov test: p-hodnota= $2\Pr(Z_W \geq |1.469||H_0) \doteq 0.142$ (pre $H_0 : p_m = p_0$).

Test pomerom vierohodnosti: p-hodnota= $\Pr(U_{LR} \geq 2.157|H_0) \doteq 0.142$ (pre $H_0 : p_m = p_0$).

Skóre test: p-hodnota= $2\Pr(Z_S \geq |1.469||H_0) \doteq 0.142$ (pre $H_0 : p_m = p_0$).

Waldov test: p-hodnota= $2\Pr(Z_W \geq |1.412||H_0) \doteq 0.158$ (pre $H_0 : g(p_m) = g(p_0)$).

```
1100 | p.hodn.zW <- 2*(1-pnorm(abs(zW.obs))) # 0.1416988
1101 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 0.1419542
1102 | p.hodn.zS <- 2*(1-pnorm(abs(zW.obs))) # 0.1416988
1103 | p.hodn.zS <- prop.test(n.m,N,p=0.5,correct=FALSE)$p.val
1104 | p.hodn.zWg <- 2*(1-pnorm(abs(zWg.obs))) # 0.1579831
```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $p_0 = 0.5$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. Slovný záver (a) – Nezamietame nulovú hypotézu o tom, že pravdepodobnosť narodenia chlapca je identická s pravdepodobnosťou narodenia dievčaťa.

Slovný záver (b) – Nezamietame nulovú hypotézu o tom, že pomer pohlaví je rovný jednej (šanca narodenia chlapca je rovná jednej).

7. **Antropologický záver** – Prenatálne faktory, ktoré ovplyvňujú vznik a udržanie mužských a ženských embryí a plodov, pôsobili v rovnováhe a neposunuli pomer mimo vyrovnaný (1.0). Vzhľadom na to, že interval spoľahlivosti zahŕňa aj celosvetovú strednú hodnotu pomeru pohlaví novorodencov (1.05) a strednú hodnotu pre českú populáciu (1.06), nemožno v empiricky zistenom pomere pohlaví v sledovanej geografickej oblasti vidieť žiadny vplyv špecifických lokálnych faktorov, ktoré by miestne hodnoty vychýľovali mimo normu.

Príklad 213 (test o pravdepodobnosti p ; malý vs. veľký rozsah) Ako by sa zmenili výsledky predchádzajúceho príkladu, keby sme mali $N = 50$, $n_m = 26$ a $n_f = 24$?

Riešenie

Pozorované testovacie štatistiky sú rovné:

Waldova testovacia štatistika $z_W \doteq 0.283$ (pre $H_0 : p_m = p_0$).

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 0.080$ (pre $H_0 : p_m = p_0$).

Skóre testovacia štatistika $z_S \doteq 0.283$ (pre $H_0 : p_m = p_0$).

Waldova testovacia štatistika $z_W \doteq 0.272$ (pre $H_0 : g(p_m) = g(p_0)$).

p-hodnoty:

Waldov test: p-hodnota $\doteq 2\Pr(Z_W \geq |0.283| | H_0) \doteq 0.777$ (pre $H_0 : p_m = p_0$).

Test pomerom vierohodnosti: p-hodnota $\doteq \Pr(U_{LR} \geq 0.080 | H_0) \doteq 0.777$ (pre $H_0 : p_m = p_0$).

Skóre test: p-hodnota $\doteq 2\Pr(Z_S \geq |0.283| | H_0) \doteq 0.777$ (pre $H_0 : p_m = p_0$).

Waldov test: p-hodnota $\doteq 2\Pr(Z_W \geq |0.272| | H_0) \doteq 0.786$ (pre $H_0 : g(p_m) = g(p_0)$).

IS:

Waldov 95% empirický DIS pre p_m : $(d, h) \doteq (0.382, 0.658)$.

Vierohodnostný 95% empirický DIS pre p :

$\mathcal{CS}_{0.95} = \{p_0 : u_{LR}(p_0) < \chi_1^2(\alpha)\} \doteq (0.383, 0.655)$.

Skóre 95% empirický DIS pre p_m : $(d, h) \doteq (0.358, 0.652)$.

Waldov 95% empirický DIS pre $g(p_m)$: $(d, h) \doteq (0.482, 1.684)$.

Waldov 95% empirický DIS pre p_m : $(d, h) \doteq (0.325, 0.627)$.

Príklad 214 (test o pravdepodobnosti p ; minimálny rozsah) Aký minimálny rozsah N by sme potrebovali na zamietnutie H_0 z predchádzajúceho príkladu, ak $\alpha = 0.05$, $1 - \beta = 0.8$?

Riešenie v \mathbb{R}

```
1105 | N <- ceiling(((qnorm(0.975)+qnorm(0.8))/(p.m-p0))^2*m*p.f) # 5100
```

Príklad 215 (test o pravdepodobnosti p) Majme dáta *one-sample-probability-sexratio.txt* a premennú pohlavie novorodenca *sex*, kde početnosť chlapcov $n_m = 729$ a početnosť dievčat $n_f = 674$. Nech početnosť chlapcov $X \sim \text{Bin}(N, p_m)$. Otestujte $H_0 : g(p_m) = g(p_0)$ oproti $H_1 : g(p_m) \neq g(p_0)$ pomocou Z_W^{alt} , kde $g(p_m) = \frac{p_m}{1-p_m}$, $SE[g(\hat{p}_m)] = \sqrt{\frac{\hat{p}_m}{N(1-\hat{p}_m)^3}}$. (a) $g(p_0) = 1.06$ (b) $g(p_0) = 1.06$.

Príklad 216 (Fisherova miera informácie) Vypočítajte Fisherovu mieru informácie $\mathcal{I}(g(\hat{p}))$, kde (a) $g(p) = \ln \frac{p}{1-p}$ a (b) $g(p) = \arcsin(\sqrt{p})$.

Príklad 217 (Fisherova miera informácie) Porovnajte DIS pre p použitím (a) Waldovho DIS, (b) vierohodnostného DIS, (c) skóre DIS, (d) transformovaného Waldovho DIS pre $g(p) = \frac{p}{1-p}$, (f) transformovaného Waldovho DIS pre $g(p) = \ln \frac{p}{1-p}$, (g) transformovaného Waldovho DIS pre $g(p) = \arcsin(\sqrt{p})$, kde (1) $N = 1400$ a $p = 0.05$, (2) $N = 40$ a $p = 0.05$, (3) $N = 1400$ a $p = 0.25$, (4) $N = 40$ a $p = 0.25$, (5) $N = 1400$ a $p = 0.5$, (6) $N = 40$ a $p = 0.5$.

Príklad 218 (minimálny rozsah N) Vypočítajte minimálny rozsah n pre $p = 0.1, 0.2, \dots, 0.9$, $p_0 = 0$ pri $\alpha = 0.05$, $\beta = 0.8$ a obojstrannej alternatíve H_{11} . Skontrolujte, či je splnená Haldova podmienka. Ak nie je, doplňte minimálne N , ktoré túto podmienku spĺňa.

Riešenie (pozri tabuľku 6.4)Tabuľka 6.4: Minimálne rozsahy N pre rôzne rozdiely p a p_0 (kde $p_0 = 0$) v porovnaní s minimálnym rozsahom vypočítaným pomocou Haldovej podmienky (tučne sú zvýraznené tie N , ktoré spĺňajú obe kritériá)

p	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
N	71	32	19	12	8	6	4	2	1
$Np(1-p)$	6.39	5.12	3.99	2.88	2.00	1.44	0.84	0.32	0.09
$9/(p(1-p))$	100	57	43	38	36	38	43	57	100

Príklad 219 (minimálny rozsah N) Vypočítajte minimálny rozsah N pre $p = 0.1, 0.2, \dots, 0.9$, p_0 vždy o 0.1 menšie ako p , pri $\alpha = 0.05$, $\beta = 0.8$ a obojstrannej alternatíve H_{11} . Skontrolujte, či je splnená Haldova podmienka. Ak nie je, doplňte minimálne N , ktoré túto podmienku spĺňa.

Riešenie (pozri tabuľku 6.5)Tabuľka 6.5: Minimálne rozsahy N pre rozdiel $p - p_0 = 0.1$ pri rôznych p a p_0 v porovnaní s minimálnym rozsahom vypočítaným pomocou Haldovej podmienky (tučne sú zvýraznené tie N , ktoré spĺňajú obe kritériá)

p	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
p_0	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8
$p(1-p)$	0.09	0.16	0.21	0.24	0.25	0.24	0.21	0.16	0.09
N	71	126	165	189	197	189	165	126	71
$Np(1-p)$	6.39	20.16	34.65	45.36	49.25	45.36	34.65	20.16	6.39
$9/(p(1-p))$	100	57	43	38	36	38	43	57	100

Príklad 220 (pravdepodobnosť pokrytia) Nech $X \sim \text{Bin}(N, p)$, kde $N = 30$ a $p = 0.8$ a pravdepodobnosť úspechu $\hat{p} = \frac{24}{30} = 0.8$, kde $x = 24$ a $N = 30$. Waldov 95% empirický DIS pre p je rovný $(d, h) = (0.657, 0.943)$. Vypočítajte pravdepodobnosť pokrytia tohoto intervalu. Pozn.: pravdepodobnosť pokrytia Waldovho 95% DIS pre p vypočítame nasledovne

$$\Pr(\text{pokrytie}) = \sum_j \Pr(X = Np_j : p \in \text{Waldov 95\% DIS pre } p_j),$$

kde $p_j \in \mathcal{M}_J = \{\frac{1}{30}, \frac{2}{30}, \dots, 1 - \frac{1}{30}\}$, t.j. ide o súčet takých funkčných hodnôt pravdepodobnostnej funkcie v bodoch Np_j , kde $p \in$ Waldovmu 95% DIS pre p_j . Výsledky usporiadajte do tabuľky, ktorej stĺpce budú x_j , p_j , d_j (dolná hranica Waldovho 95% DIS pre p_j), h_j (horná hranica Waldovho 95% DIS pre p_j), $\Pr(\text{pokrytie})$ a pokrytie (indikácia toho, či p patrí alebo nepatrí Waldovmu 95% DIS pre p_j).

Riešenie (aj v \mathbb{R})

Nech $X \sim \text{Bin}(30, 0.8)$. Pri $N = 30$ môže byť $x = 0, 1, \dots, 30$ (spolu 31 možností), a teda máme aj 31 možností aj pre p . Na zodpovedanie otázky ohľadom pravdepodobnosti pokrytia je potrebné vypočítať 95% empirický DIS pre každé p a z pravdepodobnostnej funkcie pre každé X vybrať také pravdepodobnosti korešpondujúce x , ktorých 95% empirický DIS pokrýva hodnotu 0.8.

```

1106 N <- 30
1107 x <- 0:N
1108 p.hat.j <- x/N
1109 DH <- p.hat.j - qnorm(0.975) * sqrt(p.hat.j * (1 - p.hat.j) / N)
1110 HH <- p.hat.j + qnorm(0.975) * sqrt(p.hat.j * (1 - p.hat.j) / N)
1111 p.hat <- 0.8
1112 prav.fcia <- dbinom(x, N, p.hat)
1113 pokrytie <- (p.hat > DH) & (p.hat < HH) # vektor 0 a 1
1114 round(cbind(x, p.hat.j, DH, HH, prav.fcia, pokrytie), 4)
1115 sum(dbinom(x[pokrytie], N, p.hat)) # 0.9463279

```

Pravdepodobnosť pokrytia Waldovho 95% empirický DIS pre $p = 0.8$ je rovná $\sum_{x=19}^{27} \Pr(X = x) = 0.946$. V prípade, že $p = 0.79$ je už pravdepodobnosť pokrytia len 0.888.

Príklad 221 (pravdepodobnosť pokrytia) Nech $X_i \sim \text{Bin}(N, p_i)$. Vypočítajte pravdepodobnosti pokrytia Waldovho 95% DIS pre každé p_i , kde p_i patria množine $\mathcal{M}_I = \langle \frac{1}{N}, 1 - \frac{1}{N} \rangle$, sú ekvidistantne vzdialené medzi $\frac{1}{N}$ a $1 - \frac{1}{N}$ a ich počet $M = 5000$. Nakreslite obrázok, kde na osi x budú p_i a na osi y pravdepodobnosť pokrytia $\Pr_i(\text{pokrytie})$. Zvoľte (a) $N = 30$, (b) $N = 100$ a (c) $N = 1000$. Pozn.: pravdepodobnosti pokrytia Waldovho 95% DIS pre p_i vypočítame nasledovne

$$\Pr_i(\text{pokrytie}) = \sum_j \Pr(X = Np_j : p_i \in \text{Waldov 95\% DIS pre } p_j),$$

kde $p_j \in \mathcal{M}_J = \{\frac{1}{N}, \frac{2}{N}, \dots, 1 - \frac{1}{N}\}$, t.j. ide o súčet takých funkčných hodnôt pravdepodobnostnej funkcie v bodoch Np_j , kde $p_i \in \text{Waldovmu 95\% DIS pre } p_j$.


Riešenie (aj v \mathbb{R} ; pozri obrázok 6.9)

```

1116 N <- 30
1117 x <- 0:N
1118 p.hat.j <- x/N
1119 sd.p.j <- sqrt(p.hat.j*(1-p.hat.j)/N)
1120 DH <- p.hat.j+qnorm(0.975)*sd.p.j
1121 HH <- p.hat.j-qnorm(0.975)*sd.p.j
1122 M = 5000
1123 p.hat.i <- seq(1/N,1-1/N,length=M)
1124 p.pokrytie.i <- numeric(M)
1125 for (i in 1:M)
1126 {
1127   pokrytie.i <- (p.hat.i[i]>DH)&(p.hat.i[i]<HH)
1128   prav.fcia <- dbinom(x[pokrytie.i],N,p.hat.i[i])
1129   p.pokrytie.i[i] <- sum(prav.fcia)
1130 }
1131 windows(8,8)
1132 plot(p.hat.i,p.pokrytie.i,type="n",xlab="p",ylab="pravdepodobnost_pokrytia",
1133      sub="N=30",ylim=c(0.6,1))
1134 lines(c(1/N,1-1/N),c(0.95,0.95),lwd=2,col="gray")
1135 lines(p.hat.i,p.pokrytie.i,lwd=2)

```

Zo simulačnej štúdie Waldovho DIS pre p vyplýva (pozri obrázok 6.9), že aktuálne hodnoty pravdepodobnosti pokrytia sú závislé na hodnote p a sú dostatočne blízko nominálnej hodnote $1 - \alpha = 0.95$ len pre p dostatočne ďaleko od nuly a jednotky (t.j. n a p nie príliš malé alebo veľké). Ak je N dostatočne veľké, aktuálne hodnoty pravdepodobnosti pokrytia sú dostatočne blízko nominálnej hodnote pre p takmer na celom intervale $(0, 1)$. Tento DIS je príliš liberálny pre malé N a je liberálny pre stredne veľké N .



Obr. 6.9: Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p ; $N = 30$ (vľavo), 100 (uprostred) a $N = 1000$ (vpravo)

Príklad 222 (pravdepodobnosť pokrytia) *Nech $X_i \sim \text{Bin}(N, p_i)$. Vypočítajte pravdepodobnosti pokrytia:*

- vierohodnostného 95% DIS,
- skóre 95% DIS,

(c) spätne transformovaného Waldovho 95% DIS pre $g(p_i)$ s hranicami $(d_g^{(i)}, h_g^{(i)})$ na Waldov 95% DIS pre p_i s hranicami $((g(d_g^{(i)}))^{-1}, (g(h_g^{(i)}))^{-1})$, kde (1) $g(p_i) = \frac{p_i}{1-p_i}$, (2) $g(p_i) = \ln \frac{p_i}{1-p_i}$ a (3) $g(p_i) = \arcsin(\sqrt{p_i})$


pre každé p_i , kde p_i patria množine $\mathcal{M}_I = \langle \frac{1}{N}, 1 - \frac{1}{N} \rangle$, sú ekvidištantne vzdialené medzi $\frac{1}{N}$ a $1 - \frac{1}{N}$ a ich počet $M = 5000$. Nakreslite obrázok, kde na x-ovej osi budú p_i a na y-ovej osi pravdepodobnosť pokrytia $\Pr_i(\text{pokrytie})$. Zvoľte (a) $N = 30$, (b) $N = 100$ a (c) $N = 1000$ (pozri obrázky 6.10 až 6.14).

Pozn.: pravdepodobnosti pokrytia 95% DIS pre p_i vypočítame nasledovne

$$\Pr_i(\text{pokrytie}) = \sum_j \Pr(X = Np_j : p_i \in \text{95\% DIS pre } p_j),$$


kde $p_j \in \mathcal{M}_J = \left\{ \frac{1}{N}, \frac{2}{N}, \dots, 1 - \frac{1}{N} \right\}$, t.j. ide o súčet takých funkčných hodnôt pravdepodobnostnej funkcie v bodoch Np_j , kde $p_i \in 95\%$ DIS pre p_j . Pre tie DIS, ktoré majú pre $p = 0$ a $p = 1$ nenulovú šírku, môžeme použiť $\mathcal{M}_I = \left\langle \frac{0}{N}, \frac{N}{N} \right\rangle$.

Zo simulačnej štúdie vierohodnostného DIS pre p vyplýva (pozri obrázok 6.10), že aktuálne hodnoty pravdepodobnosti pokrytia sú závislé na hodnote p a sú dostatočne blízko nominálnej hodnote $1 - \alpha = 0.95$. Pre veľmi malé a veľké n (resp. veľmi malé a veľké p) vznikajú okrajové efekty výrazného zníženia pravdepodobnosti pokrytia.



Obr. 6.10: Pravdepodobnosť pokrytia skóre 95% empirického DIS pre p pri rôznych N

Zo simulačnej štúdie skóre DIS pre p vyplýva (pozri obrázok 6.11), že aktuálne hodnoty pravdepodobnosti pokrytia sú závislé na hodnote p , ale aj pre malé a veľké n (resp. malé a veľké p) sú dostatočne blízko nominálnej hodnote $1 - \alpha = 0.95$ (t.j. nevznikajú okrajové efekty výrazného zníženia pravdepodobnosti pokrytia).




Obr. 6.11: Pravdepodobnosť pokrytia vierohodnostného 95% empirického DIS pre p pri rôznych N

Zo simulačnej štúdie spätné transformovaných Waldových DIS pre p vyplýva (pozri obrázok 6.12 až 6.14), že aktuálne hodnoty pravdepodobnosti pokrytia závisia od transformácie nasledovne:


1. spätná transformovaného DIS pre šancu – tento DIS je príliš liberálny pre malé N ; je liberálny pre stredne veľké N ; tento DIS nepoužiteľný pre veľké p , ktoré nám dáva veľkú šancu („použiteľnosť“ veľkého p sa zväčšuje s rastúcim N);
2. spätná transformovaného DIS pre logaritmus šance – aktuálne hodnoty pravdepodobnosti pokrytia tohoto DIS sú dostatočne blízko nominálnej hodnote pre p ďalej od hraníc intervalu $(0, 1)$ už pre malé a stredne veľké N ; pre p blízko hraníc intervalu 0 a 1 je mierne konzervatívny nezávisle na N ;

3. spätná transformovaného DIS pre $\arcsin \sqrt{p}$ – tento DIS je liberálny pre malé N ; aktuálne hodnoty pravdepodobnosti pokrytia tohoto DIS sú dostatočne blízko nominálnej hodnote pre p ďalej od hraníc intervalu $(0, 1)$ už pre stredne veľké N ; pre p blízko hraníc intervalu 0 a 1 je mierne liberálny nezávisle na N .

Ak je N dostatočne veľké, aktuálne hodnoty pravdepodobnosti pokrytia všetkých troch DIS sú dostatočne blízko nominálnej hodnote pre p takmer na celom intervale $(0, 1)$.



Obr. 6.12: Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p pri $N = 30$; spätné transformovaný DIS pre šancu (vľavo), spätné transformovaný DIS pre logaritmus šance (uprostred) a spätné transformovaný DIS pre $\arcsin \sqrt{p}$ (vpravo)




Obr. 6.13: Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p pri $N = 100$; spätné transformovaný DIS pre šancu (vľavo), spätné transformovaný DIS pre logaritmus šance (uprostred) a spätné transformovaný DIS pre $\arcsin \sqrt{p}$ (vpravo)

Asymptotické testy o parametri λ Poissonovho rozdelenia. Nech $X \sim Poiss(\lambda)$. Majme dvojice hypotéz $H_{01} : \lambda = \lambda_0$ oproti $H_{11} : \lambda \neq \lambda_0$, $H_{02} : \lambda \leq \lambda_0$ oproti $H_{12} : \lambda > \lambda_0$, $H_{03} : \lambda \geq \lambda_0$ oproti $H_{13} : \lambda < \lambda_0$, ktoré chceme testovať.

Ak H_0 platí, potom

$$Z_W = \frac{\bar{X} - \lambda_0}{\sqrt{\bar{X}/N}} \overset{\mathcal{D}}{\sim} N(0, 1),$$

Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **jednovýberový Z-test** o λ .



Obr. 6.14: Pravdepodobnosť pokrytia Waldovho 95% empirického DIS pre p pri $N = 1000$; spätne transformovaný DIS pre šancu (vľavo), spätne transformovaný DIS pre logaritmus šance (uprostred) a spätne transformovaný DIS pre $\arcsin \sqrt{p}$ (vpravo)

Definícia 64 (Kritický obor a silofunkcia pre Z_W test o λ) Kritický obor a silofunkcia sú definované nasledovne:

H_0	H_1	\mathcal{W}	$1 - \beta(\lambda)$
$\lambda = \lambda_0$	$\lambda \neq \lambda_0$	$\mathcal{W}_1 = \{Z_W; Z_W \geq u(\alpha/2)\}$	$1 - \Phi\left(u_{\alpha/2} - \frac{ \lambda_0 - \lambda }{\sqrt{\lambda/N}}\right)$
$\lambda \leq \lambda_0$	$\lambda > \lambda_0$	$\mathcal{W}_2 = \{Z_W; Z_W \geq u(\alpha)\}$	$1 - \Phi\left(u_\alpha + \frac{\lambda_0 - \lambda}{\sqrt{\lambda/N}}\right)$
$\lambda \geq \lambda_0$	$\lambda < \lambda_0$	$\mathcal{W}_3 = \{Z_W; Z_W \leq -u(\alpha)\}$	$1 - \Phi\left(u_\alpha - \frac{\lambda_0 - \lambda}{\sqrt{\lambda/N}}\right)$

Definícia 65 (p-hodnota pre Z_W test o λ) Nech Z_W je nejaká testovacia štatistika a $z_W = \frac{\bar{x} - \lambda_0}{\sqrt{\bar{x}/N}}$ je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : \lambda \neq \lambda_0 \\ Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : \lambda > \lambda_0 \\ Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : \lambda < \lambda_0 \end{cases}$$

Definícia 66 (Waldove $100 \times (1 - \alpha)\%$ empirické IS pre λ) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre λ pre všetky tri typy hypotéz majú nasledovný tvar:

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\lambda = \lambda_0$	$\lambda \neq \lambda_0$	$CS_{1-\alpha} = \left\{ \lambda_0 : \lambda_0 \in \left(\bar{x} - u_{\alpha/2} \sqrt{\bar{x}/N}, \bar{x} + u_{\alpha/2} \sqrt{\bar{x}/N} \right) \right\}$
$\lambda \leq \lambda_0$	$\lambda > \lambda_0$	$CS_{1-\alpha} = \left\{ \lambda_0 : \lambda_0 \in \left(\bar{x} - u_\alpha \sqrt{\bar{x}/N}, \infty \right) \right\}$
$\lambda \geq \lambda_0$	$\lambda < \lambda_0$	$CS_{1-\alpha} = \left\{ \lambda_0 : \lambda_0 \in \left(-\infty, \bar{x} + u_\alpha \sqrt{\bar{x}/N} \right) \right\}$

Majme H_{11} . Minimálny rozsah je definovaný ako

$$N \geq \left(\frac{u_{\alpha/2} + u_\beta}{\lambda - \lambda_0} \right)^2 \lambda.$$

Pre H_{12} a H_{13} zameníme v oboch prípadoch $u_{\alpha/2}$ za u_α .

Majme H_{01} oproti H_{11} . Nech $X \sim Poiss(\lambda)$, kde $\theta = \lambda$, potom logaritmus virohodnostnej funkcie bude mať tvar $l(\lambda|\mathbf{x}) = \sum_{i=1}^N x_i \ln \lambda - N\lambda$.

Skóre testovaciú štatistiku U_S odvodíme nasledovne

$$U_S = \frac{[\frac{\partial}{\partial \lambda} \ln L(\lambda|\mathbf{X})]^2}{\mathcal{I}(\lambda)} = \frac{\left(\frac{N\bar{X}}{\lambda} - N\right)^2}{\frac{N\lambda}{\lambda^2}} \stackrel{\lambda=\lambda_0}{=} \frac{(\bar{X} - \lambda_0)^2}{\lambda_0/N} \stackrel{\mathcal{D}}{\sim} \chi_1^2.$$

Skóre $100 \times (1 - \alpha)\%$ empirický DIS pre λ má tvar $\mathcal{CS}_{1-\alpha} = \{|Z_S| \leq u_{\alpha/2}\}$, kde $Z_S = \frac{\bar{X} - \lambda_0}{\sqrt{\lambda_0/N}}$.

Po niekoľkých algebraických úpravách môžeme $\mathcal{CS}_{1-\alpha}$ prepísať do kvadratickej nerovnice

$$\mathcal{CS}_{1-\alpha} = \left\{ \lambda_0 : \lambda_0^2 - (2\bar{x} + u_{\alpha/2}^2/N)\lambda_0 + \bar{x}^2 \leq 0 \right\}.$$

Korene tejto nerovnice definujú hranice DIS nasledovne

$$\frac{2\bar{x} + u_{\alpha/2}^2/N \pm \sqrt{(2\bar{x} + u_{\alpha/2}^2/N)^2 - 4\bar{x}^2}}{2}.$$

Po ďalších úpravách dostaneme DIS v tvare

$$\bar{x} + \frac{1}{2} \frac{u_{\alpha/2}^2}{N} \pm u_{\alpha/2} \sqrt{\frac{1}{N} \left(\bar{x} + \frac{u_{\alpha/2}^2}{4N} \right)}.$$

Test pomerom virohodnosti pre λ .

MLE θ je rovný $\hat{\lambda} = \bar{x}$, t.j. $\Theta_1 = \{\theta : \lambda \neq \lambda_0\}$. Za platnosti H_{01} je $\theta_0 = \lambda_0$, t.j. $\Theta_0 = \{\theta : \lambda = \lambda_0\}$. Potom -1 krát prirodzený logaritmus pomeru virohodnosti bude rovný

$$-\ln(\lambda(\mathbf{x})) = l(\hat{\lambda}|\mathbf{x}) - l(\lambda_0|\mathbf{x}) = (N\bar{x} \ln \bar{x} - N\bar{x}) - (N\bar{x} \ln \lambda_0 - N\lambda_0) = N \left(\bar{x} \ln \frac{\bar{x}}{\lambda_0} - \bar{x} + \lambda_0 \right).$$

Vieme, že **testovacia štatistika pomerom virohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X})) \stackrel{\mathcal{D}}{\sim} \chi_1^2$.

Virohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre λ bude mať tvar $\mathcal{CS}_{1-\alpha} = \{\lambda_0 : U_{LR} \leq \chi_1^2(\alpha)\}$.

Príklad 223 (pruské armádne jednotky) Majme $X \sim Poiss(\lambda)$; pozri príklad 78, tabuľka 2.7. Vypočítajte (a) Waldov 95% DIS pre λ , (b) skóre 95% DIS pre λ a (c) virohodnostný 95% DIS pre λ .

Riešenie v \mathbb{R}

Výpočet $\hat{\lambda}$ a $Var(\hat{\lambda})$ pozri v príkladoch 131 a 134. Waldov 95% DIS pre λ : $(d, h) = (0.502, 0.718)$. Skóre 95% DIS pre λ : $(d, h) = (0.511, 0.728)$. Virohodnostný 95% DIS pre λ : $(d, h) = (0.508, 0.725)$.

```

1136 m <- c(109,65,22,3,1,0); n <- c(0,1,2,3,4,5); N <- sum(m)
1137 lambda.hat <- sum(n*m)/N # 0.61
1138 var.lambda.hat <- lambda.hat/N # 0.003057
1139 IS.W <- lambda.hat+c(-1,1)*qnorm(0.975)*sqrt(var.lambda.hat)
1140 IS.S <- lambda.hat+1/2*qnorm(0.975)^2/N+c(-1,1)*qnorm(0.975)*
1141 sqrt(1/N*(lambda.hat+qnorm(0.975)^2/(4*N)))
1142 IS.W # 0.5017575 0.7182425
1143 IS.S # 0.5109359 0.7282714
1144 min.lambda <- lambda.hat-3*sqrt(var.lambda.hat)
1145 max.lambda <- lambda.hat+3*sqrt(var.lambda.hat)
1146 lambda.oi <- seq(min.lambda, max.lambda, by=0.0001)
1147 uLR.i <- 2*N*(lambda.hat*log(lambda.hat/lambda.oi)-lambda.hat+lambda.oi)
1148 plot(lambda.oi, uLR.i)
1149 lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
1150 IS.LR <- range(lambda.oi[which(uLR.i<lr.krit.hodn)])
1151 IS.LR # 0.5081196 0.7247196

```


7 Testovanie hypotéz o dvoch parametroch

V tejto kapitole sa budeme venovať testovaniu hypotéz o rozdiel stredných hodnôt $\mu_1 - \mu_2$ za predpokladov normality, t.j. $X_j \sim N(\mu_j, \sigma_j^2)$, $j = 1, 2$, $\bar{X}_1 - \bar{X}_2 \sim N(\mu_1 - \mu_2, \sigma_D^2)$, o podiele rozptylov σ_1^2/σ_2^2 za predpokladov normality, t.j. $X_j \sim N(\mu_j, \sigma_j^2)$, $j = 1, 2$, o rozdiel korelačných koeficientov $\rho_1 - \rho_2$, za predpokladov normality, t.j. $(X_j, Y_j)^T \sim N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, $j = 1, 2$, a o rozdiel pravdepodobností $p_1 - p_2$, za predpokladov $X \sim \text{Bin}(N_1, p_1)$ a $Y \sim \text{Bin}(N_2, p_2)$.

7.1 Asymptotické testy o rozdiel stredných hodnôt

Testovanie rozdielov dvoch stredných hodnôt spojitaj premennej patrí medzi najčastejšie úlohy, s ktorými sa biologický antropológ stretáva. Základné zdroje dát totiž v antropológii často tvoria normálne rozdelené metrické premenné (rozmary) na kontinúálnej (spojitej) škále, ktorých variabilita je multifaktoriálne podmienená a z genetického hľadiska predstavujú polygénne znaky. Nemúsi ísť zďaleka len o rozmary tela, ale o rôzne ukazovatele fyzického výkonu (sila stisku ruky), psychických vlastností (skóre v psychologickom dotazníku), spôsobe správania (reakčná doba na určitý podnet) i iných vlastností. Typickou úlohou je porovnanie stredných hodnôt výberov dvoch prirodzených alebo zámerné definovaných skupín danej populácie: muži vs. ženy (*sexuálny dimorfizmus*), Poliaci vs. Nemci (*etnický rozdiel*), dvadsaťroční v 60. rokoch 20. storočia vs. dvadsaťroční v 80. rokoch 20. storočia (*rozdiel vekových kohort, sekulárny trend*), nižšia sociálna vrstva vs. stredná sociálna vrstva (*sociálne rozdiely*), vysokoškooláci vs. stredoškooláci (*rozdiely v stupni vzdelania*), prvoroďičky vs. druoroďičky (*rozdiely v parite*), kresťania vs. moslimovia (*rozdiely vo vyznaní*), sila pravej paže vs. sila paže ľavej (*stranová asymetria sily*) atď. Vzhľadom na štatistickú kvalitu tohto typu premenných (najväčšie množstvo informácií) a súčasne univerzálnosť, prirodzenosť a jednoduchosť tohto typu porovnávaní/uvažovaní (jedna skupina voči druhej z hľadiska strednej hodnoty veľkosti daného znaku) je tento typ testov vôbec jeden z najdôležitejších vo fyzickej antropológii.

Množstvo foriem/úrovní rôznych dvojíc viac či menej prirodzených skupín, ktorých stredné hodnoty možno porovnávať a rozdiel testovať, otvára priestor pre celú škálu situácií, ktoré môžu nastať. Dané dve skupiny sa nemusia zhodovať v rozptyle, nemusia mať zhodné rozdelenie hodnôt, môžu byť zaťažené chybou merania v rôznej miere, môžu pochádzať z častí populácie s veľmi odlišnou celkovou veľkosťou (praváci vs. ľaváci; homosexuáli vs. heterosexuáli; matky s jedným dieťaťom vs. matky s desiatimi deťmi). Tieto rozdiely v ďalších ohľadoch problematizujú symetriu medzi testovanými skupinami z hľadiska vzorkovania a ekvivalencie porovnávaní po stránke rovnocennosti oboch vzoriek.

Nech $X_j \sim N(\mu_j, \sigma_j^2)$, $j = 1, 2$, sú dve nezávislé náhodné premenné. Potom

$$\bar{X}_1 - \bar{X}_2 \stackrel{\mathcal{D}}{\sim} N(\mu_1 - \mu_2, \sigma_D^2).$$

Majme dvojice hypotéz $H_{01} : \mu_1 - \mu_2 = \mu_0$ oproti $H_{11} : \mu_1 - \mu_2 \neq \mu_0$, $H_{02} : \mu_1 - \mu_2 \leq \mu_0$ oproti $H_{12} : \mu_1 - \mu_2 > \mu_0$, $H_{03} : \mu_1 - \mu_2 \geq \mu_0$ oproti $H_{13} : \mu_1 - \mu_2 < \mu_0$.


Nech σ_j^2 sú známe. Ak H_0 platí, potom

$$Z_W = \frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{\sigma_D} \stackrel{\mathcal{D}}{\sim} N(0, 1),$$

kde $\sigma_D^2 = \sigma_1^2/n_1 + \sigma_2^2/n_2$. V špeciálnom prípade $\sigma^2 = \sigma_1^2 = \sigma_2^2$ a môžeme písať $\sigma_D^2 = \sigma^2/n_1 + \sigma^2/n_2 = \frac{n_1+n_2}{n_1n_2}\sigma^2$. Navyše v niektorých praktických situáciách môže nastať $n = n_1 = n_2$, kde $\sigma_D^2 = \frac{1}{n}(\sigma_1^2 + \sigma_2^2)$, keď nepredpokladáme rovnosť rozptylov, resp. $\sigma_D^2 = \frac{2n}{n^2}\sigma^2 = \frac{2}{n}\sigma^2$, keď rovnosť rozptylov predpokladáme. Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojvýberový Z-test o rozdiel stredných hodnôt** $\mu_1 - \mu_2$.

Definícia 67 (Kritický obor a silofunkcia Z_W testu o $\mu_1 - \mu_2$) Kritický obor a silofunkcia sú definované (za predpokladu $\sigma_1 = \sigma_2$ a $n_1 = n_2$) nasledovne (pozri obrázok 7.1):

H_0	H_1	\mathcal{W}	$1 - \beta(\mu_1, \mu_2)$
$\mu_1 - \mu_2 = \mu_0$	$\mu_1 - \mu_2 \neq \mu_0$	$\mathcal{W}_1 = \{Z_W; Z_W \geq u(\alpha/2)\}$	$1 - \Phi\left(u_{\alpha/2} - \frac{ \mu_0 - (\mu_1 - \mu_2) }{\sigma_D}\right)$
$\mu_1 - \mu_2 \leq \mu_0$	$\mu_1 - \mu_2 > \mu_0$	$\mathcal{W}_2 = \{Z_W; Z_W \geq u(\alpha)\}$	$1 - \Phi\left(u_\alpha + \frac{\mu_0 - (\mu_1 - \mu_2)}{\sigma_D}\right)$
$\mu_1 - \mu_2 \geq \mu_0$	$\mu_1 - \mu_2 < \mu_0$	$\mathcal{W}_3 = \{Z_W; Z_W \leq -u(\alpha)\}$	$1 - \Phi\left(u_\alpha - \frac{\mu_0 - (\mu_1 - \mu_2)}{\sigma_D}\right)$



Obr. 7.1: Silofunkcie Waldovho testu o $\mu_1 - \mu_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 68 (p-hodnota Z_W testu o $\mu_1 - \mu_2$) Nech Z_W je nejaká testovacia štatistika a $z_W = \frac{\bar{x}_1 - \bar{x}_2 - \mu_0}{\sigma_D}$ je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11}: \mu_1 - \mu_2 \neq \mu_0 \\ Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12}: \mu_1 - \mu_2 > \mu_0 \\ Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13}: \mu_1 - \mu_2 < \mu_0 \end{cases}$$

Definícia 69 (Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $\mu_1 - \mu_2$) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $\mu_1 - \mu_2$ pre všetky tri typy hypotéz majú nasledovný tvar:

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\mu = \mu_0$	$\mu \neq \mu_0$	$\mathcal{CS}_{1-\alpha} = \{\mu_0 : \mu_0 \in (\bar{x}_1 - \bar{x}_2 - u_{\alpha/2}\sigma_D, \bar{x}_1 - \bar{x}_2 + u_{\alpha/2}\sigma_D)\}$
$\mu \leq \mu_0$	$\mu > \mu_0$	$\mathcal{CS}_{1-\alpha} = \{\mu_0 : \mu_0 \in (\bar{x}_1 - \bar{x}_2 - u_\alpha\sigma_D, \infty)\}$
$\mu \geq \mu_0$	$\mu < \mu_0$	$\mathcal{CS}_{1-\alpha} = \{\mu_0 : \mu_0 \in (-\infty, \bar{x}_1 - \bar{x}_2 + u_\alpha\sigma_D)\}$

Majme H_{11} . Zvoľme rozdiel $|\mu_1 - \mu_2| = c\sigma_D$. Minimálny rozsah n_1 definujeme nasledovne:

$$n_1 \geq \left(\frac{u_{\alpha/2} + u_\beta}{c}\right)^2 = \left(\frac{u_{\alpha/2} + u_\beta}{\mu_1 - \mu_2 - \mu_0}\right)^2 \left(\sigma_1^2 + \frac{\sigma_2^2}{k}\right), n_2 = kn_1.$$

Pre H_{12} a H_{13} zameníme v oboch prípadoch $u_{\alpha/2}$ za u_α .

Príklad 224 (minimálny rozsah súboru) Predpokladajme, že v roku 1986 sme zistili priemernú výšku 10-ročných dievčat ako $\bar{x}_{1986} = 136.1$ cm. V roku 1996 už bol $\bar{x}_{1996} = 139.225$ cm. Ďalej predpokladajme, že rozptyl $\sigma^2 = 6.25^2$. Pokiaľ by sme v roku 2006 v porovnaní s rokom 1996 chceli rozdiel

139.225 – 136.100 = 3.125 odhaliť s pravdepodobnosťou 0.90, teda s $\beta = 0.1$ na hladine významnosti $\alpha = 0.05$, aký minimálny rozsah n musí mať náhodný výber?

Riešenie v \mathbb{R}

1152 | $k < -1$
1153 | $n1 < - \text{ceiling}(((\text{qnorm}(0.975) + \text{qnorm}(0.9)) / (3.125))^2 * (6.25^2 + 6.25^2 / k)) \# 85$

Nech σ_j^2 sú neznáme. Ak H_0 platí, potom

$$T_W = \frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S_D} \stackrel{\mathcal{D}}{\sim} t_{df},$$

a rozdelenie t_{df} sa nazýva **centrálne t -rozdelenie s df stupňami voľnosti**. Pre $\sigma_1^2 = \sigma_2^2$ platí $df = n_1 + n_2 - 2$ a pre $\sigma_1^2 \neq \sigma_2^2$ platí

$$df = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{\left(\frac{S_1^2}{n_1}\right)^2}{n_1-1} + \frac{\left(\frac{S_2^2}{n_2}\right)^2}{n_2-1}},$$

$S_D^2 = S_1^2/n_1 + S_2^2/n_2$, S_1^2 a S_2^2 sú výberové rozptyly. V špeciálnom prípade predpokladáme $S_1^2 = S_2^2$ a môžeme písať $S_D^2 = \frac{n_1+n_2}{n_1 n_2} S^2$, kde $S^2 = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}$. Navyše v niektorých praktických situáciách môže nastať $n = n_1 = n_2$, kde $S_D^2 = \frac{1}{n} (S_1^2 + S_2^2)$, keď nepredpokladáme rovnosť rozptylov, resp. $S_D^2 = \frac{2}{n} S^2$, keď rovnosť rozptylov predpokladáme. T_W sa nazýva **Waldova testovacia štatistika** (alebo **t -štatistika**) a test **dvojvýberový Studentov t -test o rozdiel stredných hodnôt** $\mu_1 - \mu_2$. Za predpokladu rovnosti rozptylov hovoríme o **klasickom dvojvýberovom t -teste**. Za predpokladu nerovnosti rozptylov, hovoríme o **Welchovom dvojvýberovom t -teste** (alebo **dvojvýberovom Studentovom t -teste s Welchovou aproximáciou stupňov voľnosti**) a problém nerovnosti rozptylov hovoríme **Behrens-Fisherov problém** (Welch, 1947). Ak $n_1 = n_2$ a $\sigma_1^2 = \sigma_2^2 = \sigma^2$ sú neznáme, potom Welchova aproximácia df je rovná $2n - 2$ a Welchov t -test je ekvivalentný Studentovmu t -testu.

Ak H_0 neplatí, náhodné výbery sú vyvážené ($n_1 = n_2 = n$) a rozptyly rovnaké ($\sigma_1^2 = \sigma_2^2 = \sigma^2$), táto situácia vedie k necentrálnemu t -rozdeleniu s parametrom necentrality $\lambda = \delta / (\sqrt{2}\sigma) \sqrt{n}$, kde $\delta = \mu_1 - \mu_2 - \mu_0$ je minimálne detegovateľná vzdialenosť medzi μ_1 a μ_2 . Pri $n_1 \neq n_2$ a $\sigma_1^2 \neq \sigma_2^2$, táto situácia vedie tiež k necentrálnemu t -rozdeleniu, kde parameter necentrality $\lambda = \delta / \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$.

Ak predpokladáme $n_1 \neq n_2$ ($n_1 + n_2 = n$), predefinujeme T_W nasledovne

$$T_W = \sqrt{\frac{n_1 n_2}{n_1 + n_2}} \left(\frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S} \right) = \sqrt{n \times w_1 w_2} \left(\frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S} \right) \stackrel{\mathcal{D}}{\sim} t_{df},$$


kde $\frac{n_1 n_2}{n_1 + n_2} = \frac{n w_1 \times n w_2}{n} = n \times w_1 w_2$, $w_j = n_j / n$, $j = 1, 2$. Ak H_0 neplatí, táto situácia vedie k **necentrálnemu t -rozdeleniu** s df stupňami voľnosti a parametrom necentrality λ , ozn. $t_{df, \lambda}$, kde

$$T_{W, \lambda} = \sqrt{n \times w_1 w_2} \left(\frac{\bar{X}_1 - \bar{X}_2 - \mu}{S} \right) \stackrel{\mathcal{D}}{\sim} t_{df, \lambda},$$

kde parameter necentrality $\lambda = \sqrt{n \times w_1 w_2} (\delta / \sigma)$ a $\delta = \mu_1 - \mu_2 - \mu_0$ je **minimálne detegovateľná vzdialenosť** medzi rozdielom $\mu_1 - \mu_2$ a μ_0 .

Definícia 70 (Kritický obor a silofukcia T_W testu o $\mu_1 - \mu_2$) Kritický obor a silofukcia sú definované (za platnosti $\sigma_1 = \sigma_2$ a $n_1 = n_2$) nasledovne (pozri obrázok 7.2):

H_0	H_1	\mathcal{W}	$1 - \beta(\mu_1, \mu_2)$
$\mu_1 - \mu_2 = \mu_0$	$\mu_1 - \mu_2 \neq \mu_0$	$\mathcal{W}_1 = \{T_W; T_W \geq t_{df}(\alpha/2)\}$	$\Pr(F_{1, df, \lambda^2} \geq F_{1, df}(\alpha))$
$\mu_1 - \mu_2 \leq \mu_0$	$\mu_1 - \mu_2 > \mu_0$	$\mathcal{W}_2 = \{T_W; T_W \geq t_{df}(\alpha)\}$	$\Pr(t_{df, \lambda} \geq t_{df}(\alpha))$
$\mu_1 - \mu_2 \geq \mu_0$	$\mu_1 - \mu_2 < \mu_0$	$\mathcal{W}_3 = \{T_W; T_W \leq -t_{df}(\alpha)\}$	$\Pr(t_{df, \lambda} \leq t_{df}(1 - \alpha))$

Obr. 7.2: Silofunkcie Waldovho testu o $\mu_1 - \mu_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 71 (p-hodnota T_W testu o $\mu_1 - \mu_2$) Nech T_W je nejaká testovacia štatistika a $t_W = \frac{\bar{x}_1 - \bar{x}_2 - \mu_0}{s_D}$ je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2Pr(T_W \geq |t_W| | H_{01}), & \text{ak } H_{11} : \mu_1 - \mu_2 \neq \mu_0 \\ Pr(T_W \geq t_W | H_{02}), & \text{ak } H_{12} : \mu_1 - \mu_2 > \mu_0 \\ Pr(T_W \leq t_W | H_{03}), & \text{ak } H_{13} : \mu_1 - \mu_2 < \mu_0 \end{cases}$$

Definícia 72 $100 \times (1 - \alpha)\%$ empirické IS pre $\mu_1 - \mu_2$ $100 \times (1 - \alpha)\%$ empirické IS pre $\mu_1 - \mu_2$ pre všetky tri typy hypotéz majú nasledovný tvar

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\mu = \mu_0$	$\mu \neq \mu_0$	$CS_{1-\alpha} = \{\mu_0 : \mu_0 \in (\bar{x}_1 - \bar{x}_2 - t_{df}(\alpha/2)s_D, \bar{x}_1 - \bar{x}_2 + t_{df}(\alpha/2)s_D)\}$
$\mu \leq \mu_0$	$\mu > \mu_0$	$CS_{1-\alpha} = \{\mu_0 : \mu_0 \in (\bar{x}_1 - \bar{x}_2 - t_{df}(\alpha)s_D, \infty)\}$
$\mu \geq \mu_0$	$\mu < \mu_0$	$CS_{1-\alpha} = \{\mu_0 : \mu_0 \in (-\infty, \bar{x}_1 - \bar{x}_2 + t_{df}(\alpha)s_D)\}$

Dvojvýberový Studentov t -test o rozdiel stredných hodnôt $\mu_1 - \mu_2$ v \mathbb{R} (funkcia **t.test()).** Argumenty (vstupy) funkcie:

1. vektory dát x a y ;
2. alternatíva `alternative="two.sided"` je prednastavená, ďalšie voľby sú "greater", "less";
3. rovnosť rozptylov `var.equal=TRUE` alebo `var.equal=FALSE`;
4. stredná hodnota za platnosti nulovej hypotézy μ_0 , t.j. μ_0 ;
5. spoľahlivosť `conf.level=p`, prednastavené je $p = .95$.

Výstupy funkcie:

1. názov použitého testu `method`;
2. testovacia štatistika `statistic`;
3. počet stupňov voľnosti `df` parameter;
4. p-hodnota `p.value`;
5. alternatívna hypotéza `alternative hypothesis`;

6. interval spoľahlivosti rozdielu $\mu_1 - \mu_2$ conf.int;

7. bodové odhady (aritmetické priemery \bar{x}_1 a \bar{x}_2) sample estimates.

Príklad 225 (pravdepodobnosť pokrytia ak $\sigma_1^2 = \sigma_2^2$ sú neznáme) Nech $X_j \sim N(\mu_j, \sigma^2)$, kde $j = 1, 2$, $\mu_1 = 20$, $\mu_2 = 35$ a $\sigma^2 = 100$. Pomocou simulačnej štúdie ($M = 100000$) vypočítajte pravdepodobnosť pokrytia 95% DIS pre $\mu_1 - \mu_2$ ako podiel $\sum_{m=1}^M I(t_{W,m} < t_{df}(\alpha/2)) / M$, kde $t_{W,m}$ sú testovacie štatistiky klasického dvojvýberového t -testu. Zvoľte (a) $n = 5$, (b) $n = 50$ a (c) $n = 100$.

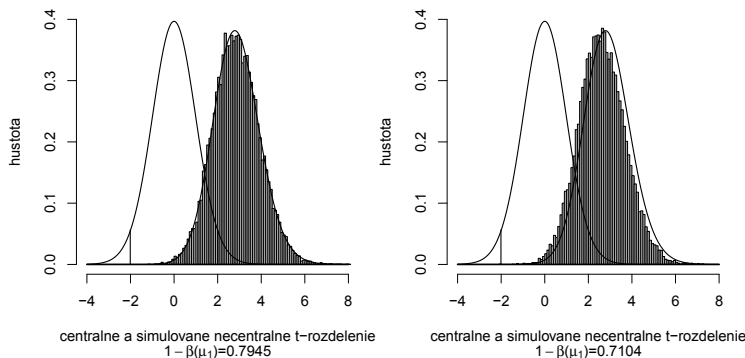
Príklad 226 (pravdepodobnosť pokrytia ak $\sigma_1^2 \neq \sigma_2^2$ sú neznáme) Nech $X_j \sim N(\mu_j, \sigma_j^2)$, kde $j = 1, 2$, $\mu_1 = 20$, $\mu_2 = 35$, $\sigma_1^2 = 100$ a $\sigma_2^2 = 150$. Pomocou simulačnej štúdie ($M = 100000$) vypočítajte pravdepodobnosť pokrytia 95% DIS pre $\mu_1 - \mu_2$ ako podiel $\sum_{m=1}^M I(t_{W,m} < t_{df}(\alpha/2)) / M$, kde $t_{W,m}$ sú (1) testovacie štatistiky klasického dvojvýberového t -testu a (2) testovacie štatistiky Welchovho dvojvýberového t -testu. Zvoľte (a) $n = 5$, (b) $n = 50$ a (c) $n = 100$.

Príklad 227 (pravdepodobnosť pokrytia ak $\sigma_1^2 = \sigma_2^2$ sú neznáme) Nech $X_j \sim [pN(\mu_j, \sigma^2) + (1-p)N(\mu_j, \sigma_a^2)]$, kde $p = 0.9$, $j = 1, 2$, $\mu_1 = 20$, $\mu_2 = 35$, $\sigma^2 = 100$ a $\sigma_a^2 = 400$. Pomocou simulačnej štúdie ($M = 100000$) vypočítajte pravdepodobnosť pokrytia 95% DIS pre $\mu_1 - \mu_2$ ako podiel $\sum_{m=1}^M I(t_{W,m} < t_{df}(\alpha/2)) / M$, kde $t_{W,m}$ sú testovacie štatistiky klasického dvojvýberového t -testu. Zvoľte (a) $n = 5$, (b) $n = 50$ a (c) $n = 100$.

Príklad 228 (pravdepodobnosť pokrytia ak $\sigma_1^2 \neq \sigma_2^2$ sú neznáme) Nech $X_j \sim [pN(\mu_j, \sigma_j^2) + (1-p)N(\mu_j, \sigma_{ja}^2)]$, kde $p = 0.9$, $j = 1, 2$, $\mu_1 = 20$, $\mu_2 = 35$, $\sigma_1^2 = 100$, $\sigma_2^2 = 150$, $\sigma_{1a}^2 = 400$ a $\sigma_{2a}^2 = 450$. Pomocou simulačnej štúdie ($M = 100000$) vypočítajte pravdepodobnosť pokrytia 95% DIS pre $\mu_1 - \mu_2$ ako podiel $\sum_{m=1}^M I(t_{W,m} < t_{df}(\alpha/2)) / M$, kde $t_{W,m}$ sú (1) testovacie štatistiky klasického dvojvýberového t -testu a (2) testovacie štatistiky Welchovho dvojvýberového t -testu. Zvoľte (a) $n = 5$, (b) $n = 50$ a (c) $n = 100$.

Príklad 229 (sila a silofunkcia testu rozdielu stredných hodnôt) Použite \mathbb{R} na simuláciu hustoty rozdelenia testovacej štatistiky $T_{df,\lambda}$ dvojvýberového testu rozdielu stredných hodnôt $\mu_1 - \mu_2$ za platnosti dvojstrannej alternatívy H_{11} pri $M = 20000$ opakovaníach. Túto hustotu v podobe histogramu v relatívnej škále zakreslite do obrázka a superponujte ju s teoretickou hustotou. Vypočítajte silu za platnosti alternatívy H_{11} : $\mu_1 - \mu_2 = 2$, kde $n_1 = n_2 = 25$. Použite (a) klasický dvojvýberový t -test a (b) Welchov dvojvýberový t -test. (1) $X_1 \sim N(4, 2.5^2)$, $X_2 \sim N(2, 2.5^2)$ a (2) $X_1 \sim [pN(4, 2.5^2) + (1-p)N(4, 4.5^2)]$, $X_2 \sim N(2, 4.5^2)$, kde $p = 0.9$.

Riešenie (a) pozri na obrázku 7.3.



Obr. 7.3: Hustota centrálneho a necentrálneho t -rozdelenia; vľavo – hustota necentrálneho t -rozdelenia je superponovaná histogramom simulácií pre $X_1 \sim N(4, 2.5^2)$, $X_2 \sim N(2, 2.5^2)$ a vpravo – pre $X_1 \sim [pN(4, 2.5^2) + (1-p)N(4, 4.5^2)]$, $X_2 \sim N(2, 4.5^2)$, kde $p = 0.9$

Test pomerom vierohodnosti pre $\mu_1 - \mu_2$.

Budeme rozlišovať tri základné situácie – (1) σ_1^2, σ_2^2 sú rôzne a známe, (2) σ_1^2, σ_2^2 sú rovnaké a neznáme a (3) σ_1^2, σ_2^2 sú rôzne a neznáme.

Nech $X_1 \sim N(\mu_1, \sigma_1^2)$ a $X_2 \sim N(\mu_2, \sigma_2^2)$, kde $\theta = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)^T$ a σ_1^2, σ_2^2 sú rôzne a známe. Odhad θ je rovný $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2)^T$, kde $\hat{\mu}_1 = \bar{x}_1, \hat{\mu}_2 = \bar{x}_2$, t.j. $\Theta_1 = \{\theta : \mu_1 \neq \mu_2\}$. Za platnosti H_{01} je $\theta_0 = (\hat{\mu}, \hat{\mu}, \hat{\sigma}_1^2, \hat{\sigma}_2^2)^T$, t.j. $\Theta_0 = \{\theta : \mu_1 = \mu_2\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) &= l(\hat{\theta}|\mathbf{x}_1, \mathbf{x}_2) - l(\theta_0|\mathbf{x}_1, \mathbf{x}_2) \\ &= \left(-\frac{1}{2\sigma_1^2} \sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 \right) \\ &\quad - \left(-\frac{1}{2\sigma_1^2} \sum_{i=1}^{n_1} (x_{1i} - \hat{\mu})^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^{n_2} (x_{2j} - \hat{\mu})^2 \right) \\ &= \frac{1}{2\sigma_1^2} \left(\sum_{i=1}^{n_1} (x_{1i} - \hat{\mu})^2 - \sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 \right) \\ &\quad + \frac{1}{2\sigma_2^2} \left(\sum_{j=1}^{n_2} (x_{2j} - \hat{\mu})^2 - \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 \right), \end{aligned}$$

kde

$$\hat{\mu} = \frac{\sum_{i=1}^{n_1} x_{1i} + \gamma \sum_{j=1}^{n_2} x_{2j}}{n_1 + \gamma n_2}, \text{ kde } \gamma = \frac{\sigma_1^2}{\sigma_2^2}.$$

Použitím rovnosti

$$\sum_{i=1}^{n_1} (x_{1i} - \hat{\mu})^2 = \sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 + n_1(\bar{x}_1 - \hat{\mu})^2 \text{ a } \sum_{j=1}^{n_2} (x_{2j} - \hat{\mu})^2 = \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 + n_2(\bar{x}_2 - \hat{\mu})^2$$

dostaneme

$$-\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) = \frac{n_1}{2\sigma_1^2} (\hat{\mu} - \bar{x}_1)^2 + \frac{n_2}{2\sigma_2^2} (\hat{\mu} - \bar{x}_2)^2.$$

Potom

$$\hat{\mu} - \bar{x}_1 = \frac{n_1 \sum_{i=1}^{n_1} x_{1i} + n_1 \gamma \sum_{j=1}^{n_2} x_{2j} - n_2 \sum_{i=1}^{n_1} x_{1i} - \gamma n_2 \sum_{j=1}^{n_2} x_{2j}}{n_1(n_1 + \gamma n_2)} = \frac{\gamma n_2 (\bar{x}_2 - \bar{x}_1)}{n_1 + \gamma n_2}$$

a

$$\hat{\mu} - \bar{x}_2 = \frac{n_1 (\bar{x}_1 - \bar{x}_2)}{n_1 + \gamma n_2}.$$

Nakoniec

$$\begin{aligned} -\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) &= \frac{n_1}{2\sigma_1^2} \frac{\gamma^2 n_2^2 (\bar{x}_2 - \bar{x}_1)^2}{(n_1 + \gamma n_2)^2} + \frac{n_2}{2\sigma_2^2} \frac{n_1^2 (\bar{x}_2 - \bar{x}_1)^2}{(n_1 + \gamma n_2)^2} \\ &= \frac{n_1 n_2 (\bar{x}_2 - \bar{x}_1)^2}{2(n_1 + \gamma n_2)^2} \left(\frac{\gamma^2 n_2}{\sigma_1^2} + \frac{n_1}{\sigma_2^2} \right). \end{aligned}$$

Ak položíme $\gamma = 1$, dostaneme

$$-\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) = \frac{n_1 n_2 (\bar{x}_2 - \bar{x}_1)^2}{2n^2} \left(\frac{n_2}{\sigma_1^2} + \frac{n_1}{\sigma_2^2} \right).$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{X}_2)) \stackrel{\mathcal{D}}{\sim} \chi_1^2$, kde H_0 bude zamietnutá pre veľké hodnoty rozdielu $|\bar{x}_2 - \bar{x}_1|$. Dá sa ukázať, že u_{LR} je rastúcou funkciou $|z_W|$.

Nech $X_1 \sim N(\mu_1, \sigma^2)$ a $X_2 \sim N(\mu_2, \sigma^2)$, kde $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma^2)^T$ a σ^2 je neznáma. Logaritmus funkcie vierohodnosti má tvar

$$l(\boldsymbol{\theta}|\mathbf{x}_1, \mathbf{x}_2) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \left(\sum_{i=1}^{n_1} (x_{1i} - \mu_1)^2 + \sum_{j=1}^{n_2} (x_{2j} - \mu_2)^2 \right),$$

kde $n = n_1 + n_2$. MLE $\boldsymbol{\theta}$ je rovný $\hat{\boldsymbol{\theta}} = (\hat{\mu}_1, \hat{\mu}_2, \tilde{\sigma}^2)^T$, kde

$$\hat{\mu}_1 = \bar{x}_1, \hat{\mu}_2 = \bar{x}_2, \tilde{\sigma}^2 = \frac{1}{n} \left(\sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 + \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 \right),$$

t.j. $\Theta_1 = \{\boldsymbol{\theta} : \mu_1 \neq \mu_2\}$. Za platnosti H_{01} je $\hat{\boldsymbol{\theta}}_0 = (\hat{\mu}, \hat{\mu}, \tilde{\sigma}_0^2)^T$ platí

$$\hat{\mu} = \frac{1}{n} \left(\sum_{i=1}^{n_1} x_{1i} + \sum_{j=1}^{n_2} x_{2j} \right) = \frac{n_1 \bar{x}_1 + n_2 \bar{x}_2}{n}$$

a

$$\begin{aligned} \tilde{\sigma}_0^2 &= \frac{1}{n} \left(\sum_{i=1}^{n_1} (x_{1i} - \hat{\mu})^2 + \sum_{j=1}^{n_2} (x_{2j} - \hat{\mu})^2 \right) \\ &= \frac{1}{n} \left(\sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 + \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 + \frac{n_1 n_2}{n} (\bar{x}_1 - \bar{x}_2)^2 \right), \end{aligned}$$

kde

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^{n_1} (x_{1i} - \hat{\mu})^2 &= \frac{1}{n} \sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 + \frac{n_1}{n} (\bar{x}_1 - \hat{\mu})^2, \\ \frac{1}{n} \sum_{j=1}^{n_2} (x_{2j} - \hat{\mu})^2 &= \frac{1}{n} \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 + \frac{n_2}{n} (\bar{x}_2 - \hat{\mu})^2 \end{aligned}$$

získame z rovnosti $(x_{1i} - \hat{\mu})^2 = ((x_{1i} - \bar{x}_1) + (\bar{x}_1 - \hat{\mu}))^2$ (a podobne pre x_{2j}). Tiež platí $\Theta_0 = \{\boldsymbol{\theta} : \mu_1 = \mu_2 = \mu\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$-\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) = \frac{n}{2} \ln \left(1 + \frac{\frac{n_1 n_2}{n} (\bar{x}_1 - \bar{x}_2)^2}{\sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 + \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2} \right) = \frac{n}{2} \ln \left(\frac{\tilde{\sigma}_0^2}{\tilde{\sigma}^2} \right).$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{X}_2)) \stackrel{D}{\sim} \chi_1^2$, kde H_0 bude zamietnutá pre veľké hodnoty podielu $\frac{\tilde{\sigma}_0^2}{\tilde{\sigma}^2}$.

Modifikovaním u_{LR} , kde $\tilde{\sigma}^2$ substituujeme

$$s^2 = \frac{n}{n-2} \tilde{\sigma}^2 = \frac{1}{n-2} \left(\sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 + \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 \right),$$

dostaneme u_{LR} , ktorá je rastúcou funkciou $|t_W|$ a $|\bar{x}_1 - \bar{x}_2|$. Potom

$$u_{LR} = n \ln \left(1 + \frac{t_W^2}{n-2} \right).$$

Nech $X \sim N(\mu_1, \sigma_1^2)$ a $Y \sim N(\mu_2, \sigma_2^2)$, kde $\theta = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)^T$ a σ_1^2, σ_2^2 sú rôzne a neznáme. Jadro logaritmu funkcie vierohodnosti je rovné

$$l(\theta|\mathbf{x}_1, \mathbf{x}_2) = -\frac{1}{2\sigma_1^2} \sum_{i=1}^{n_1} (x_{1i} - \mu_1)^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^{n_2} (x_{2j} - \mu_2)^2.$$

Nech σ_1^2, σ_2^2 sú neznáme. Odhad θ je rovný $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2)^T$, kde

$$\hat{\mu}_1 = \bar{x}_1, \hat{\mu}_2 = \bar{x}_2, \hat{\sigma}_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2, \hat{\sigma}_2^2 = \frac{1}{n_2} \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2,$$

t.j. $\Theta_1 = \{\theta : \mu_1 \neq \mu_2\}$. Za platnosti H_{01} je $\theta_0 = (\hat{\mu}, \hat{\mu}, \hat{\sigma}_1^2, \hat{\sigma}_2^2)^T$, t.j. $\Theta_0 = \{\theta : \mu_1 = \mu_2\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) &= l(\hat{\theta}|\mathbf{x}_1, \mathbf{x}_2) - l(\theta_0|\mathbf{x}_1, \mathbf{x}_2) \\ &= \left(-\frac{1}{2\hat{\sigma}_1^2} \sum_{i=1}^{n_1} (x_{1i} - \bar{x}_1)^2 - \frac{1}{2\hat{\sigma}_2^2} \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2 \right) \\ &\quad - \left(-\frac{1}{2\hat{\sigma}_1^2} \sum_{i=1}^{n_1} (x_{1i} - \hat{\mu})^2 - \frac{1}{2\hat{\sigma}_2^2} \sum_{j=1}^{n_2} (x_{2j} - \hat{\mu})^2 \right) \\ &= \left(-\frac{n_1\hat{\sigma}_1^2}{2\hat{\sigma}_1^2} - \frac{n_2\hat{\sigma}_2^2}{2\hat{\sigma}_2^2} \right) - \left(-\frac{n_1\hat{\sigma}_1^2}{2\hat{\sigma}_1^2} - \frac{n_2\hat{\sigma}_2^2}{2\hat{\sigma}_2^2} - \frac{n_1(\bar{x}_1 - \hat{\mu})^2}{2\hat{\sigma}_1^2} - \frac{n_2(\bar{x}_2 - \hat{\mu})^2}{2\hat{\sigma}_2^2} \right) \\ &= \frac{n_1(\bar{x}_1 - \hat{\mu})^2}{2\hat{\sigma}_1^2} + \frac{n_2(\bar{x}_2 - \hat{\mu})^2}{2\hat{\sigma}_2^2}, \end{aligned}$$

kde potom dosadením $\gamma = \hat{\sigma}_1^2/\hat{\sigma}_2^2$ a po použití identického postupu ako v prípade, kde σ_1^2 a σ_2^2 sú známe, dostaneme

$$-\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) = \frac{n_1 n_2 (\bar{x}_2 - \bar{x}_1)^2}{2(n_1 + \gamma n_2)^2} \left(\frac{\gamma^2 n_2}{\hat{\sigma}_1^2} + \frac{n_1}{\hat{\sigma}_2^2} \right).$$

Ak položíme $\gamma = 1$, dostaneme

$$-\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) = \frac{n_1 n_2 (\bar{x}_2 - \bar{x}_1)^2}{2n^2} \left(\frac{n_2}{\hat{\sigma}_1^2} + \frac{n_1}{\hat{\sigma}_2^2} \right).$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{X}_2)) \stackrel{D}{\sim} \chi_1^2$, kde H_0 bude zamietnutá pre veľké hodnoty rozdielu $|\bar{x}_2 - \bar{x}_1|$. Dá sa ukázať, že u_{LR} je rastúcou funkciou $|t_W|$.

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre $\mu_1 - \mu_2$ bude mať tvar

$$CS_{1-\alpha} = \{\mu_0 : U_{LR} < \chi_1^2(\alpha)\}.$$

Na výpočet tohoto DIS by sme museli reparametrizovať funkciu vierohodnosti na parameter záujmu $(\mu_1 - \mu_2)$ a rušivý parameter¹. Alternatívne by bolo možné vypočítať u_{LR} pre rôzne kombinácie μ_1 a μ_2 (na vhodne zvolených intervaloch) a pre tieto μ_j , $j = 1, 2$, vypočítať rozdiely $\mu_1 - \mu_2$. Potom $CS_{1-\alpha} = \{\mu_0 : U_{LR}(\mu_1 - \mu_2) < \chi_1^2(\alpha)\}$.

¹Namiesto reparametrizácie môžeme použiť upravenú testovaciu štatistiku u_{LR} , kde $\bar{x}_1 - \bar{x}_2$ substituujeme $\bar{x}_1 - \bar{x}_2 - \mu_0$; μ_0 patrí vhodne zvolenému intervalu, na ktorom hľadáme μ_0 vyhovujúce nerovnosti $U_{LR}(\mu_0) < \chi_1^2(\alpha)$.

Príklad 230 (test o rozdiel stredných hodnôt μ_1 a μ_2) Majme dáta *two-samples-means-birth.txt*, premennú pôrodná hmotnosť novorodencov (chlapcov, narodených v krajskej nemocnici v priebehu jedného roka) *birth.W* v gramoch a premennú počet starších súrodencov *o.sib.N*, ktorá nadobúda hodnoty 0 (žiadny) a 1 (jeden). Predpokladáme, že premenná *birth.W* chlapcov bez staršieho súrodenca má normálne rozdelenie $N(\mu_1, \sigma_1^2)$ a *birth.W* chlapcov s jedným starším súrodencom má normálne rozdelenie $N(\mu_2, \sigma_2^2)$. (a) Otestujte hypotézu o zhode stredných hodnôt μ_1 a μ_2 na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre rozdiel stredných hodnôt $\mu_1 - \mu_2$, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku T_W za predpokladu (1.1) rovnosti a (1.2) nerovnosti rozptylov, (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} za predpokladu (2.1) rovnosti a (2.2) nerovnosti rozptylov a DIS prislúchajúce (1.1), (1.2), (2.1) a (2.2).

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : stredná hodnota pôrodnej hmotnosti chlapcov bez staršieho súrodenca je zhodná so strednou hodnotou pôrodnej hmotnosti chlapcov s jedným starším súrodencom oproti H_1 : stredná hodnota pôrodnej hmotnosti chlapcov bez staršieho súrodenca nie je zhodná so strednou hodnotou pôrodnej hmotnosti chlapcov s jedným starším súrodencom.
- **matematická formulácia** – $H_0 : \mu_1 - \mu_2 = \mu_0$ oproti $H_1 : \mu_1 - \mu_2 \neq \mu_0$, kde $\mu_0 = 0$.

2. **Testovacia štatistika** – Stredné hodnoty μ_j a rozptyly σ_j^2 , kde $j = 1, 2$, sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú aritmetické priemery $\bar{x}_1 \doteq 3127.68$, $\bar{x}_2 \doteq 3194.20$ a rozptyly $s_1^2 \doteq 440261.80$ (smerodajná odchýlka $s_1 \doteq 663.52$), $s_2^2 \doteq 516335.7$ (smerodajná odchýlka $s_2 \doteq 718.565$). Rozdiel $\bar{x}_1 - \bar{x}_2 \doteq -66.53$.

```

1154 DATA <- read.table("two-samples-means-birth.txt", header=TRUE)
1155 names(DATA)
1156 ## "o.sib.N" "birth.W"
1157 attach(DATA)
1158 birth.W.0 <- birth.W[o.sib.N==0]
1159 birth.W.1 <- birth.W[o.sib.N==1]
1160 n.0 <- length(birth.W.0) # 297
1161 n.1 <- length(birth.W.1) # 276
1162 n <- n.0+n.1 # 573
1163 priemer.0 <- mean(birth.W.0) # 3127.677
1164 rozptyl.0 <- var(birth.W.0) # 440261.8
1165 smerodch.0 <- sd(birth.W.0) # 663.5223
1166 priemer.1 <- mean(birth.W.1) # 3194.203
1167 rozptyl.1 <- var(birth.W.1) # 516335.7
1168 smerodch.1 <- sd(birth.W.1) # 718.565
1169 priemer.diff <- priemer.0-priemer.1 # -66.52613

```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $t_W \doteq -1.152$ (ak $\sigma_1^2 = \sigma_2^2$).

Waldova testovacia štatistika $t_W \doteq -1.149$ (ak $\sigma_1^2 \neq \sigma_2^2$).

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 1.330$ (ak $\sigma_1^2 = \sigma_2^2$).

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 1.320$ (ak $\sigma_1^2 \neq \sigma_2^2$).

```

1170 W.test <- t.test(birth.W.0, birth.W.1, var=TRUE)
1171 W.test.welch <- t.test(birth.W.0, birth.W.1, var=FALSE)
1172 tW.obs <- W.test$stat # -1.152217
1173 tW.obs.welch <- W.test.welch$stat # -1.148857
1174 mu.hat <- (sum(birth.W.0)+sum(birth.W.1))/n # 3159.721
1175 sigma.sq.tilde <- (sum((birth.W.0-priemer.0)^2)+
1176 sum((birth.W.1-priemer.1)^2))/n # 475235.3
1177 sigma0.sq.tilde <- (sum((birth.W.0-mu.hat)^2)+sum((birth.W.1-mu.hat)^2))/n # 476340.2
1178 uLR.obs <- n*log(sigma0.sq.tilde/sigma.sq.tilde) # 1.330707
1179 sigmad.sq <- (sum((birth.W.0-priemer.0)^2)+sum((birth.W.1-priemer.1)^2))/(n-2)
1180 tWt.obs <- (priemer.diff-0)/sqrt(sigmad.sq)*sqrt(n.0*n.1/(n.0+n.1))
1181 uWt.obs <- tWt.obs^2
1182 uLRt.obs <- n*log(1+uWt.obs/(n-2)) # 1.330707
1183 gama <- (n.0-1)/n.0*rozptyl.0/((n.1-1)/n.1*rozptyl.1) # 0.852885
1184 uLR.obs.2 <- n.0*n.1*(priemer.1-priemer.0)^2/((n.0+gama*n.1)^2)*((gama^2*n.1)/((n.0-1)/n.0*rozptyl.0)+
1185 n.0/((n.1-1)/n.1*rozptyl.1)) # 1.324522

```

3. Zamietacia oblasť –

Waldov test (ak $\sigma_1^2 = \sigma_2^2$):

kritické hodnoty $t_{n-2}(1 - \alpha/2) = t_{571}(1 - 0.025) \doteq -1.9641$ a $t_{n-2}(\alpha/2) = t_{571}(0.025) \doteq 1.9641$;
kritický obor $\mathcal{W}_1 = (t_{\min}, t_{n-2}(1 - \alpha/2)) \cup (t_{n-2}(\alpha/2), t_{\max}) = (-\infty, -1.9641) \cup (1.9641, \infty)$.

Waldov test (ak $\sigma_1^2 \neq \sigma_2^2$):

kritické hodnoty $t_{df}(1 - \alpha/2) = t_{df}(1 - 0.025) \doteq -1.9642$ a $t_{df}(\alpha/2) = t_{df}(0.025) \doteq 1.9642$;
kritický obor $\mathcal{W}_1 = (t_{\min}, t_{df}(1 - \alpha/2)) \cup (t_{df}(\alpha/2), t_{\max}) \doteq (-\infty, -1.9642) \cup (1.9642, \infty)$,

kde $df \doteq 557.986$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), t_{\max}) \doteq (3.841, \infty)$.

```
1186 | W.test$parameter # 571
1187 | t.krit.d <- qt(0.025, df=W.test$parameter) # -1.964127
1188 | t.krit.h <- qt(0.975, df=W.test$parameter) # 1.964127
1189 | W.test.welch$parameter # 557.9862
1190 | t.krit.d.welch <- qt(0.025, df=W.test.welch$parameter) # -1.964225
1191 | t.krit.h.welch <- qt(0.975, df=W.test.welch$parameter) # 1.964225
1192 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov $100 \times (1 - \alpha)\%$ empirický DIS $\doteq 95\%$ empirický DIS pre μ (ak $\sigma_1^2 = \sigma_2^2$):

$(d, h) \doteq (-179.93, 46.88)$.

Waldov 95% empirický DIS pre μ (ak $\sigma_1^2 \neq \sigma_2^2$):

$(d, h) \doteq (-180.27, 47.21)$.

Vierohodnostný 95% empirický DIS pre μ (ak $\sigma_1^2 = \sigma_2^2$):

$\mathcal{CS}_{0.95} = \{\mu_0 : u_{LR}(\mu_0) < \chi_1^2(\alpha)\} \doteq (-179.68, 46.62)$.

Vierohodnostný 95% empirický DIS pre μ (ak $\sigma_1^2 \neq \sigma_2^2$):

$\mathcal{CS}_{0.95} = \{\mu_0 : u_{LR}(\mu_0) < \chi_1^2(\alpha)\} \doteq (-179.82, 46.76)$.

```
1193 | IS.W <- W.test$conf.int # -179.92997 46.87771
1194 | IS.W.welch <- W.test.welch$conf.int # -180.26719 47.21493
1195 | min.mu <- -3*sqrt(sigmad.sq)
1196 | max.mu <- 3*sqrt(sigmad.sq)
1197 | mu.0.i <- seq(min.mu, max.mu, by = 0.01)
1198 | tW.obs.i <- (priemer.diff - mu.0.i) / sqrt(sigmad.sq) * sqrt(n.0 * n.1 / (n.0 + n.1))
1199 | uW.obs.i <- tW.obs.i ^ 2
1200 | uLR.i <- n * log(1 + uW.obs.i / (n - 2))
1201 | IS.LR <- range(mu.0.i[which(uLR.i < lr.krit.hodn)]) # -179.67937 46.62063
1202 | uLR.i.2 <- n.0 * n.1 * (priemer.diff - mu.0.i) ^ 2 / ((n.0 + gama * n.1) ^ 2) *
1203 | ((gama ^ 2 * n.1) / ((n.0 - 1) * n.0 * rozptyl.0) +
1204 | n.0 / ((n.1 - 1) * n.1 * rozptyl.1))
1205 | IS.LR.2 <- range(mu.0.i[which(uLR.i.2 < lr.krit.hodn)]) # -179.8181 46.7619
```

5. Štatistický záver –

Waldov test (ak $\sigma_1^2 = \sigma_2^2$): p-hodnota $\doteq 2\Pr(T_W \geq | -1.152 | | H_0) = 0.250$.

Waldov test (ak $\sigma_1^2 \neq \sigma_2^2$): p-hodnota $\doteq 2\Pr(T_W \geq | -1.149 | | H_0) = 0.251$.

Test pomerom vierohodnosti (ak $\sigma_1^2 = \sigma_2^2$): p-hodnota $\doteq \Pr(U_{LR} \geq 1.330 | H_0) = 0.249$.

Test pomerom vierohodnosti (ak $\sigma_1^2 \neq \sigma_2^2$): p-hodnota $\doteq \Pr(U_{LR} \geq 1.320 | H_0) = 0.251$.

```
1206 | p.hodn.W <- W.test$p.val # 0.2497143
1207 | p.hodn.W.welch <- W.test.welch$p.val # 0.251107
1208 | p.hodn.LR <- 1 - pchisq(uLR.obs, df=1) # 0.2486795
1209 | p.hodn.LR.2 <- 1 - pchisq(uLR.obs.2, df=1) # 0.2497821
```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\mu_0 = 0$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. Slovný záver –

Nezamietame nulovú hypotézu o tom, že stredná hodnota pôrodnej hmotnosti chlapcov bez staršieho súrodenca je zhodná so strednou hodnotou pôrodnej hmotnosti chlapcov s jedným starším súrodencom.

7. Antropologický slovný záver –

Napriek tomu, že pôrodná hmotnosť prvorođených chlapcov bez staršieho súrodenca je v priemere číselne nižšia než u novorođených chlapcov s jedným starším súrodencom, rozdiel nie je štatisticky významný. V našej vzorke sa teda nepodarilo dokázať obvyklé nachádzaný stav, ktorý vyplýva z rozdielov medzi matkami v kapacite reprodukčnej sústavy. Malý rozdiel môže byť daný kvalitou ako prenatalnej starostlivosti, tak výživy matiek a ďalšími civilizačnými faktormi, ktoré môžu obe skupiny zblížovať. Ďalšou príčinou môže byť skutočnosť, že ide o porovnanie dvoch nezávislých vzoriek, ktoré sa môžu líšiť genetickým pozadím (sociálne

a etnickým zložením) i podmienkami prostredia. Nie sú tiež k dispozícii údaje o proporcii prirodzených pôrodov a pôrodov cisárskym rezom. Vhodným spôsobom realizácie výskumu by bolo párové porovnanie staršieho a mladšieho syna z jedného páru súrodencov tých istých rodičov, kde by bol vplyv nekontrolovaných faktorov obmedzenejší.

Príklad 231 (test o rozdiel stredných hodnôt μ_1 a μ_2) Majme dáta *two-samples-means-skull.txt*, premennú výška lebky *skull.H* v mm starovekej egyptskej populácii a premennú pohlavie *sex*, ktorá nadobúda hodnoty *m* (muž) a *f* (žena). Predpokladáme, že premenná *skull.H* mužov má normálne rozdelenie $N(\mu_1, \sigma_1^2)$ a *skull.H* žien má normálne rozdelenie $N(\mu_2, \sigma_2^2)$. (a) Otestujte hypotézu o zhode stredných hodnôt μ_1 a μ_2 na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre rozdiel stredných hodnôt $\mu_1 - \mu_2$, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku T_W za predpokladu (1.1) rovnosti a (1.2) nerovnosti rozptylov, (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} za predpokladu (2.1) rovnosti a (2.2) nerovnosti rozptylov a DIS prislúchajúce (1.1), (1.2), (2.1) a (2.2).

7.2 Asymptotické testy o podiele rozptylov

Ako bolo uvedené v úvodnom texte kapitoly 6.2, rozptyl hodnôt a jeho porovnanie medzi rôznymi výbermi má veľký význam pri odhaľovaní procesov, ktoré sa v kontexte daného znaku v populácii odohrávajú, resp. odohrávali v priebehu evolúcie. Testovanie rozdielov v rozptyle je preto dôležitým prostriedkom pri zisťovaní biologických rozdielov medzi dvoma populáciami. Na rozdiel od testovania rozptylu jednej vzorky s porovnávacou (tabelovou, publikovanou) hodnotou majú testy rozptylov dvoch výberov spracovaných v jednej štúdií tú výhodu, že obe vzorky boli získané rovnakou metodikou a rozdiely medzi nimi vypovedajú o porovnateľných zdrojoch variability (a snáď obdobnej miere vplyvu skutočných biologických rozdielov).

Nech $X_j \sim N(\mu_j, \sigma_j^2)$, $j = 1, 2$, sú dve nezávislé náhodné premenné. Majme dvojicu hypotéz $H_{01} : \sigma_1^2/\sigma_2^2 = \sigma_0$ oproti $H_{11} : \sigma_1^2/\sigma_2^2 \neq \sigma_0$, $H_{02} : \sigma_1^2/\sigma_2^2 \leq \sigma_0$ oproti $H_{21} : \sigma_1^2/\sigma_2^2 > \sigma_0$ a $H_{03} : \sigma_1^2/\sigma_2^2 \geq \sigma_0$ oproti $H_{13} : \sigma_1^2/\sigma_2^2 < \sigma_0$.

Ak H_0 platí a $\sigma_0 = 1$, potom

$$F_W = \frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} \stackrel{\mathcal{D}}{\sim} F_{n_1-1, n_2-1},$$

kde $S_j^2 = \frac{1}{n_j-1} \sum_{i=1}^{n_j} (X_{ji} - \bar{X}_j)^2$, $j = 1, 2$, a rozdelenie F_{df_1, df_2} sa nazýva **centrálne F -rozdelenie** s $df_1 = n_1 - 1$ a $df_2 = n_2 - 1$ **stupňami voľnosti**, n_1 a n_2 sú rozsahy náhodných výberov. F_W sa nazýva **Waldova testovacia štatistika** (alebo **F -štatistika**) a test **dvojjvýberový F -test o podiele rozptylov** σ_1^2/σ_2^2 .

Chceme nájsť kritickú hodnotu d_S^* za platnosti H_{02} , tak aby platilo $\Pr(S_1^2/S_2^2 < d_S^* | H_{02}) = \alpha$. Teda

$$\alpha = \Pr\left(\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} < d_S^* \frac{\sigma_2^2}{\sigma_1^2} | H_{02}\right) = \Pr(F_W < d_S^* | H_{02})$$

a z toho vyplýva, že $d_S^* = F_{n_1-1, n_2-1}(1 - \alpha)$. Ak H_{02} neplatí, t.j. skutočný rozptyl je σ_1^2/σ_2^2 , potom chceme nájsť pravdepodobnosť zamietnutia H_{02} (silu testu). To je pravdepodobnosť, že S_1^2/S_2^2 neprekročí d_S^* , teda

$$\begin{aligned} \Pr(S_1^2/S_2^2 < d_S^* | H_{12}) &= \Pr\left(\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} < d_S^* \frac{\sigma_2^2}{\sigma_1^2} | H_{12}\right) = \Pr\left(\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} < d_S^* \frac{\sigma_2^2}{\sigma_1^2} | H_{12}\right) \\ &= \Pr\left(F_W^{(\text{alt})} < F_{n_1-1, n_2-1}(1 - \alpha) \frac{\sigma_2^2}{\sigma_1^2} | H_{12}\right), \end{aligned}$$

kde $F_W^{(\text{alt})} = \frac{S_1^2}{S_2^2} \frac{\sigma_2^2}{\sigma_1^2}$.

Chceme nájsť kritickú hodnotu h_S^* za platnosti H_{03} , tak aby platilo $\Pr(S_1^2/S_2^2 < h_S^* | H_{03}) = 1 - \alpha$. Teda

$$1 - \alpha = \Pr\left(\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} < h_S^* \frac{\sigma_2^2}{\sigma_1^2} | H_{03}\right) = \Pr(F_W < h_S^* | H_{03})$$

a z toho vyplýva, že $h_S^* = F_{n_1-1, n_2-1}(\alpha)$. Ak H_{03} neplatí, t.j. skutočný rozptyl je σ_1^2/σ_2^2 , potom chceme nájsť pravdepodobnosť zamietnutia H_{03} (silu testu). To je pravdepodobnosť, že S_1^2/S_2^2 prekročí h_S^* , teda

$$\begin{aligned} \Pr(S_1^2/S_2^2 > h_S^* | H_{13}) &= \Pr\left(\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} > h_S^* \frac{\sigma_2^2}{\sigma_1^2} | H_{13}\right) = \Pr\left(\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} > h_S^* \frac{\sigma_2^2}{\sigma_1^2} | H_{13}\right) \\ &= \Pr\left(F_W^{(alt)} > F_{n_1-1, n_2-1}(\alpha) \frac{\sigma_2^2}{\sigma_1^2} | H_{13}\right). \end{aligned}$$

Ak by sme chceli nájsť kritické hodnoty d_S a h_S pre test H_{01} oproti H_{11} , použili by sme podobnú úvahu ako vyššie.

Príklad 232 Odvod'te vzorec na výpočet kritických hodnôt d_S a h_S pre H_{01} .

Definícia 73 (Kritický obor a silofunkcia F_W testu o σ_1^2/σ_2^2) Kritický obor a silofunkcia sú definované nasledovne (ozn. $d_{\alpha/2} = F_{n_1-1, n_2-1}(1 - \alpha/2)$, $h_{\alpha/2} = F_{n_1-1, n_2-1}(\alpha/2)$, $d_\alpha = F_{n_1-1, n_2-1}(1 - \alpha)$ a $h_\alpha = F_{n_1-1, n_2-1}(\alpha)$):

H_0	H_1	\mathcal{W}	$1 - \beta(\sigma_1^2/\sigma_2^2)$
$\sigma_1^2 = \sigma_2^2$	$\sigma_1^2 \neq \sigma_2^2$	$\mathcal{W}_1 = \{F_W; F_W \notin (d_{\alpha/2}, h_{\alpha/2})\}$	$1 - \Pr\left(\frac{\sigma_2^2}{\sigma_1^2} d_{\alpha/2} < F_W < \frac{\sigma_2^2}{\sigma_1^2} h_{\alpha/2}\right)$
$\sigma_1^2 \leq \sigma_2^2$	$\sigma_1^2 > \sigma_2^2$	$\mathcal{W}_2 = \{F_W; F_W \geq h_\alpha\}$	$\Pr\left(F_W^{(alt)} \geq \frac{\sigma_2^2}{\sigma_1^2} h\right)$
$\sigma_1^2 \geq \sigma_2^2$	$\sigma_1^2 < \sigma_2^2$	$\mathcal{W}_3 = \{F_W; F_W \leq d_\alpha\}$	$\Pr\left(F_W^{(alt)} \leq \frac{\sigma_2^2}{\sigma_1^2} d_\alpha\right)$

Definícia 74 (p-hodnota F_W testu o σ_1^2/σ_2^2) Nech F_W je *nejaká testovacia štatistika* a $F_{obs} = \frac{s_1^2}{s_2^2}$ je jej realizácia (*pozorovaná, vypočítaná testovacia štatistika*), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2 \min(\Pr(F_W \leq F_{obs} | H_{01}), \Pr(F_W \geq F_{obs} | H_{01})), & \text{ak } H_{11} : \sigma_1^2 \neq \sigma_2^2 \\ \Pr(F_W \geq F_{obs} | H_{02}), & \text{ak } H_{12} : \sigma_1^2 > \sigma_2^2 \\ \Pr(F_W \leq F_{obs} | H_{03}), & \text{ak } H_{13} : \sigma_1^2 < \sigma_2^2 \end{cases}$$

Definícia 75 (Waldove $100 \times (1 - \alpha)\%$ empirické IS pre σ_1^2/σ_2^2) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre σ_1^2/σ_2^2 pre všetky tri typy hypotéz majú nasledovný tvar (vieme, že platí $\frac{1}{F_{n_2-1, n_1-1}(1-\alpha/2)} = F_{n_1-1, n_2-1}(\alpha/2)$):

H_0	H_1	$\text{hranice } (d, h)$	pre $100(1 - \alpha)\%$ empirický IS
$\sigma_1^2/\sigma_2^2 = \sigma_0^2$	$\sigma_1^2/\sigma_2^2 \neq \sigma_0^2$	$\mathcal{CS}_{1-\alpha} = \left\{ \sigma_0^2 : \sigma_0^2 \in \left(\frac{s_1^2}{s_2^2 h_{\alpha/2}}, \frac{s_1^2}{s_2^2 d_{\alpha/2}} \right) \right\}$	
$\sigma_1^2/\sigma_2^2 \leq \sigma_0^2$	$\sigma_1^2/\sigma_2^2 > \sigma_0^2$	$\mathcal{CS}_{1-\alpha} = \left\{ \sigma_0^2 : \sigma_0^2 \in \left(\frac{s_1^2}{s_2^2 h_\alpha}, \infty \right) \right\}$	
$\sigma_1^2/\sigma_2^2 \geq \sigma_0^2$	$\sigma_1^2/\sigma_2^2 < \sigma_0^2$	$\mathcal{CS}_{1-\alpha} = \left\{ \sigma_0^2 : \sigma_0^2 \in \left(0, \frac{s_1^2}{s_2^2 d_\alpha} \right) \right\}$	

Minimálne rozsahy n_1, n_2 pre nejaký podiel σ_1^2/σ_2^2 (pri nejakom α a β) vypočítame iteratívne pomocou nasledovných rovností:

$$\begin{aligned} \frac{F_{n_1-1, n_2-1}(1-\beta)}{F_{n_1-1, n_2-1}(\alpha/2)} &\approx \frac{\sigma_2^2}{\sigma_1^2} \text{ za platnosti } H_{11}; \\ \frac{F_{n_1-1, n_2-1}(\beta)}{F_{n_1-1, n_2-1}(1-\alpha)} &= \frac{\sigma_2^2}{\sigma_1^2} \text{ za platnosti } H_{12}; \\ \frac{F_{n_1-1, n_2-1}(1-\beta)}{F_{n_1-1, n_2-1}(\alpha)} &= \frac{\sigma_2^2}{\sigma_1^2} \text{ za platnosti } H_{13}. \end{aligned}$$

Pri obojstrannej alternatíve ide o približný výpočet, kedy sa zanedbáva časť sily, ktorá predstavuje obsah pod dolnou kritickou hodnotou.

Dvojvýberový F -test o podiele rozptylov σ_1^2/σ_2^2 v \mathbb{R} (funkcia `var.test()`).

Argumenty (vstupy) funkcie:

1. vektory dát x a y ;
2. alternatíva `alternative="two.sided"` je prednastavená, ďalšie voľby sú "greater", "less";
3. podiel rozptylov za platnosti nulovej hypotézy `ratio`, t.j. σ_0^2 ;
4. spoľahlivosť `conf.level=p`, prednastavené je $p = .95$.

Výstupy funkcie:

1. názov použitého testu `method`;
2. testovacia štatistika `statistic`;
3. počet stupňov voľnosti `df` parameter (num df a denom df);
4. p -hodnota `p.value`;
5. alternatívna hypotéza `alternative hypothesis`;
6. interval spoľahlivosti podielu σ_1^2/σ_2^2 `conf.int`;
7. bodový odhad (podiel $\hat{\sigma}_1^2/\hat{\sigma}_2^2$) `estimate`.

Test pomerom vierohodnosti pre σ_1^2/σ_2^2 .

Nech $X_1 \sim N(\mu_1, \sigma_1^2)$ a $X_2 \sim N(\mu_2, \sigma_2^2)$, kde $\theta = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)^T$. Logaritmus funkcie vierohodnosti má tvar

$$l(\theta | \mathbf{x}_1, \mathbf{x}_2) = -\sum_{j=1}^2 \frac{n_j}{2} \ln(2\pi\sigma_j^2) - \sum_{j=1}^2 \frac{1}{2\sigma_j^2} \left(\sum_{i=1}^{n_j} (x_{ji} - \mu_j)^2 \right).$$

MLE θ je rovný $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2)^T$, kde

$$\hat{\mu}_j = \bar{x}_j, \hat{\sigma}_j^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (x_{ji} - \bar{x}_j)^2,$$

t.j. $\Theta_1 = \{\theta : \sigma_1^2 \neq \sigma_2^2 \neq \sigma^2\}$. Za platnosti H_{01} je $\theta_0 = (\hat{\mu}_1, \hat{\mu}_2, \tilde{\sigma}^2, \tilde{\sigma}^2)^T$, kde (pozri Mood a kol., 1987)

$$\tilde{\sigma}^2 = \frac{\sum_{j=1}^2 n_j \hat{\sigma}_j^2}{\sum_{j=1}^2 n_j},$$

t.j. $\Theta_0 = \{\theta : \sigma_1^2 = \sigma_2^2 = \sigma^2\}$. Logaritmus funkcie vierohodnosti pre $\hat{\theta}$ bude mať tvar

$$\begin{aligned} l(\hat{\theta} | \mathbf{x}_1, \mathbf{x}_2) &= -\sum_{j=1}^2 \frac{n_j}{2} \ln(2\pi\hat{\sigma}_j^2) - \sum_{j=1}^2 \frac{1}{2\hat{\sigma}_j^2} \left(\sum_{i=1}^{n_j} (x_{ji} - \mu_j)^2 \right) \\ &= -\sum_{j=1}^2 \frac{n_j}{2} \ln(2\pi\hat{\sigma}_j^2) - \sum_{j=1}^2 \frac{n_j \hat{\sigma}_j^2}{2\hat{\sigma}_j^2}. \end{aligned}$$

Logaritmus funkcie vierohodnosti pre θ_0 bude mať tvar

$$\begin{aligned} l(\theta_0 | \mathbf{x}_1, \mathbf{x}_2) &= -\sum_{j=1}^2 \frac{n_j}{2} \ln(2\pi\tilde{\sigma}^2) - \sum_{j=1}^2 \frac{1}{2\tilde{\sigma}^2} \left(\sum_{i=1}^{n_j} (x_{ji} - \mu_j)^2 \right) \\ &= -\sum_{j=1}^2 \frac{n_j}{2} \ln(2\pi\tilde{\sigma}^2) - \frac{1}{\tilde{\sigma}^2} \sum_{j=1}^2 \frac{n_j \hat{\sigma}_j^2}{2} \end{aligned}$$

Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) &= l(\hat{\theta} | \mathbf{x}_1, \mathbf{x}_2) - l(\theta_0 | \mathbf{x}_1, \mathbf{x}_2) \\ &= -\sum_{j=1}^2 \frac{n_j}{2} \ln \hat{\sigma}_j^2 - \sum_{j=1}^2 \frac{n_j}{2} + \sum_{j=1}^2 \frac{n_j}{2} \ln \left(\frac{\sum_{i=1}^2 n_i \hat{\sigma}_i^2}{\sum_{i=1}^2 n_i} \right) + \sum_{j=1}^2 \frac{n_j}{2} \\ &= \frac{1}{2} \sum_{j=1}^2 n_j \ln \left(\frac{\sum_{i=1}^2 n_i \hat{\sigma}_i^2}{\hat{\sigma}_j^2 \sum_{i=1}^2 n_i} \right). \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{X}_2)) \stackrel{\mathcal{D}}{\sim} \chi_1^2$.

Vierohodnostný $100 \times (1 - \alpha)\%$ **empirický DIS** pre σ_1^2/σ_2^2 bude mať tvar

$$\mathcal{CS}_{1-\alpha} = \{ \sigma_0^2 : U_{LR} < \chi_1^2(\alpha) \}.$$

Na výpočet tohoto DIS by sme museli reparametrizovať funkciu vierohodnosti na parameter záujmu (σ_1^2/σ_2^2) a rušivý parameter. Alternatívne by bolo možné vypočítať u_{LR} pre rôzne kombinácie σ_1^2 a σ_2^2 (na vhodne zvolených intervaloch) a pre tieto σ_j^2 , $j = 1, 2$, vypočítať podiely σ_1^2/σ_2^2 . Potom $\mathcal{CS}_{1-\alpha} = \{ \sigma_0^2 : U_{LR}(\sigma_1^2/\sigma_2^2) < \chi_1^2(\alpha) \}$.

Príklad 233 (test o podiele rozptylov σ_1^2 a σ_2^2) *Majme dáta two-samples-variances-skull.txt, premennú výška lebky skull.H v milimetroch u mužov a žien v starovekej egyptskej populácii. Predpokladáme, že premenná skull.H mužov má normálne rozdelenie $N(\mu_1, \sigma_1^2)$ a skull.H žien má normálne rozdelenie $N(\mu_2, \sigma_2^2)$. (a) Otestujte hypotézu o podiele rozptylov σ_1^2 a σ_2^2 na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre podiel rozptylov σ_1^2/σ_2^2 , kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku F_W , (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} a DIS prislúchajúce (1).*

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : podiel rozptylov výšky lebky u mužov a u žien je rovný jednej (t.j. rozptyly výšky lebky u mužov a u žien sa rovnajú) oproti H_1 : podiel rozptylov výšky lebky u mužov a u žien nie je rovný jednej (t.j. rozptyly výšky lebky u mužov a u žien sa nerovnajú).
- **matematická formulácia** – $H_0 : \sigma_1^2/\sigma_2^2 = \sigma_0^2$ oproti $H_1 : \sigma_1^2/\sigma_2^2 \neq \sigma_0^2$, kde $\sigma_0^2 = 1$.

2. **Testovacia štatistika** – Rozptyly σ_j^2 , kde $j = 1, 2$, sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú $s_1^2 \doteq 23.38$ a $s_2^2 \doteq 21.65$. Podiel $s_1^2/s_2^2 = 1.08$.

```
1210 DATA <- read.table("two-samples-variances-skull.txt", header=TRUE)
1211 names(DATA)
1212 ##      "id"      "pop"      "sex"      "skull.H"
1213 attach(DATA)
1214 skull.H.m <- na.omit(skull.H[sex=="m"])
1215 skull.H.f <- na.omit(skull.H[sex=="f"])
1216 n.m <- length(skull.H.m) # 215
1217 n.f <- length(skull.H.f) # 107
1218 n <- n.m+n.f # 322
```

```

1219 | rozptyl.m <- var(skull.H.m) # 23.382
1220 | rozptyl.f <- var(skull.H.f) # 21.65279
1221 | rozptyl.ratio <- rozptyl.m/rozptyl.f # 1.079861
1222 | rozptyl.tilde <- (n.m*rozptyl.m+n.f*rozptyl.f)/n # 22.80739

```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $F_{\text{obs}} \doteq 1.08$.

Testovacia štatistika pomerom vierohodnosti $u_{\text{LR}} \doteq 0.21$.

```

1223 | F.test <- var.test(skull.H.m, skull.H.f)
1224 | F.obs <- F.test$stat # 1.079861
1225 | uLR.obs <- n.m*log((n.m*rozptyl.m+n.f*rozptyl.f)/(rozptyl.m*n))+
1226 |         n.f*log((n.m*rozptyl.m+n.f*rozptyl.f)/(rozptyl.f*n)) # 0.2090286

```

3. Zamietacia oblasť –

Waldov test:

kritické hodnoty $F_{n_{m-1}, f_{-1}}(1-\alpha/2) = F_{214, 106}(1-\alpha/2) \doteq 1.40$ a $F_{n_{m-1}, f_{-1}}(\alpha/2) = F_{214, 106}(\alpha/2) \doteq 0.73$;

kritický obor $\mathcal{W}_1 \doteq (0, 0.73) \cup (1.40, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), \infty) = (3.841, \infty)$.

```

1227 | df <- F.test$param # 214 106
1228 | F.krit.d <- qf(0.025, df1=df[1], df2=df[2]) # 0.7251934
1229 | F.krit.h <- qf(0.975, df1=df[1], df2=df[2]) # 1.404928
1230 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459

```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov $100 \times (1 - \alpha)\%$ empirický DIS = 95% empirický DIS pre σ_1^2/σ_2^2 :
 $(d, h) \doteq (0.769, 1.489)$.

```

1231 | IS.W <- F.test$conf.int # 0.7686237 1.4890660

```

5. Štatistický záver –

Waldov test: p-hodnota $\doteq 2\Pr(F_W \geq 1.08|H_0) = 0.663$.

Test pomerom vierohodnosti: p-hodnota $\doteq \Pr(U_{\text{LR}} \geq 0.209|H_0) = 0.648$.

```

1232 | p.hodn.F <- F.test$p.val # 0.6630295
1233 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 0.6475298

```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\sigma_0^2 = 0$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. **Slovný záver** – Nezamietame nulovú hypotézu o tom, že podiel rozptylov výšky lebky u mužov a u žien je rovný jednej.

7. **Antropologický slovný záver** – Nemôžeme zamietnuť zhodu rozptylu výšky lebky mužov a žien v stredovekej egyptskej populácii. Faktory ovplyvňujúce rozptyl hodnôt tohto znaku boli u oboch pohlaví podobné.

7.3 Asymptotické testy o rozdiel korelačných koeficientov

Obvyklé typy testov v antropologickom výskume riešia veľkosť a znamienko závislosti (súvislosti) medzi dvoma premennými, ale zriedka sa stretneme so snahou porovnávať dve súvislosti tých istých premenných testovaním rozdielov medzi dvoma korelačnými koeficientmi. Pritom práve takýto test nás môže posunúť v pohľade na študovaný problém oveľa ďalej než testy rozdielov stredných hodnôt. Ak súvislosť medzi dvoma premennými odráža nejaký biologický proces, a pokiaľ je v jednej skupine súvislosť systematicky odlišná (korelačné koeficienty sa štatisticky významne líšia), vypovedá to o zásadných rozdieloch v biologických procesoch, ktoré za danú súvislosť zodpovedajú. Typickou oblasťou, v ktorej možno uplatniť testy rozdielov korelačných koeficientov, je sexuálny dimorfizmus. Napríklad hladiny steroidných hormónov môžu ovplyvňovať určitú časť tela u každého pohlavia odlišne alebo v rôznej miere.

Nech $(X_j, Y_j)^T \sim N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, kde $j = 1, 2$. Nech ρ_j je korelačný koeficient X_j a Y_j , R_j je výberový korelačný koeficient a $\hat{\rho}_j = r_j$ je odhad ρ_j . Korelačný koeficient má asymptoticky normálne rozdelenie, t.j. $R_j \sim N\left(\rho_j, \frac{(1 - \rho_j^2)^2}{n_j - 1}\right)$, kde n_j sú rozsahy náhodných výberov. Zaujímá nás rozdiel $R_1 - R_2$, avšak jeho konvergencia k normalite je pomalá, preto sa namiesto R_j používajú **Fisherove Z-premenné** Z_1 a Z_2 . Potom

$$Z_1 - Z_2 \sim N\left(0, \frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}\right), Z_j = \frac{1}{2} \ln \frac{1 + R_j}{1 - R_j}, j = 1, 2.$$

Majme dvojicu hypotéz $H_{01} : \rho_1 - \rho_2 = \rho_0$ oproti $H_{11} : \rho_1 - \rho_2 \neq \rho_0$, $H_{02} : \rho_1 - \rho_2 \leq \rho_0$ oproti $H_{12} : \rho_1 - \rho_2 > \rho_0$, $H_{03} : \rho_1 - \rho_2 \geq \rho_0$ oproti $H_{13} : \rho_1 - \rho_2 < \rho_0$.

Ak H_0 platí, potom

$$Z_W = \frac{Z_1 - Z_2 - \xi_0}{\sqrt{\frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}}} \stackrel{\mathcal{D}}{\sim} N(0, 1).$$

kde $\xi_0 = \frac{1}{2} \ln \frac{1 + \rho_0}{1 - \rho_0}$. Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojvýberový Z-test o rozdiel korelačných koeficientov** ρ_1 a ρ_2 .

Definícia 76 (Kritický obor a silofunkcia Z_W testu o $\rho_1 - \rho_2$) Kritický obor a silofunkcia sú definované nasledovne (ozn. $\xi = \frac{1}{2} \ln \frac{1 + \rho}{1 - \rho}$, $\delta_\xi = \xi_0 - (\xi_1 - \xi_2)$ a $n_1 = n_2 = n$):

H_0	H_1	\mathcal{W}	$1 - \beta(\xi_1, \xi_2)$
$\rho_1 - \rho_2 = \rho_0$	$\rho_1 - \rho_2 \neq \rho_0$	$\mathcal{W}_1 = \{Z_W; Z_W \geq u(\alpha/2)\}$	$1 - \Phi\left(u_{\alpha/2} - \sqrt{(n-3)/2} \delta_\xi \right)$
$\rho_1 - \rho_2 \leq \rho_0$	$\rho_1 - \rho_2 > \rho_0$	$\mathcal{W}_2 = \{Z_W; Z_W \geq u(\alpha)\}$	$1 - \Phi\left(u_\alpha + \sqrt{(n-3)/2} (\delta_\xi)\right)$
$\rho_1 - \rho_2 \geq \rho_0$	$\rho_1 - \rho_2 < \rho_0$	$\mathcal{W}_3 = \{Z_W; Z_W \leq -u(\alpha)\}$	$1 - \Phi\left(u_\alpha - \sqrt{(n-3)/2} (\delta_\xi)\right)$

Definícia 77 (p-hodnota Z_W testu o $\rho_1 - \rho_2$) Nech Z_W je nejaká testovacia štatistika a z_W je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : \rho_1 - \rho_2 \neq \rho_0 \\ \Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : \rho_1 - \rho_2 > \rho_0 \\ \Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : \rho_1 - \rho_2 < \rho_0 \end{cases}$$

Definícia 78 (Waldov $100 \times (1 - \alpha)\%$ empirický DIS pre ξ a IS pre $\rho_1 - \rho_2$) Keďže

$\Pr\left(\frac{1}{\sigma_g} |Z_1 - Z_2 - \xi| \leq u(\alpha/2)\right) = 1 - \alpha$, kde $\sigma_g^2 = \frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}$, potom Waldov $100 \times (1 - \alpha)\%$ empirický DIS pre ξ má tvar

$$\mathcal{CS}_{1-\alpha} = \{\xi_0; \xi_0 \in (z_1 - z_2 - u_{\alpha/2} \hat{\sigma}_g, z_1 - z_2 + u_{\alpha/2} \hat{\sigma}_g)\},$$

kde $\hat{\sigma}_g^2 = \frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}$. Vieme, že $\rho = \tanh(\xi)$ je monotónna funkcia ξ . Potom môžeme písať spätne transformované **Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $\rho_1 - \rho_2$** ako:

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$\rho_1 - \rho_2 = \rho_0$	$\rho_1 - \rho_2 \neq \rho_0$	$\mathcal{CS}_{1-\alpha} = \{\rho_0 : \rho_0 \in (\tanh[d], \tanh[h])\}$
$\rho_1 - \rho_2 \leq \rho_0$	$\rho_1 - \rho_2 > \rho_0$	$\mathcal{CS}_{1-\alpha} = \{\rho_0 : \rho_0 \in (\tanh[z_1 - z_2 - u_\alpha \hat{\sigma}_g], 2)\}$
$\rho_1 - \rho_2 \geq \rho_0$	$\rho_1 - \rho_2 < \rho_0$	$\mathcal{CS}_{1-\alpha} = \{\rho_0 : \rho_0 \in (-2, \tanh[z_1 - z_2 + u_\alpha \hat{\sigma}_g])\}$

kde $d = z_1 - z_2 - u_{\alpha/2} \hat{\sigma}_g$ a $h = z_1 - z_2 + u_{\alpha/2} \hat{\sigma}_g$.

Príklad 234 (DIS pre $\rho_1 - \rho_2$ použitím Fisherovej Z -premennej) Naprogramujte DIS pre $\rho_1 - \rho_2$.

Riešenie v \mathbb{R}

```
1234 | "ISkor.rozdiel" <- function(x1,y1,x2,y2,conf.level=0.95){
1235 | z1 <- atanh(cor(x1,y1)); z2 <- atanh(cor(x2,y2))
1236 | n1 <- length(x1); n2 <- length(x2)
1237 | a <- qnorm(1-(1-conf.level)/2)*(1/(n1-3)+1/(n2-3))^0.5
1238 | IS.xi <- c(z1-z2-a,z1-z2+a)
1239 | IS <- tanh(IS.xi)
1240 | return(IS)
1241 | }
```

Majme H_{11} . Použitím Fisherovej Z -premennej pre nejaký rozdiel $\xi_1 - \xi_2 - \xi_0$, α a β dostaneme **minimálny rozsah** $n = n_1 = n_2$ ako

$$n \geq 3 + 2 \left(\frac{u_{\alpha/2} + u_{\beta}}{\xi_1 - \xi_2 - \xi_0} \right)^2.$$

Pre H_{12} a H_{13} zameníme $u_{\alpha/2}$ za u_{α} .

Príklad 235 Sledujeme hladinu LDL cholesterolu a krvného tlaku u slovenských žien a mužov. Lekári stanovili klinicky dôležitý rozdiel korelačných koeficientov ako $\rho_1 - \rho_2 = 0.2$, kde $\rho_1 = 0.1, 0.3, \dots, 0.9$. Ďalej nech sila testu je $1 - \beta = 0.90$ (pravdepodobnosť odhalenia tohoto rozdielu) a hladina významnosti $\alpha = 0.05$. Aspoň koľko žien a mužov ($n_1 = n_2 = n$) musíme sledovať pri danej α a $1 - \beta$?

Riešenie v \mathbb{R} (pozri tabuľku 7.1)

```
1242 | "min.rozsah.n.kor" <- function(r1,r2,alfa,sila){
1243 | xi1 <- atanh(r1); xi2 <- atanh(r2)
1244 | xi.diff <- xi1-xi2
1245 | n <- ceiling(3+2*((qnorm(1-alfa/2)+qnorm(sila))/(xi1-xi2))^2)
1246 | TAB <- rbind(round(r1,1),round(r2,1),round(xi.diff,4),n)
1247 | dimnames(TAB)[[1]] <- c("r1","r2","xi.diff","n")
1248 | return(TAB)
1249 | }
1250 | r1 <- seq(0.1,0.9,by=0.1)
1251 | r2 <- r1-0.2
1252 | min.rozsah.n.kor(r1,r2,0.05,0.9)
```

Tabuľka 7.1: Minimálne rozsahy n pre rozdiel $\rho_1 - \rho_2 = 0.2$ pri rôznych ρ a ρ_0 spolu s rozdielom $\xi_1 - \xi_2$, ktorý je funkciou

ρ_1 a ρ_2										
ρ_1	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	
ρ_2	-0.1	0.0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	
$\xi_1 - \xi_2$	0.2007	0.2027	0.2092	0.2209	0.2398	0.2695	0.3180	0.4055	0.6049	
n	525	515	484	434	369	293	211	131	61	

Test pomerom vierohodnosti pre $\rho_1 - \rho_2$.

Majme H_{01} oproti H_{11} . Nech $(X_j, Y_j)^T \sim N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, kde $(X_j, Y_j)^T$ sú nezávislé, vektor $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2)^T$, $\boldsymbol{\theta}_j = (\mu_{j1}, \mu_{j2}, \sigma_{j1}^2, \sigma_{j2}^2, \rho_j)^T$ a $j = 1, 2$. Logaritmus funkcie vierohodnosti bude mať tvar

$$\begin{aligned} l(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{y}_1, \mathbf{x}_2, \mathbf{y}_2) &= -n \ln(2\pi) - \sum_{j=1}^2 \frac{n_j}{2} \ln(\sigma_{j1}^2 \sigma_{j2}^2) - \sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \rho_j^2) \\ &- \sum_{j=1}^2 \frac{1}{2(1 - \rho_j^2)} \left(\frac{\sum_{i=1}^{n_j} (x_{ji} - \mu_{j1})^2}{\sigma_{j1}^2} - 2\rho_j \frac{\sum_{i=1}^{n_j} (x_{ji} - \mu_{j1})(y_{ji} - \mu_{j2})}{\sigma_{j1} \sigma_{j2}} \right. \\ &\left. + \frac{\sum_{i=1}^{n_j} (y_{ji} - \mu_{j2})^2}{\sigma_{j2}^2} \right), \end{aligned}$$

kde $n = \sum_{j=1}^2 n_j$. MLE $\hat{\boldsymbol{\theta}}_j = (\hat{\mu}_{j1}, \hat{\mu}_{j2}, \hat{\sigma}_{j1}^2, \hat{\sigma}_{j2}^2, \hat{\rho}_j)^T$, kde

$$\begin{aligned}\hat{\mu}_{j1} &= \bar{x}_j, \hat{\mu}_{j2} = \bar{y}_j, \hat{\sigma}_{j1}^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (x_{ji} - \bar{x}_j)^2, \hat{\sigma}_{j2}^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2, \\ \hat{\rho}_j &= \frac{\sum_{i=1}^{n_j} (x_{ji} - \bar{x}_j)(y_{ji} - \bar{y}_j)}{n_j \hat{\sigma}_{j1} \hat{\sigma}_{j2}}\end{aligned}$$

a $\Theta_1 = \{\boldsymbol{\theta} : \rho_1 \neq \rho_2 \neq \rho\}$. Za platnosti H_{01} je $\boldsymbol{\theta}_{j0} = (\hat{\mu}_{j1}, \hat{\mu}_{j2}, \hat{\sigma}_{j1}^2, \hat{\sigma}_{j2}^2, \hat{\rho})^T$, kde

$$\tilde{\sigma}_{j1}^2 = \frac{\hat{\sigma}_{j1}^2(1 - \hat{\rho}\hat{\rho}_j)}{1 - \hat{\rho}^2}, \tilde{\sigma}_{j2}^2 = \frac{\hat{\sigma}_{j2}^2(1 - \hat{\rho}\hat{\rho}_j)}{1 - \hat{\rho}^2}$$

$\hat{\rho}$ je iteračným riešením rovnice $\sum_{j=1}^2 \frac{n_j(\hat{\rho}_j - \hat{\rho})}{1 - \hat{\rho}_j \hat{\rho}} = 0$ (pozri Pearson, 1933) a $\Theta_0 = \{\boldsymbol{\theta} : \rho_1 = \rho_2 = \rho\}$.

Logaritmus funkcie vierohodnosti pre $\hat{\boldsymbol{\theta}}$ bude mať tvar

$$\begin{aligned}l(\hat{\boldsymbol{\theta}}|\mathbf{x}_1, \mathbf{y}_1, \mathbf{x}_2, \mathbf{y}_2) &= -n \ln(2\pi) - \sum_{j=1}^2 \frac{n_j}{2} \ln(\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2) - \sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \hat{\rho}_j^2) \\ &\quad - \sum_{j=1}^2 \frac{1}{2(1 - \hat{\rho}_j^2)} \left(\frac{n_j \hat{\sigma}_{j1}^2}{\hat{\sigma}_{j1}^2} - 2\hat{\rho}_j \frac{n_j \hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2 \hat{\rho}_j}{\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2} + \frac{n_j \hat{\sigma}_{j2}^2}{\hat{\sigma}_{j2}^2} \right) \\ &= -n \ln(2\pi) - \sum_{j=1}^2 \frac{n_j}{2} \ln(\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2) - \sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \hat{\rho}_j^2) - n.\end{aligned}$$

Logaritmus funkcie vierohodnosti pre $\boldsymbol{\theta}_0$ bude mať tvar

$$\begin{aligned}l(\boldsymbol{\theta}_0|\mathbf{x}_1, \mathbf{y}_1, \mathbf{x}_2, \mathbf{y}_2) &= -n \ln(2\pi) - \sum_{j=1}^2 \frac{n_j}{2} \ln(\tilde{\sigma}_{j1}^2 \tilde{\sigma}_{j2}^2) - \sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \hat{\rho}^2) \\ &\quad - \sum_{j=1}^2 \frac{1}{2(1 - \hat{\rho}^2)} \left(\frac{n_j \hat{\sigma}_{j1}^2}{\tilde{\sigma}_{j1}^2} - 2\hat{\rho} \frac{n_j \hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2 \hat{\rho}_j}{\tilde{\sigma}_{j1}^2 \tilde{\sigma}_{j2}^2} + \frac{n_j \hat{\sigma}_{j2}^2}{\tilde{\sigma}_{j2}^2} \right) \\ &= -n \ln(2\pi) - \sum_{j=1}^2 \frac{n_j}{2} \ln(\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2) - \sum_{j=1}^2 n_j \ln \frac{(1 - \hat{\rho}\hat{\rho}_j)^2}{(1 - \hat{\rho}^2)^2} \\ &\quad - \sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \hat{\rho}^2) - n\end{aligned}$$

Potom -1 krát prirodzený logaritmus pomeru vierohodností bude potom rovný

$$\begin{aligned}-\ln(\lambda(\mathbf{x}_1, \mathbf{y}_1, \mathbf{x}_2, \mathbf{y}_2)) &= l(\hat{\boldsymbol{\theta}}|\mathbf{x}_1, \mathbf{y}_1, \mathbf{x}_2, \mathbf{y}_2) - l(\boldsymbol{\theta}_0|\mathbf{x}_1, \mathbf{y}_1, \mathbf{x}_2, \mathbf{y}_2) \\ &= -\sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \hat{\rho}_j^2) + \sum_{j=1}^2 \frac{n_j}{2} \ln(1 - \hat{\rho}^2) + \sum_{j=1}^2 n_j \ln \frac{(1 - \hat{\rho}\hat{\rho}_j)^2}{(1 - \hat{\rho}^2)^2} \\ &= \frac{1}{2} \sum_{j=1}^2 n_j \ln \frac{(1 - \hat{\rho}\hat{\rho}_j)^2}{(1 - \hat{\rho}^2)(1 - \hat{\rho}_j^2)}.\end{aligned}$$

Vieme, že testovacia štatistika pomerom vierohodností $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{Y}_1, \mathbf{X}_2, \mathbf{Y}_2)) \stackrel{\mathcal{D}}{\sim} \chi_1^2$.

Vierohodnostný $100 \times (1 - \alpha)\%$ empirický DIS pre $\rho_1 - \rho_2$ bude mať tvar

$$CS_{1-\alpha} = \{\rho_0 : U_{LR} < \chi_1^2(\alpha)\}.$$

Na výpočet tohoto DIS by sme museli reparametrizovať funkciu vierohodnosti na parameter záujmu ($\rho_1 - \rho_2$) a rušivý parameter. Alternatívne by bolo možné vypočítať u_{LR} pre rôzne kombinácie ρ_1 a ρ_2 (na vhodne zvolených intervaloch) a pre tieto ρ_j , $j = 1, 2$, vypočítať rozdiely $\rho_1 - \rho_2$. Potom $CS_{1-\alpha} = \{\rho_0 : U_{LR}(\rho_1 - \rho_2) < \chi_1^2(\alpha)\}$.

Príklad 236 (test o rozdiel ρ_1 a ρ_2) *Majme dáta two-samples-correlations-trunk.txt, premennú dĺžka dolnej končatiny lowex.L v milimetroch a dĺžka trupu tru.L v milimetroch u mužov a žien. Predpokladáme, že premenné lowex.L a tru.L majú $N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, kde $j = 1, 2$ predstavujú mužov a ženy. (a) Otestujte hypotézu o rozdiel korelačných koeficientov ρ_1 a ρ_2 na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre rozdiel $\rho_1 - \rho_2$, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite (1) Waldovu testovaciu štatistiku Z_W , (2) testovaciu štatistiku pomerom vierohodnosti U_{LR} a DIS prislúchajúce (1).*

Riešenie (aj v \mathbb{R})

1. Hypotézy

- **slovná formulácia** – testujeme H_0 : rozdiel korelačných koeficientov premenných dĺžka dolnej končatiny a dĺžka trupu u mužov a u žien je rovný nule (t.j. korelačné koeficienty u mužov a u žien sa rovnajú) oproti H_1 : rozdiel korelačných koeficientov premenných dĺžka dolnej končatiny a dĺžka trupu u mužov a u žien nie je rovný nule (t.j. korelačné koeficienty u mužov a u žien sa nerovnajú).
- **matematická formulácia** – $H_0 : \rho_1 - \rho_2 = \rho_0$ oproti $H_1 : \rho_1 - \rho_2 \neq \rho_0$, kde $\rho_0 = 0$.

2. **Testovacia štatistika** – Pearsonove korelačné koeficienty ρ_j^2 , kde $j = 1, 2$, sú neznáme, a preto ich musíme odhadnúť. Ich odhadmi sú $r_1 \doteq 0.06$ a $r_2 \doteq 0.29$. Rozdiel $r_1 - r_2 \doteq -0.23$.

```
1253 | DATA <- read.table("two-samples-correlations-trunk.txt", header=TRUE)
1254 | names(DATA)
1255 | ## "sex" "lowex.L" "tru.L"
1256 | attach(DATA)
1257 | kor.m <- cor(lowex.L[sex=="m"], tru.L[sex=="m"]) # 0.05975781
1258 | kor.f <- cor(lowex.L[sex=="f"], tru.L[sex=="f"]) # 0.285256
1259 | kor.diff <- kor.m-kor.f # -0.2254981
```

Pozorované testovacie štatistiky:

Waldova testovacia štatistika $z_W \doteq -1.50$.

Testovacia štatistika pomerom vierohodnosti $u_{LR} \doteq 2.33$.

```
1260 | xi.m <- atanh(kor.m) # 0.0598291
1261 | xi.f <- atanh(kor.f) # 0.285256
1262 | xi.diff <- xi.m-xi.f # -0.2335652
1263 | n.m <- length(lowex.L[sex=="m"]) # 75
1264 | n.f <- length(lowex.L[sex=="f"]) # 100
1265 | rozptyl.xi.diff <- 1/(n.m-3)+1/(n.f-3)
1266 | z.W <- xi.diff/sqrt(rozptyl.xi.diff) # -1.501471
1267 | "rho.hat" <- function(kor, kor.m, kor.f, n.m, n.f) {
1268 |   n.m*(kor.m-kor)/(1-kor.m*kor)+n.f*(kor.f-kor)/(1-kor.f*kor)
1269 | }
1270 | kor <- uniroot(rho.hat, interval=c(-0.5,0.5), kor.m=kor.m, kor.f=kor.f, n.m=n.m, n.f=n.f)$root # 0.1910674
1271 | uLR.obs <- n.m*log((1-kor.m*kor)^2/((1-kor^2)*(1-kor.m^2)))+
1272 |   n.f*log((1-kor.f*kor)^2/((1-kor^2)*(1-kor.f^2))) # 2.332354
```

3. Zamietacia oblasť –

Waldov test:

kritické hodnoty $u(1 - \alpha/2) \doteq -1.96$ a $u(\alpha/2) \doteq 1.96$;

kritický obor $\mathcal{W}_1 = (-\infty, -1.96) \cup (1.96, \infty)$.

Test pomerom vierohodnosti:

kritická hodnota $\chi_1^2(\alpha) \doteq 3.841$;

kritický obor $\mathcal{W} = (\chi_1^2(\alpha), \infty) \doteq (3.841, \infty)$.

```
1273 | u.krit.d <- qnorm(0.025) # -1.959964
1274 | u.krit.h <- qnorm(0.975) # 1.959964
1275 | lr.krit.hodn <- qchisq(0.95, df=1) # 3.841459
```

4. Empirický dvojstranný interval spoľahlivosti –

Waldov $100 \times (1 - \alpha)\%$ empirický DIS=95% empirický DIS pre $\rho_1 - \rho_2$:
 $(d, h) = (-0.49, 0.07)$.

```
1276 | IS.W <- tanh(xi.diff+c(-1,1)*u.krit.h*sqrt(rozptyl.xi.diff)) # -0.49181570 0.07120136
```

5. Štatistický záver –

Waldov test: p-hodnota $\doteq 2\Pr(Z_W \geq 1.50|H_0) \doteq 0.133$.

Test pomerom vierohodnosti: p-hodnota= $\Pr(U_{LR} \geq 2.33|H_0) \doteq 0.127$.

```
1277 | p.hodn.Z <- 2*(1-pnorm(abs(z.W))) # 0.1332338
1278 | p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # 0.1267102
```

H_0 na hladine významnosti nezamietame, pretože (1) testovacia štatistika nepatrí kritickému oboru, (2) $\rho_0 = 0$ patrí DIS a nakoniec (3) p-hodnota je väčšia ako 0.05.

6. Slovný záver –

Nezamietame nulovú hypotézu o tom, že rozdiel korelačných koeficientov premenných dĺžka dolnej končatiny a dĺžka trupu u mužov a u žien je rovný nule.

7. Antropologický slovný záver –

Dĺžka trupu u žien, v oblasti brucha rešpektujúca nároky rastúceho plodu v dobe tehotenstva, by mala výraznejšie súvisieť s dĺžkou dolných končatín v porovnaní s mužmi. Podľa predpokladu vyplývajúceho z reprodukčných rozdielov medzi pohlaviami je korelačný koeficient u žien číselne väčší než u mužov (0.29 vs. 0.06). Na rozdiel od mužov, u žien je korelácia štatisticky významná (p-hodnota = 0.004 vs. 0.611) a oba rozmery spolu súvisia. I keď je medzi pohlaviami relatívne veľký rozdiel v korelačných koeficientoch medzi oboma rozmermi, rozdiel korelačných koeficientov v testovanej vzorke štatisticky významný nebol. Dôvodom môže byť celkovo nevyvážená vzorka (100 žien vs. 75 mužov) a nízky počet pozorovaní v oboch vzorkách. Pri $\alpha = 0.05$, $1 - \beta = 0.8$ a vyvázenej vzorke ($n = n_1 = n_2$) by sme potrebovali minimálne $n = 291$, aby bol rozdiel korelačných koeficientov -0.23 štatisticky signifikantný. Iným dôvodom môže byť skladba oboch vzoriek, keďže ide o nepribuzných mužov a ženy, vybraných z populácie mladých študentov pôvodom takmer z celej Českej a Slovenskej republiky. Najrôznejšie faktory (määtúce premenné: geografické, sociálne, genetické) tak môžu ovplyvňovať (zvyšovať) variabilitu oboch znakov u mužov a žien. Pokiaľ by sme tieto faktory obmedzili (napríklad na vzorky zložené z ľudí určitého geografického územia, obdobných rastových vzorcov alebo rovnaké vzorky zložené z párov brat – sestra), rozdiel korelačných koeficientov by pravdepodobne mohol byť väčší alebo jeho štatistická významnosť vyššia. Je tiež možné, že obmedzením definície rozmeru dĺžky trupu len na oblasť brucha (v našom prípade šlo o rozdiel výšky akromiálnej a výšky spinálnej, t.j. projekčná vzdialenosť *spina iliaca anterior superior* od laterálneho konca kľúčnej kosti) by korelácia u žien mohla byť ešte silnejšia a rozdiel medzi pohlaviami štatisticky významný.

7.4 Asymptotické testy o dvoch pravdepodobnostiach

Kontingenčné tabuľky 2×2 a testy dvoch pravdepodobností patria k častým úlohám v rôznych oblastiach antropológie a ich použitie je veľmi univerzálne. Porovnanie pravdepodobností výskytu nejakého javu medzi dvoma skupinami patrí medzi najbežnejšie štatistické úlohy vôbec. V kostrovej antropológii sa uplatňuje napr. pri testovaní rozdielov vo výskyte rôznych epigenetických znakov (pozri úvod ku kapitole 6.4), u živého človeka pri testovaní akýchkoľvek kvalitatívnych znakov, u ktorých zaznamenávame ich prítomnosť alebo neprítomnosť. V oblasti medicíny možno týmto spôsobom testovať rozdiel vo výskyte chorôb (*morbidity*) i úmrtnosť (*fatalita*) na určitú chorobu.

Nech $X_j \sim \text{Bin}(N_j, p_j)$, $j = 1, 2$, sú dve nezávislé náhodné premenné. Realizácie x_j môžeme usporiadať do nasledovnej **kontingenčnej tabuľky 2×2 pre početnosti**

	odpoveď 1 (má znak X)	odpoveď 0 (nemá znak X)	spolu
skupina 1	n_1	$N_1 - n_1$	N_1
skupina 2	n_2	$N_2 - n_2$	N_2

a kontingenčnej tabuľky 2×2 pre pravdepodobnosti

	odpoveď 1 (má znak X)	odpoveď 0 (nemá znak X)	spolu
skupina 1	p_1	$1 - p_1$	1
skupina 2	p_2	$1 - p_2$	1

Kontingenčnú tabuľku 2×2 pre početnosti je možné preznačiť nasledovne

	odpoveď 1 (má znak X)	odpoveď 0 (nemá znak X)	spolu
skupina 1	n_{11}	n_{12}	$N_{1\bullet}$
skupina 2	n_{21}	n_{22}	$N_{2\bullet}$
suma	$N_{\bullet 1}$	$N_{\bullet 2}$	N

Početnosti n_{ij} , $j = 1, 2$, sa nazývajú **združené početnosti**, početnosti $N_{\bullet j} = n_{1j} + n_{2j}$ **marginálne stĺpcové početnosti**, početnosti $N_{j\bullet} = n_{j1} + n_{j2}$ **marginálne riadkové početnosti** a početnosť $N = N_{\bullet 1} + N_{\bullet 2} = N_{1\bullet} + N_{2\bullet} = N_{11} + N_{12} + N_{21} + N_{22}$ sa nazýva **celková (totálna) početnosť**. Kontingenčnú tabuľku 2×2 pre pravdepodobnosti je možné preznačiť nasledovne

	odpoveď 1 (má znak X)	odpoveď 0 (nemá znak X)	spolu
skupina 1	p_{11}	p_{12}	$p_{1\bullet}$
skupina 2	p_{21}	p_{22}	$p_{2\bullet}$
suma	$p_{\bullet 1}$	$p_{\bullet 2}$	1

Pravdepodobnosti $p_{ij} = \frac{n_{ij}}{N}$, $j = 1, 2$, sa nazývajú **združené pravdepodobnosti**, pravdepodobnosti $p_{\bullet j} = \frac{N_{\bullet j}}{N}$ **marginálne stĺpcové pravdepodobnosti**, pravdepodobnosti $p_{j\bullet} = \frac{N_{j\bullet}}{N}$ **marginálne riadkové pravdepodobnosti**. Alternatívnym preznačením dostaneme **kontingenčnú tabuľku 2×2 pre podmienené pravdepodobnosti**

	odpoveď 1 (má znak X)	odpoveď 0 (nemá znak X)	spolu
skupina 1	$p_{1 1}$	$p_{2 1}$	1
skupina 2	$p_{1 2}$	$p_{2 2}$	1

Ide o **podmienené pravdepodobnosti odpovede (výskytu znaku) za podmienky príslušnosti do skupiny**, kde $p_{1|1} = p_1$, $p_{1|2} = p_2$, $p_{2|1} = 1 - p_1$ a $p_{2|2} = 1 - p_2$.

Nech $\theta = (p_1, p_2)^T$. Potom môžeme zhrnúť najčastejšie používané funkcie $g(\theta)$ nasledovne:

názov	označenie	$g(\theta)$	rozpätie	nulový bod
rozdiel rizík	RD	$p_1 - p_2$	$(-1, 1)$	0
relatívne riziko	RR	$\frac{p_1}{p_2}$	$(0, \infty)$	1
logaritmus relatívneho rizika	ln RR	$\ln \frac{p_1}{p_2}$	$(-\infty, \infty)$	0
pomer šancí	OR	$\frac{p_1/(1-p_1)}{p_2/(1-p_2)}$	$(0, \infty)$	1
logaritmus pomeru šancí	ln OR	$\ln \frac{p_1/(1-p_1)}{p_2/(1-p_2)}$	$(-\infty, \infty)$	0

Rozdiel rizík predstavuje rozdiel pravdepodobností p_1 a p_2 výskytu sledovaného znaku X v dvoch populáciách. **Relatívne riziko** predstavuje podiel pravdepodobností p_1 a p_2 výskytu sledovaného znaku X v dvoch populáciách. **Pomer šancí** predstavuje podiel šancí $p_1/(1-p_1)$ a $p_2/(1-p_2)$ pre výskyt znaku X . Logaritmovanie podielu rizík a pomeru šancí spôsobuje zmenu nesymetrického rozdelenia $g(\theta)$ za platnosti H_0 ($g(\theta)$ je rovné svojmu nulovému bodu) na symetrické rozdelenie. Voľba $g(\theta)$ v praxi závisí na konkrétnej aplikácii. Avšak relatívne riziko nie je možné priamo odhadnúť (bez dopĺňujúcich informácií) v retrospektívnych štúdiách prípadov a kontrol. Ale pomer šancí priamo odhadnuteľný je a navyše za predpokladu, že choroba je zriedkavá, je aproximáciou relatívneho rizika. Lekári, biológovia a antropológovia považujú relatívne riziko za najvhodnejšiu $g(\theta)$. V matematickej štatistike je však najčastejšie používaným $g(\theta)$ pomer šancí, ktorý je prirodzeným parametrom funkcie vierohodnosti a parameter, ktorý sa odhaduje aj v logistickom regresnom modeli.


Medzi jednotlivými $g(\theta)$ je nelineárny vzťah. Vyberajme p_2 z intervalu $(0, 1)$ a ponechajme rozdiel rizík konštantný a rovný -0.1 . Keď p_2 rastie, relatívne riziko je monotónnou funkciou rastúcou smerom k jeho nulovému bodu jedna, indikujúc proporčne menšiu redukciu rizika. Ak p_1 ide k nule a p_2 ide k jednotke, pomer šancí sa približne rovná nule. Ak p_2 rastie, pomer šancí rastie, dosiahne maximum

približne rovné 0.669 v bode $\tilde{p}_2 = 0.5(1 - RD) = 0.55$ a potom klesá k nule (pozri obrázok 7.4 vľavo; pre $RD = -0.5$ pozri obrázok 7.5 vľavo).

Vyberajme p_2 opäť z intervalu $(0, 1)$ a ponechajme rozdiel rizík konštantný a rovný 0.1. Keď p_2 rastie, relatívne riziko je monotónnou funkciou klesajúcou smerom k jeho nulovému bodu jedna, indikujúcej porovnanie menšiu redukciu rizika. Ak p_1 ide k nule a p_2 ide k jednotke, pomer šancí sa rovná nejakému číslu oveľa väčšiemu ako jedna. Ak p_2 rastie, pomer šancí klesá, dosiahne minimum približne rovné 1.494 v bode $\tilde{p}_2 = 0.5(1 - RD) = 0.45$ a potom rastie (pozri obrázok 7.4 vpravo; pre $RD = -0.5$ pozri obrázok 7.5 vpravo).

Majme dve štúdie A a B s rovnakým záporným rozdielom rizík $RD = -0.1$ (t.j. $p_1 < p_2$), ale pravdepodobnosti sú rozdielne, t.j. $RD_A = RD_B$, $p_{A1} < p_{B1}$ a $p_{A2} < p_{B2}$. Potom $RR_A \neq RR_B$ a štúdiá s väčším p_2 bude mať RR bližšie k jednotke (RR bude väčšie). Pomer šancí sa tiež bude odlišovať, t.j. $OR_A \neq OR_B$, ak obe p_2 sú menšie ako \tilde{p}_2 alebo obe p_2 sú väčšie ako \tilde{p}_2 . Ak $p_{A2} < \tilde{p}_2 < p_{B2}$, môže nastať situácia, že $OR_A = OR_B$. Napr. ak $\tilde{p}_2 = 0.5(1 - RD) = 0.55$, potom $p_{A2} = 0.46$ a $p_{B2} = 0.64$, $OR_A = \frac{p_{A1}/(1-p_{A1})}{p_{A2}/(1-p_{A2})} = 0.6581197$ a $OR_B = \frac{p_{B1}/(1-p_{B1})}{p_{B2}/(1-p_{B2})} = 0.6581197$, pretože $|\tilde{p}_2 - p_{A2}| = |p_{B2} - \tilde{p}_2|$.

Majme dve štúdie A a B s rovnakým kladným rozdielom rizík $RD = 0.1$ (t.j. $p_1 < p_2$), ale pravdepodobnosti sú rozdielne, t.j. $RD_A = RD_B$, $p_{A1} > p_{B1}$ a $p_{A2} > p_{B2}$. Potom $RR_A \neq RR_B$ a štúdiá s väčším p_2 bude mať RR bližšie k jednotke (RR bude menšie). Pomer šancí sa tiež bude odlišovať, t.j. $OR_A \neq OR_B$, ak obe p_2 sú menšie ako \tilde{p}_2 alebo obe p_2 sú väčšie ako \tilde{p}_2 . Ak $p_{A2} < \tilde{p}_2 < p_{B2}$, môže nastať situácia, že $OR_A = OR_B$. Napr. ak $\tilde{p}_2 = 0.5(1 - RD) = 0.45$, potom $p_{A2} = 0.35$ a $p_{B2} = 0.55$, $OR_A = \frac{p_{A1}/(1-p_{A1})}{p_{A2}/(1-p_{A2})} = 1.519481$ a $OR_B = \frac{p_{B1}/(1-p_{B1})}{p_{B2}/(1-p_{B2})} = 1.519481$, pretože $|\tilde{p}_2 - p_{A2}| = |p_{B2} - \tilde{p}_2|$.



Obr. 7.4: Nelineárny vzťah rozdielu rizík, pomeru šancí a pomeru rizík (vľavo $OR_{\max} = 0.669$; vpravo $OR_{\max} = 112.235$ a $OR_{\min} = 1.494$)

Medzi p_1 a OR existuje nasledovný vzťah

$$p_1 = \frac{p_2 \times OR}{1 - p_2 + p_2 \times OR}$$


a medzi RR a OR platí

$$RR = OR \frac{1 + n_{21}/n_{22}}{1 + n_{11}/n_{12}}.$$

Rozdiel rizík p_1 a p_2 . Majme dvojice hypotéz $H_{01} : p_1 - p_2 = p_0$ oproti $H_{11} : p_1 - p_2 \neq p_0$, $H_{02} : p_1 - p_2 \leq p_0$ oproti $H_{12} : p_1 - p_2 > p_0$, $H_{03} : p_1 - p_2 \geq p_0$ oproti $H_{13} : p_1 - p_2 < p_0$, ktoré chceme testovať. Hypotézy H_0 sa často nazývajú **hypotézy homogenity dvoch binomických rozdelení**, ak $p_0 = 0$.

Ak H_0 platí, potom

$$Z_W = \frac{X_1/N_1 - X_2/N_2 - p_0}{S_g} \mathcal{D} N(0, 1),$$




Obr. 7.5: Nelineárny vzťah rozdielu rizík, pomeru šancí a pomeru rizík (vľavo $OR_{\max} = 0.111$; vpravo $OR_{\max} = 1003.004$ a $OR_{\min} = 9.000$)

kde $S_g^2 = \frac{X_1/N_1(1-X_1/N_1)}{N_1} + \frac{X_2/N_2(1-X_2/N_2)}{N_2} \neq 0$. Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojvýberový Z-test o rozdiel pravdepodobností** $p_1 - p_2$.

Definícia 79 (Kritický obor a silofunkcia Z_W testu o $p_1 - p_2$) Kritický obor a silofunkcia je definovaná nasledovne (ozn. $\sigma_g^2 = \frac{p_1(1-p_1)}{N_1} + \frac{p_2(1-p_2)}{N_2}$; pozri obrázok 7.6):

H_0	H_1	\mathcal{W}	$1 - \beta(p_1, p_2)$
$p_1 - p_2 = p_0$	$p_1 - p_2 \neq p_0$	$\mathcal{W}_1 = \{Z_W; Z_W \geq u(\alpha/2)\}$	$1 - \Phi\left(u_{\alpha/2} - \frac{ p_0 - (p_1 - p_2) }{\sigma_g}\right)$
$p_1 - p_2 \leq p_0$	$p_1 - p_2 > p_0$	$\mathcal{W}_2 = \{Z_W; Z_W \geq u(\alpha)\}$	$1 - \Phi\left(u_{\alpha} + \frac{p_0 - (p_1 - p_2)}{\sigma_g}\right)$
$p_1 - p_2 \geq p_0$	$p_1 - p_2 < p_0$	$\mathcal{W}_3 = \{Z_W; Z_W \leq -u(\alpha)\}$	$1 - \Phi\left(u_{\alpha} - \frac{p_0 - (p_1 - p_2)}{\sigma_g}\right)$



Obr. 7.6: Silofunkcie Waldovho testu o $p_1 - p_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 80 (p-hodnota Z_W testu o $p_1 - p_2$) Nech Z_W je nejaká testovacia štatistika a $z_W = \frac{\hat{p}_1 - \hat{p}_2 - p_0}{s_g}$, kde $\hat{\sigma}_g^2 = s_g^2 = \frac{\hat{p}_1(1-\hat{p}_1)}{N_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{N_2}$, je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : p_1 - p_2 \neq p_0 \\ Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : p_1 - p_2 > p_0 \\ Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : p_1 - p_2 < p_0 \end{cases}$$

Definícia 81 ((Klasické) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $p_1 - p_2$) (Klasické) Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $p_1 - p_2$ pre všetky tri typy hypotéz majú nasledovný tvar

$$\begin{array}{lll} H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1 - \alpha)\% \text{ empirický IS} \\ p_1 - p_2 = p_0 & p_1 - p_2 \neq p_0 & \mathcal{CS}_{1-\alpha} = \{p_0 : p_0 \in (\hat{p}_1 - \hat{p}_2 - u_{\alpha/2}s_g, \hat{p}_1 - \hat{p}_2 + u_{\alpha/2}s_g)\} \\ p_1 - p_2 \leq p_0 & p_1 - p_2 > p_0 & \mathcal{CS}_{1-\alpha} = \{p_0 : p_0 \in (\hat{p}_1 - \hat{p}_2 - u_{\alpha}s_g, 1)\} \\ p_1 - p_2 \geq p_0 & p_1 - p_2 < p_0 & \mathcal{CS}_{1-\alpha} = \{p_0 : p_0 \in (-1, \hat{p}_1 - \hat{p}_2 + u_{\alpha}s_g)\} \end{array}$$

Majme H_{11} . Potom **minimálny rozsah** definujeme ako

$$N_1 \geq \left(\frac{u_{\alpha/2} + u_{\beta}}{p_1 - p_2} \right)^2 \left(p_1(1 - p_1) + \frac{p_2(1 - p_2)}{k} \right), N_2 = kN_1.$$

Pre H_{12} a H_{13} zameníme $u_{\alpha/2}$ za u_{α} .


Ak za platnosti H_0 berieme pri výpočte do úvahy, že $p_1 = p_2$, potom dostaneme alternatívnu testovaciu štatistiku, ktorá bude mať za platnosti H_0 nasledovný tvar

$$Z_W^{(\text{alt})} = \frac{X_1/N_1 - X_2/N_2 - p_0}{S_g} \underset{\mathcal{D}}{\sim} N(0, 1),$$

kde $S_g^2 = X/N(1 - X/N) \left(\frac{1}{N_1} + \frac{1}{N_2} \right) \neq 0$, $N = N_1 + N_2$ a $X = N_1X_1/N_1 + N_2X_2/N_2$. $Z_W^{(\text{alt})}$ sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **alternatívny dvojvýberový Z-test o rozdiel pravdepodobností** $p_1 - p_2$.

Definícia 82 (Kritický obor a silofunkcia $Z_W^{(\text{alt})}$ testu o $p_1 - p_2$) Kritický obor a silofunkcia sú definované nasledovne (ozn. $\sigma_g^2 = p(1 - p) \left(\frac{1}{N_1} + \frac{1}{N_2} \right)$; pozri obrázok 7.7):

$$\begin{array}{llll} H_0 & H_1 & \mathcal{W} & \beta(p_1, p_2) \\ p_1 - p_2 = p_0 & p_1 - p_2 \neq p_0 & \mathcal{W}_1 = \left\{ Z_W^{(\text{alt})}; |Z_W^{(\text{alt})}| \geq u(\alpha/2) \right\} & \Phi \left(u_{\alpha/2} - \frac{|p_0 - (p_1 - p_2)|}{\sigma_g} \right) \\ p_1 - p_2 \leq p_0 & p_1 - p_2 > p_0 & \mathcal{W}_2 = \left\{ Z_W^{(\text{alt})}; Z_W^{(\text{alt})} \geq u(\alpha) \right\} & \Phi \left(u_{\alpha} + \frac{p_0 - (p_1 - p_2)}{\sigma_g} \right) \\ p_1 - p_2 \geq p_0 & p_1 - p_2 < p_0 & \mathcal{W}_3 = \left\{ Z_W^{(\text{alt})}; Z_W^{(\text{alt})} \leq -u(\alpha) \right\} & \Phi \left(u_{\alpha} - \frac{p_0 - (p_1 - p_2)}{\sigma_g} \right) \end{array}$$



Obr. 7.7: Silofunkcie alternatívneho Waldovho testu o $p_1 - p_2$ pre H_{11} (vľavo), H_{12} (uprostred) a H_{13} (vpravo)

Definícia 83 (p-hodnota $Z_W^{(alt)}$ testu o $p_1 - p_2$) Nech $Z_W^{(alt)}$ je nejaká testovacia štatistika a $z_W^{(alt)} = \frac{\hat{p}_1 - \hat{p}_2 - p_0}{s_g}$, kde $\hat{\sigma}_g^2 = s_g^2 = \hat{p}(1 - \hat{p}) \left(\frac{1}{N_1} + \frac{1}{N_2} \right)$, je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W^{(alt)} \geq |z_W^{(alt)}| | H_{01}), & \text{ak } H_{11} : p_1 - p_2 \neq p_0 \\ Pr(Z_W^{(alt)} \geq z_W^{(alt)} | H_{02}), & \text{ak } H_{12} : p_1 - p_2 > p_0 \\ Pr(Z_W^{(alt)} \leq z_W^{(alt)} | H_{03}), & \text{ak } H_{13} : p_1 - p_2 < p_0 \end{cases}$$

Definícia 84 (Alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $p_1 - p_2$) Alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $p_1 - p_2$ pre všetky tri typy hypotéz majú nasledovný tvar:

H_0	H_1	hranice (d, h) pre $100(1 - \alpha)\%$ empirický IS
$p_1 - p_2 = p_0$	$p_1 - p_2 \neq p_0$	$\mathcal{CS}_{1-\alpha} = \{p_0 : p_0 \in (\hat{p}_1 - \hat{p}_2 - u_{\alpha/2}s_g, \hat{p}_1 - \hat{p}_2 + u_{\alpha/2}s_g)\}$
$p_1 - p_2 \leq p_0$	$p_1 - p_2 > p_0$	$\mathcal{CS}_{1-\alpha} = \{p_0 : p_0 \in (\hat{p}_1 - \hat{p}_2 - u_{\alpha}s_g, \infty)\}$
$p_1 - p_2 \geq p_0$	$p_1 - p_2 < p_0$	$\mathcal{CS}_{1-\alpha} = \{p_0 : p_0 \in (-\infty, \hat{p}_1 - \hat{p}_2 + u_{\alpha}s_g)\}$

Majme H_{11} . Potom **minimálny rozsah** definujeme ako

$$N_1 \geq \left(\frac{u_{\alpha/2} + u_{\beta}}{p_1 - p_2} \right)^2 p(1-p) \left(\frac{k+1}{k} \right), N_2 = kN_1.$$

Ak $N_1 = N_2 = N$, tak $p = \frac{Np_1 + Np_2}{2N} = \frac{p_1 + p_2}{2}$. Ak $N_1 \neq N_2$, tak $p = \frac{N_1p_1 + kN_1p_2}{N_1 + kN_1} = \frac{p_1 + kp_2}{1+k}$. Pre H_{12} a H_{13} zameníme $u_{\alpha/2}$ za u_{α} .

Príklad 237 (minimálny rozsah) Sledujeme výskyt určitej choroby v ČR a v SR u žien. V minulosti sme zistili, že daná choroba sa nevyskytuje u žien s $p_1 = 0.6$ a $p_2 = 0.7$ a stanovili sme klinicky dôležitý rozdiel ako $p_2 - p_1 = 0.1$ na základe tejto minulej skúsenosti a vedomostí o tejto chorobe. Dalej nech sila Z-testu pri dojstrannej alternatíve je $1 - \beta = 0.90$ (pravdepodobnosť odhalenia tohoto rozdielu) a hladina významnosti $\alpha = 0.05$. Minimálne koľko žien musíme sledovať v ČR a v SR pri danej α a $1 - \beta$? Vypočítajte (a) pre $N_1 = N_2 = N$ ako aj pre (b) $N_1 = 2N_2$ (skutočnosť na základe počtu obyvateľov v ČR a v SR). Použite (1) Z_W a (2) $Z_W^{(alt)}$.

Riešenie

```

1279 "min.rozsah.n.p" <- function(p1,p2,alfa,sila,k){
1280 N1 <- ((qnorm(1-alfa/2)+qnorm(sila))/(p1-p2))^2*(p1*(1-p1)+p2*(1-p2)/k)
1281 N2 <- k*N1
1282 N <- round(c(N1,N2))
1283 p <- (p1+k*p2)/(1+k)
1284 N1.alt <- ((qnorm(1-alfa/2)+qnorm(sila))/(p1-p2))^2*(p*(1-p)*(k+1)/k)
1285 N2.alt <- k*N1.alt
1286 N.alt <- ceiling(c(N1.alt,N2.alt))
1287 rozsahy <- list(N=N,N.alt=N.alt)
1288 return(rozsahy)
1289 }
1290 min.rozsah.n.p(0.6,0.7,0.05,0.9,2)
1291 min.rozsah.n.p(0.6,0.7,0.05,0.9,1)

```

Pri použití Z_W sú minimálne rozsahy nasledovné – $N_1 = N_2 = 473$ pre homogénny dizajn; $N_1 = 363$ a $N_2 = 725$ pre nehomogénny dizajn. Pri použití $Z_W^{(alt)}$ sú minimálne rozsahy nasledovné – $N_1 = N_2 = 479$ pre homogénny dizajn; $N_1 = 351$ a $N_2 = 701$ pre nehomogénny dizajn.

Príklad 238 (porovnanie testovacích štatistík) Ukážte, že ak $N_1 = N_2$, potom $|Z_W^{(alt)}| \leq |Z_W|$. Naviac ak $X_1 = X_2$, potom $|Z_W^{(alt)}| = |Z_W|$.

Riešenie

Funkcia $f(x) = x(1-x)$ je konkávna na $\langle 0, 1 \rangle$. Pre ľubovoľné $\gamma \in \langle 0, 1 \rangle$ a pre ľubovoľné čísla $a, b \in \langle 0, 1 \rangle$ platí

$$f(\gamma a + (1-\gamma)b) \geq \gamma f(a) + (1-\gamma)f(b).$$

Ak zvolíme $\gamma = \frac{1}{2}$, $a = p_1$, $b = p_2$, potom dostaneme

$$\frac{1}{2}(p_1 + p_2) \left[1 - \frac{1}{2}(p_1 + p_2) \right] \geq \frac{1}{2}p_1(1-p_1) + \frac{1}{2}p_2(1-p_2).$$

Ak $N_1 = N_2$, máme $p = \frac{p_1+p_2}{2}$. Menovateľ Z_W má pod odmocninou

$$\frac{2}{N_1} \left[\frac{1}{2}p_1(1-p_1) + \frac{1}{2}p_2(1-p_2) \right],$$

menovateľ $Z_W^{(\text{alt})}$ má pod odmocninou

$$\frac{2}{N_1} \left[\frac{p_1+p_2}{2} \left(1 - \frac{p_1+p_2}{2} \right) \right].$$

Z nerovnosti uvedenej vyššie vyplýva, že $|Z_W^{(\text{alt})}| \leq |Z_W|$. Rovnosť v nerovnosti nastáva len vtedy, ak $p_1 = p_2$.

Pri $N_1 \neq N_2$, nie je medzi $Z_W^{(\text{alt})}$ a Z_W žiadny jednoduchý vzťah. Zdanlivo by pri $N_1 = N_2$ test založený na Z_W bol výhodnejší, lebo ma väčšiu silu $1 - \beta$ pri danej alternatíve, ale pri malom rozsahu výberu nám prináša väčšiu pravdepodobnosť CHPD než požadovaná α . Ak napr. pri $\alpha = 0.05$, $N_1 = N_2 = 20$, $\text{Pr}(\text{CHPD}) = 0.081$ a pri $N_1 = 20$, $N_2 = 40$ je $\text{Pr}(\text{CHPD}) = 0.085$.

Z predchádzajúceho príkladu vyplýva, že ak $N_1 = N_2$, potom minimálny rozsah N_1 vypočítaný z testovacej štatistiky $Z_W^{(\text{alt})}$ bude vždy väčší ako rozsah N_1 vypočítaný zo Z_W .

Dvojvýberový χ^2 -test o rozdiel pravdepodobností $p_1 - p_2$ v \mathbb{R} (funkcia `prop.test()`).

Argumenty (vstupy) funkcie:

1. vektor početností úspechov (n_1 a n_2) `x`;
2. vektor rozsahov (početnosti úspechov spolu s neúspechmi N_1 a N_2) `n`;
3. vektor pravdepodobností p_{01} a p_{02} za platnosti H_0 `p` ($p_{0j} \in (0, 1)$, kde $j = 1, 2$);
4. formulácia alternatívy `alternative="two.sided"` je prednastavené, ďalšie voľby sú "greater", "less";
5. spoľahlivosť `conf.level=p`, prednastavené je `conf.level=.95`;
6. Yatesova korekcia na spojitosť (Newcombe, 1998), prednastavené `correct = TRUE`.

Výstupy funkcie:

1. testovacia štatistika `statistic` ($\chi^2 = (Z_W^{(\text{alt})})^2$);
2. stupne voľnosti `df` (`parameter`; $df = 1$);
3. p-hodnota `p.value`;
4. odhad pravdepodobností \hat{p}_1 a \hat{p}_2 `estimate`;
5. interval spoľahlivosti pre $p_1 - p_2$ `conf.int` (prislúchajúci Z_W a nie $Z_W^{(\text{alt})}$);
6. alternatívna hypotéza `alternative hypothesis`;
7. názov použitého testu `method`.

Príklad 239 (programovanie; Z-testy rozdielu $p_1 - p_2$) Naprogramujte v \mathbb{R} klasický a alternatívny (a) Z-test o rozdiel pravdepodobností p_1 a p_2 a (b) Waldov 95% empirický DIS rozdielu pravdepodobností p_1 a p_2 .

Riešenie (aj v \mathbb{R})

```

1292 " test.rozdielu.prav" <- function(n1,n2,N1,N2){
1293   p1.hat <- n1/N1
1294   p2.hat <- n2/N2
1295   # klasicky Z-test a IS
1296   sg.sq <- p1.hat*(1-p1.hat)/N1+p2.hat*(1-p2.hat)/N2
1297   zW <- (p1.hat-p2.hat)/sqrt(sg.sq)
1298   p.hodn <- 1-pnorm(abs(zW))
1299   IS <- p1.hat-p2.hat+c(-1,1)*qnorm(0.975)*sqrt(sg.sq)
1300   Ztest <- c(IS,zW,p.hodn)
1301   # alternativny Z-test a IS
1302   p.hat <- (N1+p1.hat+N2+p2.hat)/(N1+N2)
1303   sg.sq.alt <- p.hat*(1-p.hat)*(1/N1+1/N2)
1304   zW.alt <- (p1.hat-p2.hat)/sqrt(sg.sq.alt)
1305   p.hodn.alt <- 1-pnorm(abs(zW.alt))
1306   ISalt <- p1.hat-p2.hat+c(-1,1)*qnorm(0.975)*sqrt(sg.sq.alt)
1307   Ztest.alt <- c(ISalt,zW.alt,p.hodn.alt)
1308   # vysledky
1309   Z.test <- rbind(Ztest,Ztest.alt)
1310   dimnames(Z.test)[[2]] <- c("DH","HH","Z-stat","p-hodnota")
1311   dimnames(Z.test)[[1]] <- c("Ztest(p1-p2)","Ztest.alt(p1-p2)")
1312   # odhady
1313   odhady <- c(p.hat,p1.hat,p2.hat,p1.hat-p2.hat,sqrt(sg.sq),sqrt(sg.sq.alt))
1314   names(odhady) <- c("p","p1","p2","rozdiel","sd","sd.alt")
1315   VYSL <- list(odhady=round(odhady,4),Z.test=round(Z.test,4))
1316   return(VYSL)
1317 }

```

Príklad 240 (zuby a tepelný šok; rozdiel rizík) Z 50 zubov vystavených tepelnému šoku sa 21 zlomilo. Z kontrolných 50 zubov sa zlomilo len 11. (a) Znižuje tepelný šok mechanickú odolnosť zubov? Porovnajme výsledky klasického a alternatívneho Z-testu rozdielu pravdepodobností. (b) Vypočítajte klasický a alternatívny Waldov 95% empirický DIS rozdielu pravdepodobností p_1 a p_2 zlomenia sa zuba.

Riešenie (aj v \mathbb{R})

$N_1 = N_2 = 50, n_1 = 21, n_2 = 11, \hat{p}_1 = 0.42, \hat{p}_2 = 0.22, \hat{p} = 0.32.$

$z_W \doteq 2.195$, p-hodnota $\doteq 0.014$ a H_0 zamietame na $\alpha = 0.05$.

Waldov 95% empirický DIS rozdielu pravdepodobností p_1 a p_2 : $(d, h) \doteq (0.0214, 0.3786)$

$z_W^{(alt)} \doteq 2.144$, p-hodnota $\doteq 0.016$ a H_0 zamietame na $\alpha = 0.05$.

Alternatívny Waldov 95% empirický DIS rozdielu pravdepodobností p_1 a p_2 : $(d, h) \doteq (0.017, 0.383)$

```

1318 test.rozdielu.prav(21,11,50,50)
1319 ##$odhady
1320 #      p      p1      p2 rozdiel      sd      sd.alt
1321 # 0.3200 0.4200 0.2200 0.2000 0.0911 0.0933
1322 ##$Z.test
1323 #              DH      HH Z-stat p-hodnota
1324 #Ztest(p1-p2) 0.0214 0.3786 2.1948 0.0141
1325 #Ztest.alt(p1-p2) 0.0171 0.3829 2.1437 0.0160

```

Relatívne riziko p_1/p_2 . Majme dvojice hypotéz $H_{01} : \ln RR = \ln RR_0$ oproti $H_{11} : \ln RR \neq \ln RR_0$, $H_{02} : \ln RR \leq \ln RR_0$ oproti $H_{12} : \ln RR > \ln RR_0$, $H_{03} : \ln RR \geq \ln RR_0$ oproti $H_{13} : \ln RR < \ln RR_0$, ktoré chceme testovať. Hypotézy H_0 sa často nazývajú **hypotézy homogenity dvoch binomických rozdelení**, ak $\ln RR_0 = 0$.

Ak H_0 platí, potom

$$Z_W = \frac{\ln \frac{X_1/N_1}{X_2/N_2} - \ln RR_0}{S_g} \mathcal{D} N(0, 1),$$

kde $S_g^2 = \text{Var}[\ln(X_1/N_1)] + \text{Var}[\ln(X_2/N_2)] = \frac{1-X_1/N_1}{X_1} + \frac{1-X_2/N_2}{X_2} \neq 0$. Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojvýberový Z-test o logaritme relatívneho rizika**. Rozptyl σ_g^2 vypočítame pomocou δ -metódy z rozptylov $\text{Var}[\ln p_j]$, $j = 1, 2$, kde

$$\text{Var}[\ln p_j] \approx \left(\frac{\partial \ln p_j}{\partial p_j} \right)^2 \text{Var}[p_j] = \left(\frac{1}{p_j} \right)^2 \frac{p_j(1-p_j)}{N_j} = \frac{1-p_j}{N_j p_j}.$$

Asymptoticky

$$Z_W = \frac{\ln(X_j/N_j) - \ln p_0}{\sqrt{\text{Var}[\ln(X_j/N_j)]}} \mathcal{D} N(0, 1).$$

Keďže $\ln RR = \ln p_1 - \ln p_2$ a p_1 a p_2 sú nezávislé, potom (Katz a kol., 1978)

$$\sigma_g^2 = \text{Var}[\ln RR] = \text{Var}[\ln p_1] + \text{Var}[\ln p_2] = \frac{1-p_1}{N_1 p_1} + \frac{1-p_2}{N_2 p_2} = \frac{1-p_1}{n_1} + \frac{1-p_2}{n_2} = \frac{1}{n_1} - \frac{1}{N_1} + \frac{1}{n_2} - \frac{1}{N_2}.$$

Definícia 85 (p-hodnota Z_W testu o $\ln RR$) Nech Z_W je *nejaká testovacia štatistika* a $z_W = \frac{\ln \widehat{RR} - \ln RR_0}{s_g}$, kde $\ln \widehat{RR} = \ln \frac{\widehat{p}_1}{\widehat{p}_2}$ a $\widehat{\sigma}_g^2 = s_g^2 = \frac{1-\widehat{p}_1}{N_1 \widehat{p}_1} + \frac{1-\widehat{p}_2}{N_2 \widehat{p}_2}$, je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : \ln RR \neq \ln RR_0 \\ \Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : \ln RR > \ln RR_0 \\ \Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : \ln RR < \ln RR_0 \end{cases}$$

Ak za platnosti H_0 berieme pri výpočte do úvahy, že $p_1 = p_2$, potom dostaneme alternatívny rozptyl, ktorý bude rovný

$$\sigma_g^2 = \text{Var}[\ln RR] = \frac{1-p}{p} \left(\frac{1}{N_1} + \frac{1}{N_2} \right) = \frac{1-p}{p} \frac{N}{N_1 N_2},$$

kde $N = N_1 + N_2$. Potom

$$Z_W^{(\text{alt})} = \frac{\ln \frac{X_1/N_1}{X_2/N_2} - \ln RR_0}{S_g} \stackrel{\mathcal{D}}{\sim} N(0, 1),$$

kde $S_g^2 = \frac{1-X/N}{X/N} \left(\frac{1}{N_1} + \frac{1}{N_2} \right) \neq 0$, kde $X = N_1 X_1 / N_1 + N_2 X_2 / N_2$. $Z_W^{(\text{alt})}$ sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **alternatívny dvojvýberový Z-test o logaritme relatívneho rizika**.

Definícia 86 (p-hodnota $Z_W^{(\text{alt})}$ testu o $\ln RR$) Nech $Z_W^{(\text{alt})}$ je *nejaká testovacia štatistika* a $z_W^{(\text{alt})} = \frac{\ln \widehat{RR} - \ln RR_0}{s_g}$, kde $\widehat{\sigma}_g^2 = s_g^2 = \frac{1-\widehat{p}}{\widehat{p}} \left(\frac{1}{N_1} + \frac{1}{N_2} \right)$, je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\Pr(Z_W^{(\text{alt})} \geq |z_W^{(\text{alt})}| | H_{01}), & \text{ak } H_{11} : \ln RR \neq \ln RR_0 \\ \Pr(Z_W^{(\text{alt})} \geq z_W^{(\text{alt})} | H_{02}), & \text{ak } H_{12} : \ln RR > \ln RR_0 \\ \Pr(Z_W^{(\text{alt})} \leq z_W^{(\text{alt})} | H_{03}), & \text{ak } H_{13} : \ln RR < \ln RR_0 \end{cases}$$

Definícia 87 (Klasické a alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $\ln RR$)

Klasické a alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $\ln RR$ (dosadí sa smerodajná odchýlka s_g prislúchajúca jednému z testov) pre všetky tri typy hypotéz majú nasledovný tvar:

$$\left. \begin{array}{lll} H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1 - \alpha)\% \text{ empirický IS} \\ \ln RR = \ln RR_0 & \ln RR \neq \ln RR_0 & \mathcal{CS}_{1-\alpha} = \left\{ \ln RR_0 : \ln RR \in \left(\ln \widehat{RR} - u_{\alpha/2} s_g, \widehat{RR} + u_{\alpha/2} s_g \right) \right\} \\ \ln RR \leq \ln RR_0 & \ln RR > \ln RR_0 & \mathcal{CS}_{1-\alpha} = \left\{ \ln RR_0 : \ln RR \in \left(\ln \widehat{RR} - u_{\alpha} s_g, \infty \right) \right\} \\ \ln RR \geq \ln RR_0 & \ln RR < \ln RR_0 & \mathcal{CS}_{1-\alpha} = \left\{ \ln RR_0 : \ln RR \in \left(-\infty, \ln \widehat{RR} + u_{\alpha} s_g \right) \right\} \end{array} \right\}$$

Majme dvojice hypotéz $H_{01} : RR = RR_0$ oproti $H_{11} : RR \neq RR_0$, $H_{02} : RR \leq RR_0$ oproti $H_{12} : RR > RR_0$, $H_{03} : RR \geq RR_0$ oproti $H_{13} : RR < RR_0$, ktoré chceme testovať. Hypotézy H_0 sa často nazývajú **hypotézy homogenity dvoch binomických rozdelení**, ak $RR_0 = 1$.

Ak H_0 platí, potom

$$Z_W = \frac{\frac{X_1/N_1}{X_2/N_2} - RR_0}{S_g} \mathcal{D} N(0, 1),$$

kde z δ -metódy pomocou rozptylu $\ln RR$ (a rovnosti $Var[RR] \approx RR^2 Var[\ln RR]$) dostaneme $S_g^2 \approx \left(\frac{X_1/N_1}{X_2/N_2}\right)^2 \left(\frac{1-X_1/N_1}{X_1} + \frac{1-X_2/N_2}{X_2}\right) \neq 0$. Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojvýberový Z-test o relatívnom riziku**.

Definícia 88 (p-hodnota Z_W testu o RR) *Nech Z_W je nejaká testovacia štatistika a $z_W = \frac{\widehat{RR} - RR_0}{s_g}$, kde $\widehat{RR} = \frac{\hat{p}_1}{\hat{p}_2}$ a $\hat{\sigma}_g^2 = s_g^2 = \widehat{RR}^2 \left(\frac{1-\hat{p}_1}{N_1\hat{p}_1} + \frac{1-\hat{p}_2}{N_2\hat{p}_2}\right)$, je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:*

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : RR \neq RR_0 \\ Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : RR > RR_0 \\ Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : RR < RR_0 \end{cases}$$

Ak za platnosti H_0 berieme pri výpočte do úvahy, že $p_1 = p_2$, potom dostaneme alternatívnu testovaciu štatistiku, ktorá bude mať nasledovný tvar

$$Z_W^{(alt)} = \frac{\frac{X_1/N_1}{X_2/N_2} - RR_0}{S_g} \mathcal{D} N(0, 1),$$

kde z δ -metódy pomocou rozptylu $\ln RR$ dostaneme $S_g^2 \approx \left(\frac{X_1/N_1}{X_2/N_2}\right)^2 \times \frac{1-X/N}{X/N} \left(\frac{1}{N_1} + \frac{1}{N_2}\right) \neq 0$. $Z_W^{(alt)}$ sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **alternatívny dvojvýberový Z-test o relatívnom riziku**.

Definícia 89 (p-hodnota $Z_W^{(alt)}$ testu o RR) *Nech $Z_W^{(alt)}$ je nejaká testovacia štatistika a $z_W^{(alt)} = \frac{\widehat{RR} - RR_0}{s_g}$, kde $\hat{\sigma}_g^2 = s_g^2 = \widehat{RR}^2 \frac{1-\hat{p}}{\hat{p}} \left(\frac{1}{N_1} + \frac{1}{N_2}\right)$, je jej realizácia (pozorovaná, vypočítaná testovacia štatistika), potom p-hodnotu počítame nasledovne:*

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W^{(alt)} \geq |z_W^{(alt)}| | H_{01}), & \text{ak } H_{11} : RR \neq RR_0 \\ Pr(Z_W^{(alt)} \geq z_W^{(alt)} | H_{02}), & \text{ak } H_{12} : RR > RR_0 \\ Pr(Z_W^{(alt)} \leq z_W^{(alt)} | H_{03}), & \text{ak } H_{13} : RR < RR_0 \end{cases}$$

Definícia 90 (Klasické a alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre RR)

Klasické a alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre RR (dosadí sa smerodajná odchýlka s_g prislúchajúca jednému z testov) pre všetky tri typy hypotéz majú nasledovný tvar

$$\begin{array}{lll} H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1 - \alpha)\% \text{ empirický IS} \\ RR = RR_0 & RR \neq RR_0 & \mathcal{CS}_{1-\alpha} = \left\{ RR_0 : RR_0 \in \left(\widehat{RR} - u_{\alpha/2} s_g, \ln \widehat{RR} + u_{\alpha/2} s_g \right) \right\} \\ RR \leq RR_0 & RR > RR_0 & \mathcal{CS}_{1-\alpha} = \left\{ RR_0 : RR_0 \in \left(\widehat{RR} - u_{\alpha} s_g, \infty \right) \right\} \\ RR \geq RR_0 & RR < RR_0 & \mathcal{CS}_{1-\alpha} = \left\{ RR_0 : RR_0 \in \left(0, \widehat{RR} + u_{\alpha} s_g \right) \right\} \end{array}$$

Príklad 241 (programovanie; Z-testy pre $\ln RR$ a RR) Naprogramujte v \mathbb{R} (a) klasický a alternatívny Z-test o logaritme relatívneho rizika $\ln p_1/p_2$ a (b) klasický a alternatívny Z-test relatívneho rizika p_1/p_2 , (c) klasický a alternatívny Waldov 95% empirický DIS relatívneho rizika (spätne transformovaný klasický a alternatívny Waldov 95% empirický DIS logaritmu relatívneho rizika) a (d) klasický a alternatívny Waldov 95% empirický DIS relatívneho rizika. Funkciu nazvite `test.relat.rizika()`.

Príklad 242 (zuby a tepelný šok; podiel rizík) Z 50 zubov vystavených tepelnému šoku sa 21 zlomilo. Z kontrolných 50 zubov sa zlomilo len 11. (a) Znižuje tepelný šok mechanickú odolnosť zubov? Porovnajte výsledky klasického a alternatívneho Z-testu (1) logaritmu podielu rizík a (2) podielu rizík. Vypočítajte (b) klasický a alternatívny Waldov 95% empirický DIS relatívneho rizika (spätne transformovaný klasický a alternatívny Waldov 95% empirický DIS logaritmu relatívneho rizika) zlomenia sa zuba a (c) klasický a alternatívny Waldov 95% empirický DIS relatívneho rizika zlomenia sa zuba.

Riešenie (aj v \mathbb{R})

$N_1 = N_2 = 50, n_1 = 21, n_2 = 11, \hat{p}_1 = 0.42, \hat{p}_2 = 0.22, \hat{p} = 0.32, \widehat{RR} = 1.91$.

Z-testy logaritmu relatívneho rizika a Waldove 95% empirické DIS pre relatívne riziko (spätne transformované DIS pre logaritmus relatívneho rizika):

$z_W \doteq 2.060$, p-hodnota $\doteq 0.020$ a H_0 zamietame na $\alpha = 0.05$.

Waldov 95% empirický DIS pre relatívne riziko RR: $(d, h) \doteq (1.032, 3.532)$

$z_W^{(\text{alt})} \doteq 2.220$, p-hodnota $\doteq 0.013$ a H_0 zamietame na $\alpha = 0.05$.

Alternatívny Waldov 95% empirický DIS pre relatívne riziko RR: $(d, h) \doteq (1.078, 3.381)$

Z-testy relatívneho rizika a Waldove 95% empirické DIS pre relatívne riziko:

$z_W \doteq 1.517$, p-hodnota $\doteq 0.065$ a H_0 nezamietame na $\alpha = 0.05$.

Waldov 95% empirický DIS pre relatívne riziko RR: $(d, h) \doteq (0.735, 3.084)$

$z_W^{(\text{alt})} \doteq 1.633$, p-hodnota $\doteq 0.051$ a H_0 nezamietame na $\alpha = 0.05$.

Alternatívny Waldov 95% empirický DIS pre relatívne riziko RR: $(d, h) \doteq (0.818, 3.000)$

```

1326 | test.relat.rizika(21,11,50,50)
1327 | ###$odhady
1328 | #      p      p1      p2      RR      sd(lnRR)      sd.alt(lnRR)      sd(RR)      sd.alt(RR)
1329 | # 0.3200 0.4200 0.2200 1.9091 0.3139 0.2915 0.5992 0.5566
1330 | ###$Ztest
1331 | #      DH      HH Z-stat p-hodnota
1332 | #Ztest(lnRR) 1.0319 3.5319 2.0600 0.0197
1333 | #Ztest.alt(lnRR) 1.0781 3.3806 2.2179 0.0133
1334 | #Ztest(RR) 0.7346 3.0836 1.5171 0.0646
1335 | #Ztest.alt(RR) 0.8182 3.0000 1.6333 0.0512

```

Pomer šancí $\frac{p_1/(1-p_1)}{p_2/(1-p_2)}$. Majme dvojice hypotéz $H_{01} : \ln OR = \ln OR_0$ oproti $H_{11} : \ln OR \neq \ln OR_0$, $H_{02} : \ln OR \leq \ln OR_0$ oproti $H_{12} : \ln OR > \ln OR_0$, $H_{03} : \ln OR \geq \ln OR_0$ oproti $H_{13} : \ln OR < \ln OR_0$, ktoré chceme testovať. Hypotézy H_0 sa často nazývajú **hypotézy homogenity dvoch binomických rozdelení**, ak $\ln OR_0 = 0$.

Ak H_0 platí, potom

$$Z_W = \frac{\ln \frac{(X_1/N_1)/(1-X_1/N_1)}{(X_2/N_2)/(1-X_2/N_2)} - \ln OR_0}{S_g} \underset{\mathcal{D}}{\sim} N(0, 1),$$

kde $S_g^2 = \frac{1}{N_1 X_1/N_1(1-X_1/N_1)} + \frac{1}{N_2 X_2/N_2(1-X_2/N_2)} = \frac{1}{N_1} + \frac{1}{N_1 - X_1} + \frac{1}{N_2} + \frac{1}{N_2 - X_2}$. Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojvýberový Z-test o logaritme pomeru šancí**. $Var[\ln OR]$ vypočítame na základe invariantnosti MLE $\boldsymbol{\theta} = (p_1, p_2)^T$ platí (Woolf, 1955)

$$\mathcal{I}^{-1}(\boldsymbol{\theta}) = \begin{pmatrix} \frac{p_1(1-p_1)}{N_1} & 0 \\ 0 & \frac{p_2(1-p_2)}{N_2} \end{pmatrix}$$

a pre $g(\boldsymbol{\theta}) = \ln \frac{p_1}{1-p_1} - \ln \frac{p_2}{1-p_2}$ platí

$$\boldsymbol{\Delta} = \frac{\partial}{\partial \boldsymbol{\theta}} g(\boldsymbol{\theta}) = \left(\frac{\partial}{\partial p_1} g(\boldsymbol{\theta}), \frac{\partial}{\partial p_2} g(\boldsymbol{\theta}) \right)^T = \left(\frac{1}{p_1(1-p_1)}, \frac{-1}{p_2(1-p_2)} \right)^T.$$

Potom

$$\sigma_g^2 = \text{Var}[\ln \text{OR}] = \boldsymbol{\Delta}^T \mathcal{I}^{-1}(\boldsymbol{\theta}) \boldsymbol{\Delta} = \frac{1}{N_1 p_1 (1-p_1)} + \frac{1}{N_2 p_2 (1-p_2)}.$$

Definícia 91 (p-hodnota Z_W testu o $\ln \text{OR}$) Nech Z_W je *nejaká testovacia štatistika* a $z_W = \frac{\ln \widehat{\text{OR}} - \ln \text{OR}_0}{s_g}$, kde $\ln \widehat{\text{OR}} = \ln \frac{\widehat{p}_1 / (1-\widehat{p}_1)}{\widehat{p}_2 / (1-\widehat{p}_2)}$ a $\widehat{\sigma}_g^2 = s_g^2 = \frac{1}{N_1 \widehat{p}_1 (1-\widehat{p}_1)} + \frac{1}{N_2 \widehat{p}_2 (1-\widehat{p}_2)}$, je jej realizácia (*pozorovaná, vypočítaná testovacia štatistika*), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\text{Pr}(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : \ln \text{OR} \neq \ln \text{OR}_0 \\ \text{Pr}(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : \ln \text{OR} > \ln \text{OR}_0 \\ \text{Pr}(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : \ln \text{OR} < \ln \text{OR}_0 \end{cases}$$

Ak za platnosti H_0 berieme pri výpočte do úvahy, že $p_1 = p_2$, potom dostaneme alternatívny rozptyl, ktorý bude rovný

$$\sigma_g^2 = \text{Var}[\ln \text{OR}] = \frac{1}{p(1-p)} \left(\frac{1}{N_1} + \frac{1}{N_2} \right) = \frac{N}{p(1-p)N_1N_2},$$

Potom

$$Z_W^{(\text{alt})} = \frac{\ln \frac{(X_1/N_1)/(1-X_1/N_1)}{(X_2/N_2)/(1-X_2/N_2)} - \ln \text{OR}_0}{S_g} \stackrel{\mathcal{D}}{\sim} N(0, 1),$$

kde $S_g^2 = \frac{1}{\bar{X}/N(1-\bar{X}/N)} \left(\frac{1}{N_1} + \frac{1}{N_2} \right) = \frac{N1}{\bar{X}/N(1-\bar{X}/N)N_1N_2} \neq 0$. $Z_W^{(\text{alt})}$ sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **alternatívny dvojvýberový Z-test o logaritme pomeru šancí**.

Definícia 92 (p-hodnota $Z_W^{(\text{alt})}$ testu o $\ln \text{OR}$) Nech $Z_W^{(\text{alt})}$ je *nejaká testovacia štatistika* a $z_W^{(\text{alt})} = \frac{\ln \widehat{\text{OR}} - \ln \text{OR}_0}{s_g}$, kde $\widehat{\sigma}_g^2 = s_g^2 = \frac{1}{\widehat{p}(1-\widehat{p})} \left(\frac{1}{N_1} + \frac{1}{N_2} \right)$, je jej realizácia (*pozorovaná, vypočítaná testovacia štatistika*), potom p-hodnotu počítame nasledovne:

$$p\text{-hodnota} = \begin{cases} 2\text{Pr}(Z_W^{(\text{alt})} \geq |z_W^{(\text{alt})}| | H_{01}), & \text{ak } H_{11} : \ln \text{OR} \neq \ln \text{OR}_0 \\ \text{Pr}(Z_W^{(\text{alt})} \geq z_W^{(\text{alt})} | H_{02}), & \text{ak } H_{12} : \ln \text{OR} > \ln \text{OR}_0 \\ \text{Pr}(Z_W^{(\text{alt})} \leq z_W^{(\text{alt})} | H_{03}), & \text{ak } H_{13} : \ln \text{OR} < \ln \text{OR}_0 \end{cases}$$

Definícia 93 (Klasické a alternatívne Waldove $100 \times (1-\alpha)\%$ empirické IS pre $\ln \text{OR}$) Klasické a alternatívne Waldove $100 \times (1-\alpha)\%$ empirické IS pre $\ln \text{OR}$ (dosadí sa smerodajná odchýlka s_g prislúchajúca jednému z testov) pre všetky tri typy hypotéz majú nasledovný tvar

$$\begin{array}{lll} H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1-\alpha)\% \text{ empirický IS} \\ \ln \text{OR} = \ln \text{OR}_0 & \ln \text{OR} \neq \ln \text{OR}_0 & \mathcal{CS}_{1-\alpha} = \left\{ \ln \text{OR}_0 : \ln \text{OR}_0 \in (\ln \widehat{\text{OR}} - u_{\alpha/2} s_g, \ln \widehat{\text{OR}} + u_{\alpha/2} s_g) \right\} \\ \ln \text{OR} \leq \ln \text{OR}_0 & \ln \text{OR} > \ln \text{OR}_0 & \mathcal{CS}_{1-\alpha} = \left\{ \ln \text{OR}_0 : \ln \text{OR}_0 \in (\ln \widehat{\text{OR}} - u_{\alpha} s_g, \infty) \right\} \\ \ln \text{OR} \geq \ln \text{OR}_0 & \ln \text{OR} < \ln \text{OR}_0 & \mathcal{CS}_{1-\alpha} = \left\{ \ln \text{OR}_0 : \ln \text{OR}_0 \in (-\infty, \ln \widehat{\text{OR}} + u_{\alpha} s_g) \right\} \end{array}$$

Majme dvojice hypotéz $H_{01} : OR = OR_0$ oproti $H_{11} : OR \neq OR_0$, $H_{02} : OR \leq OR_0$ oproti $H_{12} : OR > OR_0$, $H_{03} : OR \geq OR_0$ oproti $H_{13} : OR < OR_0$, ktoré chceme testovať. Hypotézy H_0 sa často nazývajú **hypotézy homogenity dvoch binomických rozdelení**, ak $OR_0 = 1$.

Ak H_0 platí, potom

$$Z_W = \frac{(X_1/N_1)/(1-X_1/N_1)}{(X_2/N_2)/(1-X_2/N_2)} - OR_0 \stackrel{\mathcal{D}}{\sim} N(0, 1),$$

kde z δ -metódy ($Var[OR] \approx OR^2 Var[\ln OR]$) pomocou rozptylu $\ln OR$ dostaneme

$$S_g^2 \approx \left(\frac{(X_1/N_1)/(1-X_1/N_1)}{(X_2/N_2)/(1-X_2/N_2)} \right)^2 \left(\frac{1}{N_1} + \frac{1}{N_1 - X_1} + \frac{1}{N_2} + \frac{1}{N_2 - X_2} \right) \neq 0.$$

Z_W sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **dvojjvýberový Z-test o pomere šancí**.

Definícia 94 (p-hodnota Z_W testu o OR) *Nech Z_W je nejaká testovacia štatistika a $z_W = \frac{\widehat{OR} - OR_0}{s_g}$, kde $\widehat{OR} = \frac{\widehat{p}_1/(1-\widehat{p}_1)}{\widehat{p}_2/(1-\widehat{p}_2)}$ a $\widehat{\sigma}_g^2 = s_g^2 = \widehat{OR}^2 \left(\frac{1}{N_1\widehat{p}_1(1-\widehat{p}_1)} + \frac{1}{N_2\widehat{p}_2(1-\widehat{p}_2)} \right)$, je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:*

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W \geq |z_W| | H_{01}), & \text{ak } H_{11} : OR \neq OR_0 \\ Pr(Z_W \geq z_W | H_{02}), & \text{ak } H_{12} : OR > OR_0 \\ Pr(Z_W \leq z_W | H_{03}), & \text{ak } H_{13} : OR < OR_0 \end{cases}$$

Ak za platnosti H_0 berieme pri výpočte do úvahy, že $p_1 = p_2$, potom dostaneme alternatívnu testovaciu štatistiku, ktorá bude mať nasledovný tvar

$$Z_W^{(alt)} = \frac{(X_1/N_1)/(1-X_1/N_1)}{(X_2/N_2)/(1-X_2/N_2)} - OR_0 \stackrel{\mathcal{D}}{\sim} N(0, 1),$$

kde z δ -metódy pomocou rozptylu $\ln OR$ dostaneme

$$S_g^2 \approx \left(\frac{(X_1/N_1)/(1-X_1/N_1)}{(X_2/N_2)/(1-X_2/N_2)} \right)^2 \times \frac{N_1}{X/N(1-X/N)N_1N_2} \neq 0.$$

$Z_W^{(alt)}$ sa nazýva **Waldova testovacia štatistika** (alebo **Z-štatistika**) a test **alternatívny dvojjvýberový Z-test o pomere šancí**.

Definícia 95 (p-hodnota $Z_W^{(alt)}$ testu o OR) *Nech $Z_W^{(alt)}$ je nejaká testovacia štatistika a $z_W^{(alt)} = \frac{\widehat{OR} - OR_0}{s_g}$, kde $\widehat{\sigma}_g^2 = s_g^2 = \widehat{OR}^2 \frac{1}{\widehat{p}(1-\widehat{p})} \left(\frac{1}{N_1} + \frac{1}{N_2} \right)$, je jej realizácia (**pozorovaná, vypočítaná testovacia štatistika**), potom p-hodnotu počítame nasledovne:*

$$p\text{-hodnota} = \begin{cases} 2Pr(Z_W^{(alt)} \geq |z_W^{(alt)}| | H_{01}), & \text{ak } H_{11} : OR \neq OR_0 \\ Pr(Z_W^{(alt)} \geq z_W^{(alt)} | H_{02}), & \text{ak } H_{12} : OR > OR_0 \\ Pr(Z_W^{(alt)} \leq z_W^{(alt)} | H_{03}), & \text{ak } H_{13} : OR < OR_0 \end{cases}$$

Definícia 96 (Klasické a alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre OR)

Klasické a alternatívne Waldove $100 \times (1 - \alpha)\%$ empirické IS pre $\ln OR$ (dosadí sa smerodajná odchýlka s_g prislúchajúca jednému z testov) pre všetky tri typy hypotéz majú nasledovný tvar

$$\begin{array}{lll} H_0 & H_1 & \text{hranice } (d, h) \text{ pre } 100(1 - \alpha)\% \text{ empirický IS} \\ OR = OR_0 & OR \neq OR_0 & \mathcal{CS}_{1-\alpha} = \left\{ OR_0 : OR_0 \in \left(\widehat{OR} - u_{\alpha/2}s_g, \widehat{OR} + u_{\alpha/2}s_g \right) \right\} \\ OR \leq OR_0 & OR > OR_0 & \mathcal{CS}_{1-\alpha} = \left\{ OR_0 : OR_0 \in \left(\widehat{OR} - u_{\alpha}s_g, \infty \right) \right\} \\ OR \geq OR_0 & OR < OR_0 & \mathcal{CS}_{1-\alpha} = \left\{ OR_0 : OR_0 \in \left(0, \widehat{OR} + u_{\alpha}s_g \right) \right\} \end{array}$$

Príklad 243 (programovanie; Z-testy pre OR a ln OR) Naprogramujte v \mathbb{R} (a) klasický a alternatívny Z-test o logaritme pomeru šancí $\ln \frac{p_1/(1-p_1)}{p_2/(1-p_2)}$ a (b) klasický a alternatívny Z-test pomeru šancí $p_1/(1-p_1)p_2/(1-p_2)$, (c) klasický a alternatívny Waldov 95% empirický DIS pomeru šancí (spätne transformovaný klasický a alternatívny Waldov 95% empirický DIS logaritmu pomeru šancí) a (d) klasický a alternatívny Waldov 95% empirický DIS pomeru šancí. Funkciu nazvite `test.pomeru.sanci()`.

Príklad 244 (zuby a tepelný šok; pomer šancí) Z 50 zubov vystavených tepelnému šoku sa 21 zlomilo. Z kontrolných 50 zubov sa zlomilo len 11. (a) Znižuje tepelný šok mechanickú odolnosť zubov? Porovnajte výsledky klasického a alternatívneho Z-testu (1) logaritmu pomeru šancí a (2) pomeru šancí. Vypočítajte (b) klasický a alternatívny Waldov 95% empirický DIS pomeru šancí (spätne transformovaný klasický a alternatívny Waldov 95% empirický DIS logaritmu pomeru šancí) zlomenia sa zuba a (c) klasický a alternatívny Waldov 95% empirický DIS pomeru šancí zlomenia sa zuba.

Riešenie (aj v \mathbb{R})

$N_1 = N_2 = 50, n_1 = 21, n_2 = 11, \hat{p}_1 = 0.42, \hat{p}_2 = 0.22, \hat{p} = 0.32, \widehat{OR} = 1.91$.

Z-testy logaritmu pomeru šancí a Waldove 95% empirické DIS pre pomer šancí (spätne transformované DIS pre logaritmus pomeru šancí):

$z_W \doteq 2.116$, p-hodnota $\doteq 0.017$ a H_0 zamietame na $\alpha = 0.05$.

Waldov 95% empirický DIS pre pomer šancí OR: $(d, h) \doteq (1.072, 6.150)$.

$z_W^{(\text{alt})} \doteq 2.120$, p-hodnota $\doteq 0.014$ a H_0 zamietame na $\alpha = 0.05$.

Alternatívny Waldov 95% empirický DIS pre pomer šancí OR: $(d, h) \doteq (1.108, 5.949)$.

Z-testy pomeru šancí a Waldove 95% empirické DIS pre pomer šancí:

$z_W \doteq 1.370$, p-hodnota $\doteq 0.085$ a H_0 nezamietame na $\alpha = 0.05$.

Waldov 95% empirický DIS pre pomer šancí OR: $(d, h) \doteq (0.325, 4.810)$.

$z_W^{(\text{alt})} \doteq 1.424$, p-hodnota $\doteq 0.077$ a H_0 nezamietame na $\alpha = 0.05$.

Alternatívny Waldov 95% empirický DIS pre pomer šancí OR: $(d, h) \doteq (0.410, 4.724)$.

```

1336 | test.pomeru.sanci(21,11,50,50)
1337 | ##$odhady
1338 | #      p      p1      p2      OR      sd(lnOR)      sd.alt(lnOR)      sd(OR)      sd.alt(OR)
1339 | # 0.3200 0.4200 0.2200 2.5674 0.4457 0.4287 1.1443 1.1008
1340 | ##$Ztest
1341 | #              DH              HH Z-stat p-hodnota
1342 | #Ztest(lnOR) 1.0718 6.1500 2.1155 0.0172
1343 | #Ztest.alt(lnOR) 1.1080 5.9490 2.1992 0.0139
1344 | #Ztest(OR) 0.3246 4.8102 1.3697 0.0854
1345 | #Ztest.alt(OR) 0.4099 4.7249 1.4239 0.0772

```

Test pomerom vierohodnosti pre $p_1 - p_2$.

Majme H_{01} oproti H_{11} . Nech $X_j \sim \text{Bin}(N_j, p_j)$, $j = 1, 2$, sú nezávislé náhodné premenné. Funkcia vierohodnosti binomického rozdelenia pre p_1 a p_2 bude mať tvar

$$L(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{x}_2) = p_1^{n_1} (1 - p_1)^{N_1 - n_1} p_2^{n_2} (1 - p_2)^{N_2 - n_2},$$

kde $\boldsymbol{\theta} = (p_1, p_2)^T$. MLE $\boldsymbol{\theta}$ je rovný $\hat{\boldsymbol{\theta}} = (\hat{p}_1, \hat{p}_2)^T$, kde $\hat{p}_1 = n_1/N_1$ a $\hat{p}_2 = n_2/N_2$, t.j. $\Theta_1 = \{\boldsymbol{\theta} : p_1 \neq p_2 \neq p\}$. Za platnosti H_{01} je $\boldsymbol{\theta}_0 = (\hat{p}, \hat{p})^T$, kde $\hat{p} = \frac{N_1 \hat{p}_1 + N_2 \hat{p}_2}{N_1 + N_2}$ a $\Theta_0 = \{\boldsymbol{\theta} : p_1 = p_2 = p\}$. Potom -1

krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{x}_1, \mathbf{x}_2)) &= l(\hat{\boldsymbol{\theta}}|\mathbf{x}_1, \mathbf{x}_2) - l(\boldsymbol{\theta}_0|\mathbf{x}_1, \mathbf{x}_2) \\ &= \sum_{j=1}^2 n_j \ln \hat{p}_j + \sum_{j=1}^2 (N_j - n_j) \ln(1 - \hat{p}_j) - \sum_{j=1}^2 n_j \ln \hat{p} - \sum_{j=1}^2 (N_j - n_j) \ln(1 - \hat{p}) \\ &= \sum_{j=1}^2 n_j \ln \frac{\hat{p}_j}{\hat{p}} + \sum_{j=1}^2 (N_j - n_j) \ln \frac{1 - \hat{p}_j}{1 - \hat{p}}. \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{X}_2)) \stackrel{D}{\sim} \chi_1^2$. Preznačíme p_1 na p_{11} , $1 - p_1$ na p_{12} , p_2 na p_{21} , $1 - p_2$ na p_{22} . Ekvivalentne preznačíme n_1 na n_{11} , $N_1 - n_1$ na n_{12} , n_2 na n_{21} , $N_2 - n_2$ na n_{22} . Potom $\boldsymbol{\theta} = \mathbf{p} = (p_{11}, p_{12}, p_{21}, p_{22})^T$, $\hat{\boldsymbol{\theta}} = \hat{\mathbf{p}} = (\hat{p}_{11}, \hat{p}_{12}, \hat{p}_{21}, \hat{p}_{22})^T$, kde $\hat{p}_{11} = \frac{n_{11}}{N_1}$, $\hat{p}_{12} = \frac{n_{12}}{N_1}$, $\hat{p}_{21} = \frac{n_{21}}{N_2}$, $\hat{p}_{22} = \frac{n_{22}}{N_2}$ a $\boldsymbol{\theta}_0 = \mathbf{p}_0 = (p_{0,11}, p_{0,12}, p_{0,21}, p_{0,22})^T = (\hat{p}, 1 - \hat{p}, \hat{p}, 1 - \hat{p})^T$, kde $p_{j1} + p_{j2} = 1$, $n_{j1} + n_{j2} = N_j$ a $j = 1, 2$. Potom dostaneme

$$u_{LR} = 2 \sum_{j=1}^2 \sum_{i=1}^2 n_{ji} \ln \frac{\hat{p}_{ji}}{p_{0,ji}} = 2 \sum_{j,i} \text{pozorované}_{ji} \times \ln \frac{\text{pozorované}_{ji}}{\text{očakávané}_{ji}}.$$

Vierohodnostný $100 \times (1 - \alpha)\%$ **empirický DIS** pre $p_1 - p_2$ bude mať tvar

$$CS_{1-\alpha} = \{p_0 : U_{LR} < \chi_1^2(\alpha)\}.$$

Na výpočet tohoto DIS by sme museli reparametrizovať funkciu vierohodnosti na parameter záujmu ($p_1 - p_2$) a rušivý parameter. Alternatívne by bolo možné vypočítať u_{LR} pre rôzne kombinácie p_1 a p_2 (na vhodne zvolených intervaloch) a pre tieto p_j , $j = 1, 2$, vypočítať rozdiely $p_1 - p_2$. Potom $CS_{1-\alpha} = \{p_0 : U_{LR}(p_1 - p_2) < \chi_1^2(\alpha)\}$.

Parametrom záujmu $g(\boldsymbol{\theta}) = \theta$ môže byť namiesto samotných pravdepodobností p_1 a p_2 ich rozdiel $\theta = p_1 - p_2$ (často nazývaný aj rozdiel rizík), relatívne riziko $\theta = p_1/p_2$, pomer šancí $\theta = \frac{p_1/(1-p_1)}{p_2/(1-p_2)}$ alebo logaritmus pomeru šancí $\theta = \ln \frac{p_1/(1-p_1)}{p_2/(1-p_2)}$. Každý parameter záujmu má svoje výhody a nevýhody vo vzťahu k interpretácii alebo štatistickým vlastnostiam. Pri malých rozsahoch výberov je funkcia vierohodnosti **logaritmu pomeru šancí** regulárnejšia než funkcia vierohodnosti ostatných parametrov záujmu, preto vyjadríme funkciu vierohodnosti pre logaritmus pomeru šancí θ s rušivým parametrom $\eta = \ln \frac{p_2}{1-p_2}$. Potom $p_2 = \frac{e^\eta}{1+e^\eta}$ a $p_1 = \frac{e^{\theta+\eta}}{1+e^{\theta+\eta}}$ a funkcia vierohodnosti bude rovná

$$\begin{aligned} L(\boldsymbol{\theta}|\mathbf{x}_1, \mathbf{x}_2) &= \left(\frac{p_1}{1-p_1}\right)^{n_1} (1-p_1)^{N_1} \left(\frac{p_2}{1-p_2}\right)^{n_2} (1-p_2)^{N_2} \\ &= \left(\frac{p_1/(1-p_1)}{p_2/(1-p_2)}\right)^{n_1} \left(\frac{p_2}{1-p_2}\right)^{n_1+n_2} (1-p_1)^{N_1} (1-p_2)^{N_2} \\ &= e^{\theta n_1} e^{\eta(n_1+n_2)} (1+e^{\theta+\eta})^{-N_1} (1+e^\eta)^{-N_2}. \end{aligned}$$

kde $\boldsymbol{\theta} = (\theta, \eta)^T$. Maximálne vierohodný odhad logaritmu pomeru šancí $\hat{\theta} = \ln \frac{n_1/(N_1-n_1)}{n_2/(N_2-n_2)}$. Aby sme dostali profilovú funkciu vierohodnosti pre θ , mohli by sme vypočítať maximálne vierohodný odhad η v každej fixovanej hodnote θ avšak to nie je možné. Preto musíme profilovú funkciu vierohodnosti počítať numericky ako

$$L(\theta|\mathbf{x}_1, \mathbf{x}_2) = \max_{\forall \eta} L(\boldsymbol{\theta}|\mathbf{x}_1, \mathbf{x}_2).$$

Príklad 245 (maximálne vierohodné odhady; nádor prsníka) *Majme početnosti subjektov X_1 , ktoré majú rozšírené metastázy nádoru prsníka, kde $X_1 \sim \text{Bin}(N_1, p_1)$ a početnosti subjektov X_2 , ktoré*

majú lokalizované metastázy nádoru prsníka, kde $X_2 \sim \text{Bin}(N_2, p_2)$; pozri Pawitan (2001). (a) Aplikujte funkciu vierohodnosti $L(\theta | \mathbf{x}_1, \mathbf{x}_2)$, kde $\theta = (\theta, \eta)^T$, logaritmus pomeru šancí $\theta = \ln \frac{p_1/(1-p_1)}{p_2/(1-p_2)}$ a rušivý parameter $\eta = \ln \frac{p_2}{1-p_2}$ na dáta v tabuľke 7.2 a vypočítajte $\hat{\theta}$. (b) Nakreslite funkciu vierohodnosti ako aj profilovú funkciu vierohodnosti a DIS. Zopakujte pre $n_1 = 6$ a $n_2 = 0$. (c) Vypočítajte vierohodnostný 95% DIS pre θ pomocou metodiky 15% cut-off štandardizovanej profilovej funkcie vierohodnosti. DIS dokreslite do jedného obrázka k profilovej funkcii vierohodnosti v jej 15% cut-off.

Tabuľka 7.2: Početnosti subjektov s rozšírenými a lokalizovanými metastázami

metastázy	rozšírené	lokalizované	spolu
áno	5	1	6
nie	10	9	19
spolu	15	10	25

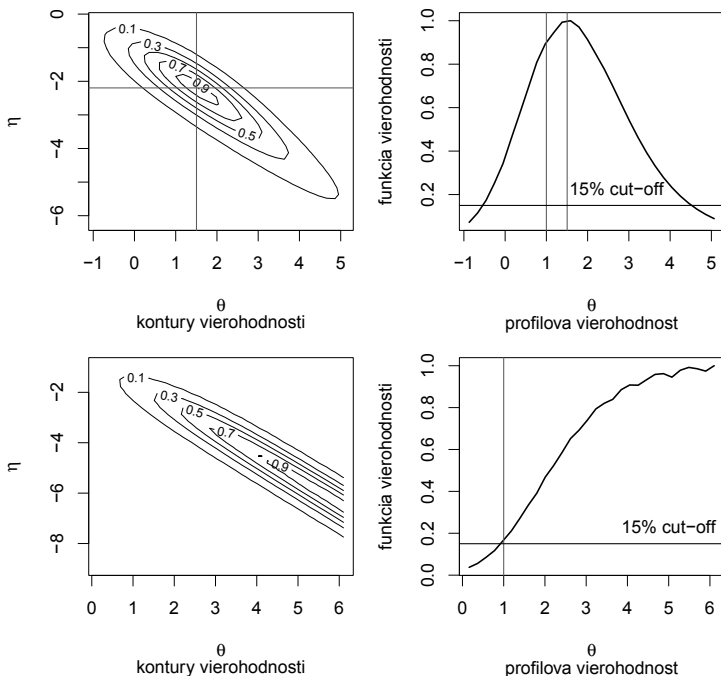
Riešenie (pozri obrázky 7.8)

Keď $n_1 = 5$ a $n_2 = 1$, logaritmus pomeru šancí $\hat{\theta} = \ln \frac{5/10}{1/9} = 1.5$.

Vierohodnostný 95% DIS pre θ je rovný $(-0.544, 4.524)$ a vierohodnostný 95% DIS pre pomer šancí je rovný $(0.580, 92.226)$.

Keď $n_1 = 6$ a $n_2 = 0$, $\theta = \infty$ a vierohodnosť nie je regulárna.

Vierohodnostný 95% JIS pre θ je rovný $(0.921, \infty)$.



Obr. 7.8: Funkcia vierohodnosti a profilová funkcia vierohodnosti binomického rozdelenia pre θ ; $n_1 = 5, n_2 = 1$ (prvý riadok), $n_1 = 6, n_2 = 0$ (druhý riadok)

Príklad 246 (zuby a tepelný šok; pomer šancí) Z 50 zubov vystavených tepelnému šoku sa 21 zlomilo. Z kontrolných 50 zubov sa zlomilo len 11. (a) Znižuje tepelný šok mechanickú odolnosť zubov?

Na testovanie použite test pomerom vierohodnosti. Vypočítajte (b) vierohodnostný 95% empirický DIS pre pomer šancí.


Riešenie (aj v \mathbb{R})

```

1346 n1 <- 21
1347 n2 <- 11
1348 N1 <- 50
1349 N2 <- 50
1350 N <- N1+N2
1351 p1.hat <- n1/N1
1352 p2.hat <- n2/N2
1353 p.hat <- c(p1.hat,1-p1.hat,p2.hat,1-p2.hat)
1354 n <- c(n1,N1-n1,n2,N2-n2)
1355 p.exp <- c((n1+n2)/N,(N1-n1+N2-n2)/N,(n1+n2)/N,(N1-n1+N2-n2)/N)
1356 uLR <- 2*(sum(n*log(p.hat/p.exp))) # 4.653895
1357 1-pchisq(uLR,df=1) # 0.03098316

```

Testovacia štatistika $u_{LR} = 4.654$ a prislúchajúca p-hodnota = 0.031, t.j. $H_0 : p_1 - p_2 = 0$ zamietame na $\alpha = 0.05$. Na výpočet DIS použijeme funkciu vierohodnosti pre logaritmus pomeru šancí (pozri obrázok 7.9) a spätne ho transformujeme na DIS pre pomer šancí. DIS pre logaritmus pomeru šancí je rovný $(d, h) = (0.103, 1.834)$. DIS pre pomer šancí je rovný $(d, h) = (1.107, 6.262)$.



Obr. 7.9: Funkcia vierohodnosti a profilová funkcia vierohodnosti binomického rozdelenia pre logaritmus pomeru šancí zlomenia sa zuba

Príklad 247 (test o pomere šancí) Majme dáta *two-samples-probabilities-sexratio.txt*, premennú počtu starších súrodencov $o.sib.N$ a pohlavie sex . Predpokladáme, že početnosť chlapcov, ak nemá staršieho súrodenu, $X_{m,0} \sim \text{Bin}(N_{m,0}, p_{m,0})$; početnosť chlapcov, ak ho majú, $X_{m,1} \sim \text{Bin}(N_{m,1}, p_{m,1})$; početnosť dievčat, ak nemajú staršieho súrodenu, $X_{f,0} \sim \text{Bin}(N_{f,0}, p_{f,0})$; početnosť dievčat, ak ho majú, $X_{f,1} \sim \text{Bin}(N_{f,1}, p_{f,1})$. (a) Otestujte hypotézu o pomere šancí narodenia chlapca (ak nemá staršieho súrodenu voči situácii, že ho má) na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre tento pomer šancí, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. Použite Waldovu testovaciu štatistiku Z_W pre logaritmus pomeru šancí a jej zodpovedajúci DIS.

Funkcia vierohodnosti **Poissonovho rozdelenia** má nasledovný tvar

$$L(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{x}_2) = e^{-(\lambda_1 + \lambda_2)} \lambda_1^{n_1} \lambda_2^{n_2},$$

kde $\boldsymbol{\theta} = (\lambda_1, \lambda_2)^T$. Zaujíma nás len **relatívne riziko** $\theta = \lambda_2 / \lambda_1$ a nie λ_1 a λ_2 samostatne, pričom λ_1 budeme považovať za rušivý parameter. Model reparametrizujeme z $\boldsymbol{\theta} = (\lambda_1, \lambda_2)^T$ na $\boldsymbol{\theta} = (\theta, \lambda_1)^T$. Potom

$$L(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{x}_2) = e^{-\lambda_1(1+\theta)} \lambda_1^{n_1+n_2} \theta^{n_2},$$

Tabuľka 7.3: Odhad relatívneho rizika úmrtia a 95% IS relatívneho rizika úmrtia celkovo a pre každú vekovú skupinu

kód vekovej skupiny	veková skupina	minulý rok	tento rok	$\hat{\theta}_j$	(d, h) pre 95% DIS
vek 1	< 20	20	35	1.75	(1.024, 3.073)
vek 2	(20, 40)	40	54	1.35	(0.901, 2.039)
vek 3	(40, 50)	75	65	0.87	(0.620, 1.207)
vek 4	≥ 50	10	2	0.20	(0.028, 0.755)

kde $\theta = (\theta, \lambda_1)^T$. Pre každé fixované θ je maximálne vierohodný odhad λ_1 je rovný $\hat{\lambda}_1(\theta) = (n_1 + n_2)/(1 + \theta)$. Potom profilová funkcia vierohodnosti


$$L(\theta|\mathbf{x}_1, \mathbf{x}_2) = e^{-\hat{\lambda}_1(\theta)(1+\theta)} \left(\hat{\lambda}_1(\theta)\right)^{n_1+n_2} \theta^{n_2} = c \left(\frac{1}{1+\theta}\right)^{n_1} \left(1 - \frac{1}{1+\theta}\right)^{n_2},$$

kde maximalizácia $L(\theta|\mathbf{x}_1, \mathbf{x}_2)$ nezávisí na c . Potom $\hat{\theta} = n_2/n_1$.

Príklad 248 (maximálne vierohodné odhady; úmrtia) *Nech početnosti úmrtí na cestách v minulom a tomto roku, ozn. X_1 a X_2 , majú nezávislé Poissonove rozdelenia s parametrami λ_1 a λ_2 , t.j. $X_1 \sim Poiss(\lambda_1)$ a $X_2 \sim Poiss(\lambda_2)$. (a) Aplikujte funkciu vierohodnosti $L(\theta|\mathbf{x}_1, \mathbf{x}_2)$, kde $\theta = (\theta, \lambda_1)^T$, relatívne riziko $\theta = \lambda_2/\lambda_1$ a rušivý parameter λ_1 na dáta v tabuľke 7.3 ($n_1 = 170$ a $n_2 = 190$; pozri Pawitan (2001)) a vypočítajte $\hat{\theta}$. (b) Nakreslite funkciu vierohodnosti ako aj profilové funkcie vierohodnosti pre každú vekovú skupinu. (c) Vypočítajte vierohodnostný 95% DIS pre θ a θ_j pomocou metódy 15% cut-off štandardizovanej funkcie vierohodnosti.*

Riešenie (pozri obrázok 7.10)

Relatívne riziko $\hat{\theta} = 1.12$, $\hat{\theta}_j, j = 1, 2, 3, 4$ pozri v tabuľke. Vierohodnostný 95% DIS pre θ je rovný (0.910, 1.374).



Obr. 7.10: Profilová funkcia vierohodnosti Poissonovho rozdelenia pre θ a $\theta_j, j = 1, 2, 3, 4$

Aproximácia binomického rozdelenia Poissonovým rozdelením. Nech $X_j \sim Bin(N_j, p_j), j = 1, 2$, kde p_j sú veľmi malé čísla a N_j sú veľké čísla. Parametrom záujmu je **relatívne riziko** $\theta = p_1/p_2$. Preto môžeme predpokladať, že $X_1 \sim Poiss(\lambda_1), \lambda_1 = N_1 p_1$ a $X_2 \sim Poiss(\lambda_2), \lambda_2 = N_2 p_2$. Tiež môžeme situáciu zjednodušiť použitím $N_1 \approx N_2$. Potom funkcia vierohodnosti bude mať tvar

$$L(\theta|\mathbf{x}_1, \mathbf{x}_2) = e^{-(N_1 p_1 + N_2 p_2)} (N_1 p_1)^{n_1} (N_2 p_2)^{n_2} = c e^{-p_2(N_1 \theta + N_2)} \theta^{n_1} p_2^{n_1 + n_2}$$

kde $\theta = (\theta, p_2)^T, c = N_1^{n_1} N_2^{n_2}$ (maximalizácia $L(\theta|\mathbf{x}_1, \mathbf{x}_2)$ nezávisí na c) a profilová funkcia vierohodnosti

$$L(\theta|\mathbf{x}_1, \mathbf{x}_2) = \left(\frac{N_1 \theta}{N_1 \theta + N_2}\right)^{n_1} \left(1 - \frac{N_1 \theta}{N_1 \theta + N_2}\right)^{n_2}.$$

Príklad 249 (maximálne vierohodné odhady; nové liek vs. placebo) Predpokladajme, že početnosť subjektov s infarktom myokardu (IM) X_1 v skupine A (nový liek) má binomické rozdelenie s parametrami N_1 a p_1 , t.j. $X_1 \sim \text{Bin}(N_1, p_1)$, a počet subjektov s IM v skupine B (placebo) má tiež binomické rozdelenie s parametrami N_2 a p_2 , t.j. $X_2 \sim \text{Bin}(N_2, p_2)$. Pozorovali sme $n_1 = 139$ z celkového počtu $N_1 = 11037$ subjektov a $n_2 = 239$ z celkového počtu $N_2 = 11034$ subjektov. Keďže N_1 a N_2 sú vysoké čísla a pravdepodobnosti IM malé čísla, môžeme predpokladať, že $X_1 \sim \text{Poiss}(\lambda_1)$, $\lambda_1 = N_1 p_1$ a $X_2 \sim \text{Poiss}(\lambda_2)$, $\lambda_2 = N_2 p_2$. Zjednodušíme situáciu použitím $N_1 \approx N_2$. (a) Aplikujte funkciu vierohodnosti $L(\theta | \mathbf{x}_1, \mathbf{x}_2)$, kde $\theta = (\theta, p_2)^T$ a relatívne riziko $\theta = p_1/p_2$ na dáta v tabuľke 7.4 (pozri Pawitan (2001)) – pre (1) IM ako aj (2) pre mozgovú mŕtvicu (MM). (b) Nakreslite profilové funkcie vierohodnosti pre každú skupinu. (c) Vypočítajte vierohodnostný 95% DIS pre (1) θ_{IM} a (2) θ_{MM} pomocou metodiky 15% cut-off štandardizovanej funkcie vierohodnosti.


Tabuľka 7.4: Početnosti subjektov s infarktom myokardu a mozgovou mŕtvicou v skupine A a B

skupina	IM	MM	spolu
skupina A	139	119	11037
skupina B	239	98	11034

Riešenie (pozri tabuľku 7.4 a obrázok 7.11)

Relatívne riziko $\hat{\theta}_{IM} = \frac{139/11037}{239/11034} \doteq 0.581$. Vierohodnostný 95% DIS pre θ_{IM} je rovný (0.471, 0.715).

Relatívne riziko $\hat{\theta}_{MM} = \frac{119/11037}{98/11034} \doteq 1.214$. Vierohodnostný 95% DIS pre θ_{MM} je rovný (0.931, 1.586).



Obr. 7.11: Profilová funkcia vierohodnosti pre θ

8 Testovanie hypotéz o viacerých parametroch

Aj keď nám v praxi v mnohých situáciách stačí testovanie hypotéz o jednom parametri alebo dvoch parametroch (čo je náplňou predchádzajúcich dvoch kapitol), bežne sa v antropológii stretávame aj s požiadavkou otestovať rozdiely J parametrov súčasne (kde $J > 2$). Tieto parametre charakterizujú rozdelenie nejakej premennej v J populáciách, ktoré sú identifikovateľné pomocou nejakej ordinálnej alebo nominálnej premennej, ktorú v tomto prípade nazývame **faktor**. **Kategórie (úrovne)** daného faktora

- existujú buď prirodzene – napr. faktor pohlavie, mesto, štát, archeologická kultúra (lokalita), zamestnanie, faktor počet predchádzajúcich detí biologickej matky hodnoteného jedinca, faktor populácia odrážajúca podtypy jednej choroby odlišnej etiológie, faktor poradie narodenia (prvorodený, druhorodený, narodený vo vyššom poradí), faktor počet narodených detí (*nullipara*, *primipara*, *secundipara* atď.), vekové intervaly, faktor vzdelanie alebo
- sú dané metodicky na základe použitej štandardnej kategorizačnej metódy – napr. faktor sexuálna orientácia (sedembodová Likertova škála, Kinseyho škála – od sexuálnej orientácie výlučne na opačné pohlavie (0) až po sexuálnu orientáciu výlučne na rovnaké pohlavie (6)), faktor zdravotný stav novorodenca (kategórie orientačného hodnotenia zdravotného stavu novorodencov na základe Apgar skóre).

V takýchto situáciách máme dve hlavné úlohy

1. zistiť, či vôbec existuje nejaký rozdiel aspoň medzi dvoma populáciami, t.j. či sa stredné hodnoty aspoň dvoch populácií líšia (ide o **viacvýberový test rovnosti stredných hodnôt**) a
2. zistiť, medzi ktorými populáciami existuje štatisticky významný rozdiel a ktoré sa navzájom nelíšia (ide o tzv. **mnohonásobné porovnávanie** alebo **post-hoc testy**).

Ako zdanlivo správna alternatíva k testovaniu viacerých parametrov súčasne (viac kategórií, viac populácií, viac premenných a pod.) sa ponúka viacnásobné použitie príslušného počtu testov dvoch parametrov (napr. tri dvojvýberové Studentove t -testy v prípade troch úrovní faktora a testovania rozdielov stredných hodnôt). Pri viacnásobnom porovnávaní dvoch parametrov je však pravdepodobnosť vzniku chyby prvého druhu vyššia (často výrazne vyššia v závislosti od počtu testovaných nulových hypotéz) a sila testu nižšia ako pri porovnávaní dvoch parametrov (pozri kapitolu 4 Testovanie hypotéz). V prípade viacerých výberov alebo viacerých premenných by sme preto mali vždy použiť test pre viac parametrov s nadväzujúcimi post-hoc testami a nie sekvenciu dvojvýberových testov.

Pri testovaní hypotéz o viacerých parametroch však treba pamätať na splnenie predpokladov, pri ktorých možno tieto testy použiť. Vo všeobecnosti jednotlivé náhodné výbery nemusia mať rovnaké rozvahy a môžu sa líšiť ich rozptyly alebo ich rozdelenie (tieto podmienky však možno ošetriť pri plánovaní štúdie/experimentu). Jednotlivé úrovne môžu a nemusia tvoriť stupne v rámci nejakého gradientu. Okrem toho môžu byť rozdiely medzi niektorými úrovňami (populáciami) výrazne väčšie než medzi inými. K riešeniu musíme pristupovať rôznym spôsobom, na základe toho, čo o vzorkách a populáciách, z ktorých vzorky pochádzajú, vopred vieme. Napr. pri porovnaní šiestich miest, z ktorých tri sú z jedného a tri z druhého kraja, môžeme vopred predpokladať existenciu nejakých skupín, v ktorých si môžu byť výbery bližšie, zatiaľ čo pri iných porovnávaní to vopred predpokladať nie je možné a skupiny sa objavujú až ako výsledok štatistickej analýzy. Rozdiely takýchto skupín možno testovať použitím vhodne zvolených **kontrastov** pred analýzou ale i v priebehu analýzy.

V antropológii a biomedicínsky zameraných disciplínach sa analýza rozptylu (ANOVA) bežne používa pri testovaní rozdielov stredných hodnôt u viacerých výberov alebo pri testovaní vplyvu iných faktorov na tieto rozdiely. Menej používané však už sú viacvýberové testy rozdielov v rozptyloch, korelačných koeficientoch a pravdepodobnostiach, hoci sú rovnako potrebné a užitočné. Dôvodom môže byť snád aj to, že väčšinou nie sú implementované v najčastejšie používaných „klikacích“ štatistických balíkoch. Aj z tohto dôvodu sa domnievame, že ich zaradenie do tejto kapitoly spolu s riešeniami a neriešenými príkladmi môže prispieť k ich väčšiemu rozšíreniu v relevantných oblastiach. Nejde pritom len o ich

prínos pri plánovaní štúdií a experimentov, ale aj o prínos pri štatistických analýzach samotných, kedy znalosť týchto testov môže pomôcť bližšie pochopiť komplexné vzťahy v analyzovaných dátach a tým zjednodušiť interpretáciu štatistických výsledkov.

Z praktických dôvodov (použitie testov založených na predpokladoch zhody v rozptyloch) nás najčastejšie zaujíma zhoda rozptylov nejakej premennej v dvoch populáciách. Ako už bolo uvedené v predchádzajúcich kapitolách (kapitola 6 a 7), štúdium rozdielov v rozptyloch medzi porovnávanými populáciami môže byť podstatné i meritórne z hľadiska štúdia *evolučných procesov* (stabilizujúca selekcia) alebo *ontogenetických procesov* (vplyv modifikujúcich faktorov prostredia). Predstavuje preto dôležitý krok na ceste k rozlíšeniu rozdielov medzi porovnávanými populáciami. Variabilita v dátach predstavuje súhrn *variability pôvodnej* (napr. biologickej povahy), vznikajúcej v dôsledku procesov, ktoré nás zaujímajú, a *variability vnesenej druhotne*, t.j. buď prirodzenou selekciou časti populácie, z ktorej vzorku vyberáme (napr. časť pohrebiska), náhodou (šum, nepresnosť merania) alebo úplne umelo metódou vzorkovania či technikou merania (napr. rozdiely v meradlách). Pokiaľ sa vzorky v rozptyloch nelíšia, neznamená to, že ide o identické výsledky spolupôsobenia rovnakých zdrojov variability pôvodných a druhotných. Pokiaľ sa ale vzorky v rozptyloch významne líšia, je potrebné hľadať príčinu tejto odlišnosti. Na rozdiel od porovnania rozptylov dvoch populácií môže byť našou úlohou pri porovnávaní viacerých populácií (podobne ako pri porovnávaní viacerých stredných hodnôt) 1. zistiť, či sa aspoň jedna z nich líši v rozptyle od ostatných a 2. testovať, medzi ktorými populáciami existujú štatisticky významné rozdiely v rozptyle.

Použitie viacvýberového testu zhody korelačných koeficientov je obdobou hodnotenia zhody viacerých stredných hodnôt alebo rozptylov pomocou viacvýberových testov. K dispozícii máme dáta z niekoľkých populácií popisujúce vzťah dvoch spojitých premenných a pýtame sa, či 1. je súvislosť (asociácia) oboch premenných v sledovaných populáciách rovnaká alebo nie. Pokiaľ sa aspoň jedna populácia v tejto asociácii líši, zaujíma nás 2., ktorá to je, resp. ktoré populácie sa od seba navzájom líšia. Typickým príkladom môžu byť medzipopulačné rozdiely vo vzťahu medzi šírkou a výškou nosa. V porovniach nosa existujú rozdiely medzi veľkými, geograficky vymedzenými populačnými skupinami (tradične a nesprávne hľadané rozdiely medzi „rasami“), ktoré však vychádzajú najmä z prílišného zjednodušenia situácie, sprevádzaného zanedbávaním funkčných adaptácií ako zdroja variability vo veľkosti a proporciách ľudského tela. Charakter nosa je v skutočnosti výsledkom evolučných adaptácií na teplotu a vlhkosť klímy – dlhé a relatívne úzke nosy sú výhodnejšie v aridných (suchých) a chladných podmienkach kvôli lepšiemu zvlhčeniu a ohriatiu vdychovaného vzduchu (tzv. Thomsonovo biogeografické pravidlo). Táto adaptácia pritom môže zanechať určitý obraz aj na tvare podkladových lebečných štruktúr nosa. V rôznych ľudských populáciách tak spolu môže šírka a výška nosa súvisieť rôzne. Prítom si treba uvedomiť, že našou úlohou *nie je* zistenie rozdielu medzi populáciami v strednej hodnote pomeru šírky a výšky nosa (t.j. či sa populácie líšia alebo nelíšia v pomere oboch rozmerov, alebo či rozdiely medzi populáciami v tomto pomere závisia na rozdieloch v stredných hodnotách niektorého z oboch rozmerov), *ale zistenie rozdielu v asociácii* jedného a druhého rozmeru v sledovaných populáciách. Na pamäti treba mať, že nejde o zisťovanie rozdielov v miere veľkosti izometrie/alometrie tvaru nosa, t.j. či sa oba korelované rozmery zväčšujú proporčne rovnako (izometria) alebo jeden z nich napr. v polovičnej či dvojnásobnej miere. Test zhody viacerých korelačných koeficientov zisťuje, či je v nulovej hypotéze vo všetkých populáciách súvislosť oboch rozmerov rovnaká. Nulovú hypotézu zamietame, ak existuje aspoň jedna dvojica populácií, kde je rozdiel korelačných koeficientov nennulový. Zamietnutie nulovej hypotézy nezávisí od tesnosti vzťahu dvoch veličín v dvoch populáciách, ale od samotného rozdielu korelačných koeficientov. V kombinácii s testem stredných hodnôt týchto rozmerov a ich rozptylov to dovoľuje uvažovať o funkčnom význame morfológie nosa (veľkosť, tvar, variabilita a vzájomný vzťah rozmerov) v širšom kontexte.

Napriek tomu, že na celý rad riešených úloh biologickej antropológie stačí jednovýberové alebo dvojevýberové porovnanie pravdepodobností, mnohokrát nie je možné situáciu takto zjednodušiť bez straty podstatných informácií. V takom prípade je potrebné testovať rozdiely medzi populáciami pomocou testov porovnávajúcich viac než dve pravdepodobnosti. V antropológii môže byť typickým prípadom porovnanie frekvencií mužov a žien, klasifikovaných v rámci nejakého faktoru s tromi alebo viacerými úrovňami, napr. päť vekových intervalov, štyri stupne vzdelania, osem krajských miest, rôzne druhy zamestnania, ap. Pri testovaní nulových hypotéz s viacerými pravdepodobnosťami je nevyhnutné presne špecifikovať, aké prípadné rozdiely nás konkrétne zaujímajú, napr. sú podstatné rozdiely medzi pohlaviami v každom krajskom meste alebo rozdiely medzi rôznymi krajskými mestami v rámci každého pohlavia? Testovanie všetkých možných rozdielov totiž zvyšuje počet stupňov voľnosti a znižuje schopnosť testu zamietnuť nulovú hypotézu pri rovnakých frekvenciách. V prípade kostrových nálezov je typickou úlohou porovnanie frekvencií viacúrovňového epigenetického znaku me-

dzi dvoma alebo viacerými populáciami s cieľom štúdia ich genetickej príbuznosti. Môže sa však stať, že aj v relatívne veľkých kostrových súboroch (čo už samo osebe nie je úplne bežné) budú frekvencie v jednotlivých úrovniach (kategóriách) daného znaku veľmi malé, t.j. rádovo v jednotkách prípadov (napr. Kaur a kol., 2012). V malých kostrových súboroch či v populáciách s extrémne nízkym podielom daného epigenetického znaku sa dokonca znak nemusí v niektorej z jeho úrovní vyskytovať vôbec. V prípade neprítomnosti niektorej úrovne znaku, t.j. nulovej frekvencie, je potom vhodné a niekedy dokonca nevyhnutné použitie špeciálne navrhnutých testov, ktorých problematika však už presahuje rámec tejto knihy (bližšie Rücker a kol., 2009).

Príkladom viacvýberového testu zhody stredných hodnôt môže byť test rozdielov stredných hodnôt výšky hornej časti tváre v piatich rôznych populáciách (dáta: `anova-means-skull.txt`). Príkladom viacvýberového testu rozptylov môže byť test rozdielov v rozptyloch dĺžky kľúčnej kosti v štyroch populáciách kľúčnych kostí (dáta: `more-samplex-variances-clavicle.txt`). Testom zhody viacerých korelačných koeficientov môžeme napr. zistiť, či sa päť populácií líši v asociácii výšky a šírky nosa (dáta: `more-samples-correlations-skull.txt`). Zhoda viacerých pravdepodobností nás môže zaujímať napr. pri testovaní rozdielov vo výskyte troch stupňov útvarov negatívneho reliéfu na vnútornej strane lonovej spony u žien z troch populácií (dáta: `more-samples-probabilities-pubis.txt`).

V tejto kapitole sa teda budeme venovať testovaniu hypotéz o stredných hodnách $\mu_1, \mu_2, \dots, \mu_J$, za predpokladov normality, t.j. $X_{ji} \sim N(\mu_j, \sigma_j^2)$, kde $j = 1, 2, \dots, J$ a $i = 1, 2, \dots, n_j$, o rozptyloch $\sigma_1^2, \sigma_2^2, \dots, \sigma_J^2$, za predpokladov normality, t.j. $X_{ji} \sim N(\mu_j, \sigma_j^2)$, o korelačných koeficientoch $\rho_1, \rho_2, \dots, \rho_J$, za predpokladov normality, t.j. $(X_{ji}, Y_{ji})^T \sim N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, a o pravdepodobnostiach p_1, p_2, \dots, p_J , za predpokladov $X \sim Mult_J(N, \mathbf{p})$, kde $\mathbf{p} = (p_1, p_2, \dots, p_J)^T$. Keďže X_{ji} v tomto prípade zapisujeme do štatistického modelu, kde sa na jeho ľavej strane nachádzajú závislé premenné (ozn. Y), preznačíme ich na Y_{ji} . Ozn. X_{ij} rezervujeme pre nezávislé premenné, napr. fixné efekty (zaradenie do skupín a pod.).

8.1 Asymptotické testy o stredných hodnotách

Nech $Y_{ji} \sim N(\mu_j, \sigma_j^2)$, kde $j = 1, 2, \dots, J$ a $i = 1, 2, \dots, n_j$, sú nezávislé náhodné premenné. Budeme rozlišovať dve situácie

1. $Y_{ji} \sim N(\mu_j, \sigma_j^2)$, kde $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma_e^2$ (**homogenita rozptylov**), σ_j^2 sú neznáme a
2. $Y_{ji} \sim N(\mu_j, \sigma_j^2)$, kde existuje aspoň jedna dvojica $i \neq j$ taká, že $\sigma_i^2 \neq \sigma_j^2$ (**nehomogenita rozptylov**), σ_j^2 sú neznáme.

8.1.1 Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

Nech $Y_{ji} \sim N(\mu_j, \sigma_j^2)$, kde $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma_e^2$ a zároveň σ_j^2 sú neznáme. Majme **jednofaktorový model analýzy rozptylu (ANOVA) s fixnými (pevnými) efektami**, ozn. \mathcal{F}_{H_1} , definovaný ako

$$Y_{ji} = \mu_j + \varepsilon_{ji} = \mu + \alpha_j + \varepsilon_{ji},$$

kde $\mu = \sum_{j=1}^J \mu_j / J$, $\mu_j = \mu + \alpha_j$, $\sum_{j=1}^J \alpha_j = 0$, μ je celková (spoločná) úroveň spoločná všetkým populáciám (alebo celková stredná hodnota), α_j je j -ta úroveň faktora A (j -ty efekt faktora A) a znamená odchýlku strednej hodnoty j -tej populácie od μ . Pre chyby ε_{ji} platí $\varepsilon_{ji} \sim N(0, \sigma_e^2)$. Model $Y_{ji} \sim N(\mu + \alpha_j, \sigma_e^2)$ sa nazýva aj **model podmieneného normálneho rozdelenia**.

Majme dvojicu hypotéz $H_0: \mu_1 = \mu_2 = \dots = \mu_J = \mu$ oproti H_1 : existuje aspoň jedno $i < j$ také, že $\mu_i \neq \mu_j$. Ak H_0 platí, potom $\alpha_1 = \alpha_2 = \dots = \alpha_J = 0$, dostaneme submodel, ozn. \mathcal{F}_{H_0} , definovaný ako

$$Y_{ji} = \mu + \varepsilon_{ji}.$$

Ak H_0 platí, potom

$$F_W = \frac{\frac{SS_A}{J-1}}{\frac{SS_e}{n-J}} \stackrel{\mathcal{D}}{\sim} F_{J-1, n-J},$$

kde $df_A = J - 1$, $df_e = (n - 1) - (J - 1) = n - J$ sú stupne voľnosti, $n = \sum_{j=1}^J n_j$ je celkový rozsah, n_j sú rozsahy jednotlivých výberov, SS_A je **výberový súčet štvorcov rozdielov medzi súbormi** a je definovaný ako

$$SS_A = \sum_{j=1}^J n_j (\bar{Y}_{j\cdot} - \bar{Y}_{\cdot\cdot})^2 = \sum_{j=1}^J \frac{Y_{j\cdot}^2}{n_j} - \frac{1}{n} Y_{\cdot\cdot}^2,$$

$\hat{\mu} = \bar{Y}_{\cdot\cdot} = Y_{\cdot\cdot}/n$ je maximálne virohodný odhad μ , $Y_{\cdot\cdot} = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}$, $\hat{\mu}_j = \bar{Y}_{j\cdot} = Y_{j\cdot}/n_j$ je maximálne virohodný odhad μ_j , $Y_{j\cdot} = \sum_{i=1}^{n_j} Y_{ji}$, SS_e je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

$$SS_e = \sum_{j=1}^J \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_{j\cdot})^2 = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}^2 - \sum_{j=1}^J \frac{Y_{j\cdot}^2}{n_j}.$$

Súčet SS_A a SS_e sa rovná SS_T , čo je **celkový výberový súčet štvorcov rozdielov** a je definovaný ako

$$SS_T = \sum_{j=1}^J \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_{\cdot\cdot})^2 = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}^2 - \frac{1}{n} Y_{\cdot\cdot}^2,$$

Rovnosti $SS_T = SS_A + SS_e$ hovoríme aj *rozklad celkovej sumy štvorcov*. Pre stupne voľnosti potom platí $df_T = df_A + df_e$, kde $df_T = n - 1$. Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi	$SS_{A,obs}$	$J - 1$	$MS_{A,obs} = SS_{A,obs}/(J - 1)$
vnútri súborov	$SS_{e,obs}$	$n - J$	$MS_{e,obs} = SS_{e,obs}/(n - J) = \hat{\sigma}_e^2 = s^2$
celkovo	$SS_{T,obs}$	$n - 1$	

F_W sa nazýva **Fisherova testovacia štatistika** (alebo **ANOVA F -štatistika**) a test **viacvýberový F -test o rovnosti stredných hodnôt** $\mu_1, \mu_2, \dots, \mu_J$ (alebo **ANOVA F -test**). Realizáciou F_W je F_{obs} a p-hodnota = $\Pr(F_W \geq F_{obs} | H_0)$.

Úlohu môžeme interpretovať tak, že stredná hodnota μ_j náhodnej veličiny Y_{ji} závisí na **faktore** A , čo je premenná v nominálnej škále. Jednotlivým **úrovniam** (hladinám) tejto premennej zodpovedajú **fixné efekty** $\alpha_j = \mu_j - \mu$. Úrovně premennej volí experimentátor, sú teda nenáhodné, dopredu dané (fixné). Potom chápeme α_j ako neznáme parametre, ktorých maximálne virohodné odhady definujeme ako $\hat{\alpha}_j = \bar{y}_{j\cdot} - \bar{y}_{\cdot\cdot}$. Samotné rozhodovanie o H_0 bude založené na porovnaní priemerných súm štvorcov $SS_{A,obs}/df_A$ a $SS_{e,obs}/df_e$. Väčšie rozdiely $\bar{y}_{j\cdot}$ a $\bar{y}_{\cdot\cdot}$ (v absolútnej hodnote) sa prejavujú vo väčšej hodnote štatistiky $SS_{A,obs}$. Štatistika $SS_{e,obs}$ zasa umožňuje odhadnúť rozptyl σ_e^2 a súčasne dáva mieru pre hodnotenie veľkosti variability medzi súbormi.

Rozdelenia používané v ANOVA modeli môžeme zhrnúť do nasledovných bodov:

1. Nech $Z_{ji} \sim N(0, 1)$, kde $j = 1, 2, \dots, J$; $i = 1, 2, \dots, n_j$, potom $\sum_{j=1}^J \sum_{i=1}^{n_j} Z_{ji}^2 \sim \chi_{df}^2$, kde $df = n = \sum_{j=1}^J n_j$;
2. Nech $Z_{ji} \sim N(0, \sigma_e^2)$, potom $\sum_{j=1}^J \sum_{i=1}^{n_j} Z_{ji}^2 \sim \sigma_e^2 \chi_n^2$ a $\sum_{j=1}^J \sum_{i=1}^{n_j} (Z_{ji} - \bar{Z}_{j\cdot})^2 \sim \sigma_e^2 \chi_{n-1}^2$;
3. Nech $Z_{ji} \sim N(\alpha_j, \sigma_e^2)$, potom $\sum_{j=1}^J \sum_{i=1}^{n_j} Z_{ji}^2 \sim \sigma_e^2 \chi_{df, \lambda^2}^2$, $\sum_{j=1}^J \sum_{i=1}^{n_j} (Z_{ji} - \bar{Z}_{j\cdot})^2 \sim \sigma_e^2 \chi_{df-1, \lambda^2}^2$, kde $\lambda^2 = \sum_{j=1}^J \alpha_j^2 / \sigma_e^2$ a zároveň $\frac{SS_T}{n-1} \sim \frac{\sigma_e^2}{n-1} \chi_{n-1}^2$, $SS_e \sim \sigma_e^2 \chi_{df_e}^2$;
4. Nech $\bar{Z}_{j\cdot} \sim N(\alpha_j, \sigma_e^2/n_j)$, potom $\frac{SS_A}{J-1} \sim \frac{\sigma_e^2}{J-1} \chi_{J-1, \lambda^2}^2$, kde $\lambda^2 = \sum_{j=1}^J \frac{\alpha_j^2}{\sigma_e^2/n_j}$.

Majme **vyvážený model** (vyvážené triedenie), t.j. nech $n_1 = n_2 = \dots = n_J = K$, kde K je počet opakovaní v podtriede. Ak v jednofaktorovom ANOVA modeli platí nulová hypotéza H_0 , potom má testovacia štatistika F_W centrálnu F rozdelenie so stupňami voľnosti $df_A = J - 1$ a $df_e = n - J = KJ - J = J(K - 1)$. Teda

$$F_W = \frac{MS_A}{MS_e} = \frac{SS_A/df_A}{SS_e/df_e} \approx \frac{\chi_{df_A}^2/df_A}{\chi_{df_e}^2/df_e} \stackrel{\mathcal{D}}{\sim} F_{df_A, df_e}$$

a ide o podiel dvoch centrovanych χ^2 (čítame „chí-kvadrátov“) podelených príslušnými stupňami voľnosti. Nech $Z_{ji} = Y_{ji} - \mu$. Potom $Z_{ji} \sim N(0, \sigma_e^2)$, $\bar{Z}_j \sim N(0, \sigma_e^2/K)$ a $SS_A \sim \sigma_e^2 \chi_{df_A}^2$.

Ale ak H_0 neplatí, potom $Z_{ji} \sim N(\alpha_j, \sigma_e^2)$ a $\bar{Z}_j \sim N(\alpha_j, \sigma_e^2/K)$, kde aspoň jedno $\alpha_j \neq 0$ a testovacia štatistika má necentrálne F rozdelenie

$$F_{W,\lambda} \approx \frac{\chi_{df_A, \lambda^2}^2 / df_A}{\chi_{df_e}^2 / df_e} \stackrel{\mathcal{D}}{\sim} F_{df_A, df_e, \lambda^2},$$

kde χ_{df_A, λ^2}^2 je necentrálne chi-kvadrát rozdelenie s parametrom necentrality

$$\lambda^2 = \frac{\sum_{j=1}^J \alpha_j^2}{\sigma_e^2 / K} = \frac{\sum_{j=1}^J (\mu_j - \mu)^2}{\sigma_e^2 / K} = K(J-1) \frac{\sigma_A^2}{\sigma_e^2},$$

kde $\sigma_A^2 = \frac{1}{J-1} \sum_{j=1}^J (\mu_j - \mu)^2$.

Sila testu. Sila ANOVA F -testu $1 - \beta$ je definovaná ako


$$1 - \beta = \Pr(F_{df_A, df_e, \lambda^2} \geq F_{df_A, df_e}(\alpha)),$$

kde $F_{df_A, df_e}(\alpha)$ je kritická hodnota centrálného F -rozdelenia a $F_{df_A, df_e, \lambda^2}$ je náhodná premenná z necentrálneho F -rozdelenia (pozri obrázok 8.1). Potom **minimálny rozsah** K bude iteračným riešením rovnice

$$1 - \beta = \Pr(F_{J-1, J(K-1), \lambda^2} \geq F_{J-1, J(K-1)}(\alpha)),$$

ktorú môžeme napísať aj nasledovne (Rasch a kol., 2011)

$$F_{J-1, J(K-1), \lambda^2}(1 - \beta) = F_{J-1, J(K-1)}(\alpha).$$



Obr. 8.1: Silofunkcie ANOVA F -testu pri rôznych J a K – vľavo $J = 3$, uprostred $JK = 12$ a vpravo $JK = 100$

Príklad 250 (sila ANOVA F -testu a minimálny rozsah) Majme štyri populácie, ktorých stredné hodnoty sú $\mu_1 = 390$, $\mu_2 = 405$, $\mu_3 = 415$ a $\mu_4 = 410$. Predpokladajme, že $Y_{ji} \sim N(\mu_j, \sigma_e^2)$.

(a) Vypočítajte silu $1 - \beta$ ANOVA F -testu rovnosti stredných hodnôt za predpokladu, že $K = 6$, $\sigma_e^2 = 20^2$ a $\alpha = 0.05$.

(b) Vypočítajte silu $1 - \beta$ ANOVA F -testu rovnosti stredných hodnôt za predpokladu, že $K = 6$, $\sigma_e^2 = 10^2$ a $\alpha = 0.05$.

(c) Použite \mathbb{R} na simuláciu hustoty necentrálneho $F_{df_A, df_e, \lambda^2}$ testovacích štatistík $F_{W,\lambda}^{(m)}$ (necentrálne F rozdelenie s df_A a df_e stupňami voľnosti a parametrom necentrality λ^2), kde $\alpha = 0.05$, $K = 6$, $\sigma_e^2 = 20^2$, $\lambda^2 = \sum_{j=1}^J (\mu_j - \hat{\mu})^2 / (\sigma_e^2 / K)$, $m = 1, 2, \dots, M$, pri $M = 1000$ opakovaníach.

(d) Vypočítajte minimálny rozsah K , ak $\sigma_e^2 = 20^2$ a $\alpha = 0.05$. K bude iteračným riešením rovnice $F_{J-1, J(K-1), \lambda^2}(\beta) = F_{J-1, J(K-1)}(1 - \alpha)$.

Riešenie


$$(a) \lambda^2 = \frac{6(390-405)^2 + 6(405-405)^2 + 6(415-405)^2 + 6(410-405)^2}{20^2} = 5.25,$$

$$1 - \beta(\lambda^2) = \Pr(F_{df_A, df_e, \lambda^2} \geq F_{df_A, df_e}(\alpha)) = \Pr(F_{3, 20, 5.25} \geq F_{3, 20}(0.05)) = 0.386.$$

$$(b) \lambda^2 = \frac{6(405-405)^2 + 6(405-405)^2 + 6(415-405)^2 + 6(410-405)^2}{10^2} = 21,$$

$$1 - \beta(\lambda^2) = \Pr(F_{df_A, df_e, \lambda^2} \geq F_{df_A, df_e}(\alpha)) = \Pr(F_{3, 20, 21} \geq F_{3, 20}(0.05)) = 0.95.$$

(c) simulácia silofunkcie (pozri obrázok 8.2)



Obr. 8.2: Hustota centrálneho a necentrálneho F -rozdelenia superponovaná histogramom simulácií pre $Y_j \sim N(\mu_j, \sigma_e^2)$

(d) minimálny rozsah $K = 14$ a $n = KJ = 56$.

Alternatívnym prístupom je zistenie sily špecifikáciou **najmenšieho detegovateľného rozdielu**, ktorý chceme mať medzi dvoma najvzdialenejšími strednými hodnotami. Môžeme písať, že najmenšia vzdialenosť medzi najvzdialenejšími strednými hodnotami bude $\delta = c\sigma$, kde $c > 0$. Dá sa ukázať, že $\sum_{j=1}^J \alpha_j^2$ je minimálna, ak budú ľubovoľné dva efekty $\alpha_i = -c\sigma/2$ a $\alpha_j = c\sigma/2$ a ostatných $J - 2$ efektov bude rovných nule. Preto

$$\sum_{j=1}^J \alpha_j^2 = \left(-\frac{c\sigma}{2}\right)^2 + \left(\frac{c\sigma}{2}\right)^2 + \underbrace{0 + \dots + 0}_{J-2} = 2\frac{c^2\sigma^2}{4}.$$

Potom

$$\lambda^2 = \frac{\sum_{j=1}^J \alpha_j^2}{\sigma_e^2/K} = \frac{\delta^2}{2\sigma_e^2/K}.$$

Maticový zápis modelu \mathcal{F}_{H_1} a \mathcal{F}_{H_0} .

Modely \mathcal{F}_{H_1} a \mathcal{F}_{H_0} sú lineárnymi regresnými modelmi a môžeme ich všeobecne zapísať v tvare $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, kde \mathbf{Y} je n -rozmerný náhodný vektor, \mathbf{X} je **matica plánu** s rozmermi $n \times (J + 1)$ a $\boldsymbol{\varepsilon}$ je n -rozmerný **vektor chýb**. Potom model \mathcal{F}_{H_1} bude mať tvar

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_J \end{pmatrix} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \begin{pmatrix} \mathbf{1}_1 & \mathbf{1}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{1}_2 & \mathbf{0} & \mathbf{1}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \mathbf{1}_J & \mathbf{0} & \mathbf{0} & \dots & \mathbf{1}_J \end{pmatrix} \begin{pmatrix} \mu \\ \alpha_1 \\ \vdots \\ \alpha_J \end{pmatrix} + \begin{pmatrix} \boldsymbol{\varepsilon}_1 \\ \boldsymbol{\varepsilon}_2 \\ \vdots \\ \boldsymbol{\varepsilon}_J \end{pmatrix},$$

kde $\mathbf{Y}_j = (Y_{j1}, Y_{j2}, \dots, Y_{jn_j})^T$ je n_j -rozmerný vektor, $\mathbf{1}_j$ je n_j -rozmerný vektor jednotiek a $\boldsymbol{\varepsilon}_j$ je n_j -rozmerný vektor chýb. Potom $\mathbf{Y}_j \sim N_{n_j}(\mathbf{X}_j\boldsymbol{\beta}, \sigma_e^2\mathbf{I}_{n_j \times n_j})$, vektor chýb $\boldsymbol{\varepsilon}_j \sim N_{n_j}(\mathbf{0}, \sigma_e^2\mathbf{I}_{n_j \times n_j})$, vektor

parametrov $\widehat{\beta} \sim N_{J+1}(\beta, \sigma_c^2(\mathbf{X}^T \mathbf{X})^{-1})$, kde maximálne vierohodný odhad $\widehat{\beta}$ vypočítame pomocou metódy najmenších štvorcov, t.j. $\widehat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$.

Model \mathcal{F}_{H_0} bude mať tvar

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_J \end{pmatrix} = \mathbf{X}\beta + \varepsilon = \begin{pmatrix} \mathbf{1}_1 \\ \mathbf{1}_2 \\ \vdots \\ \mathbf{1}_J \end{pmatrix} \mu + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_J \end{pmatrix}.$$

Test pomerom vierohodnosti o rovnosti stredných hodnôt.

Nech $Y_j \sim N(\mu_j, \sigma^2)$, kde $j = 1, 2, \dots, J$ a σ^2 je neznáma. Logaritmus funkcie vierohodnosti má tvar

$$l(\boldsymbol{\theta} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2,$$

kde $n = \sum_{j=1}^J n_j$. MLE $\boldsymbol{\theta}$ je rovný $\widehat{\boldsymbol{\theta}} = (\widehat{\mu}_1, \widehat{\mu}_2, \dots, \widehat{\mu}_J, \widehat{\sigma}^2)^T$, kde

$$\widehat{\mu}_j = \bar{y}_j, \widehat{\sigma}^2 = \frac{1}{n} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2,$$

t.j. $\Theta_1 = \{\boldsymbol{\theta} : \mu_i \neq \mu_j; i < j, i = 1, 2, \dots, J-1; j = 2, 3, \dots, J\}$ pre aspoň jedno i a j . Za platnosti H_0 je $\widehat{\boldsymbol{\theta}}_0 = (\widehat{\mu}, \widehat{\mu}, \dots, \widehat{\mu}, \widehat{\sigma}_0^2)^T$ platí

$$\bar{x} = \widehat{\mu} = \frac{1}{n} \sum_{j=1}^J \sum_{i=1}^{n_j} y_{ji}, \widehat{\sigma}_0^2 = \frac{1}{n} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \widehat{\mu})^2,$$

Tiež platí $\Theta_0 = \{\boldsymbol{\theta} : \mu_1 = \mu_2 = \dots = \mu_J = \mu\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$-\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J)) = \frac{n}{2} \ln \left(\frac{\widehat{\sigma}_0^2}{\widehat{\sigma}^2} \right)$$

Vieme, že testovacia štatistika pomerom vierohodnosti $U_{\text{LR}} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_J)) \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$, kde H_0 bude zamietnutá pre veľké hodnoty podielu $\frac{\widehat{\sigma}_0^2}{\widehat{\sigma}^2}$.

Dá sa ukázať, že $-\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J))$ je rastúcou funkciou F_{obs} . Úpravou podielu $\widehat{\sigma}_0^2/\widehat{\sigma}^2$ dostaneme

$$\begin{aligned} -\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J)) &= \frac{n}{2} \ln \left(\frac{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j + \bar{y}_j - \widehat{\mu})^2}{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2} \right) \\ &= \frac{n}{2} \ln \left(\frac{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2 + \sum_{j=1}^J n_j (\bar{y}_j - \widehat{\mu})^2}{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2} \right) \\ &= \frac{n}{2} \ln \left(1 + \frac{J-1}{n-J} \frac{\sum_{j=1}^J n_j (\bar{y}_j - \widehat{\mu})^2 / (J-1)}{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2 / (n-J)} \right) \\ &= \frac{n}{2} \ln \left(1 + \frac{J-1}{n-J} F_{\text{obs}} \right). \end{aligned}$$

Potom môžeme U_{LR} prepísať

$$u_{\text{LR}} = n \ln \left(1 + \frac{J-1}{n-J} F_{\text{obs}} \right).$$

ANOVA model v \mathbb{R} (funkcia `aov()`)Argumenty (vstupy) funkcie `aov()`:

1. ANOVA model formula v podobe $y \sim x$;
2. dátová tabuľka `data`;
3. nastavenie výstupu v podobe tabuľky s rozmermi $n \times 3$ obsahujúcej odhady $\hat{\mu}$, $\hat{\alpha}_j$ a reziduály (chyby) ε_{ji} , `projections=FALSE` (prednastavené);

Výstup funkcie `aov()`:

1. tabuľky s rozmermi $n \times 3$ obsahujúca odhady $\hat{\mu}$, $\hat{\alpha}_j$ a reziduály ε_{ji} , `projections`;
2. odhady \hat{y}_{ji} `fitted.values`;
3. reziduály ε_{ji} `residuals`;

Výstupy funkcie `summary(aov())`:

1. ANOVA tabuľka, kde
 - stupne voľnosti df_A a df_e `summary(MODEL)[[1]][1]`,
 - sumy štvorcov $SS_{A,obs}$ a $SS_{e,obs}$ `summary(MODEL)[[1]][2]`,
 - priemerné štvorce $MS_{A,obs}$ a $MS_{e,obs}$ `summary(MODEL)[[1]][3]`;
2. realizáciu testovacej štatistiky F_{obs} `summary(MODEL)[[1]][4]`;
3. p-hodnota `summary(aov())[1][5]`.

Funkcia `aov()` používa na výpočty funkciu lineárny regresný model `lm()`. Pri priamom použití funkcie `lm()` dostaneme ANOVA tabuľku ako `anova(lm())`. Odmocninu z rozptylu $\hat{\sigma}_e^2$ dostaneme pomocou `summary(lm())$sig`. Alternatívne je možné použiť funkciu `oneway.test()`, ktorej vstupom je ANOVA model formula v podobe $y \sim x$, dátová tabuľka `data` a nastavenie rovnosti rozptylov `var.equal=TRUE`. Výstupom sú realizácia testovacej štatistiky F_{obs} , stupne voľnosti df_A a df_e a p-hodnota.

Príklad 251 (test pomerom vierohodnosti o rovnosti stredných hodnôt) *Naprogramujte v \mathbb{R} test pomerom vierohodnosti o rovnosti stredných hodnôt za predpokladu homogenity rozptylov. Aplikujte na dáta `anova-head.txt` a premennú `bizyg.W` u mužov a porovnajte výsledok testu pomerom vierohodnosti s výsledkom ANOVA F-testu. Odôvodnite rozdiely vo výsledkoch.*

Riešenie v \mathbb{R}

```

1358 | "testy.o.stred.hodnotach" <- function(x,y){
1359 | MODEL <- aov(y~x)
1360 | F.stat <- summary(MODEL)[[1]][1,4]
1361 | p.hodnota.F <- summary(MODEL)[[1]][1,5]
1362 | VYSL.F.test <- c(F.stat,p.hodnota.F)
1363 | names(VYSL.F.test) <- c("test-stat","p-hodnota")
1364 | J <- nlevels(x)
1365 | n <- length(x)
1366 | u.LT <- n*log(1+(J-1)/(n-J)*F.stat)
1367 | p.hodnota.LR <- 1-pchisq(u.LT,df=J-1)
1368 | VYSL.LR.test <- c(u.LT,p.hodnota.LR)
1369 | names(VYSL.LR.test) <- c("test-stat","p-hodnota")
1370 | VYSL <- list(VYSL.F.test,VYSL.LR.test)
1371 | return(VYSL)
1372 | }
1373 | testy.o.stred.hodnotach(sex.sexor[sex=="m"],bizyg.W[sex=="m"])
1374 | #[[1]]
1375 | #test-stat p-hodnota
1376 | #3.32743009 0.07303222
1377 | #[[2]]
1378 | #test-stat p-hodnota
1379 | #9.8476790 0.0199063


```

Príklad 252 (testy o rovnosti stredných hodnôt; simulačná štúdia) *Majme 4 populácie, ktorých stredné hodnoty sú $\mu_1 = 390$, $\mu_2 = 405$, $\mu_3 = 415$ a $\mu_4 = 410$. Predpokladajme, že $Y_{ji} \sim N(\mu_j, \sigma_e^2)$, kde $\sigma_e^2 = 15^2$. Použite \mathbb{R} na simuláciu hustoty (1) necentrálneho $F_{df_A, df_e, \lambda^2}$ testovacích štatistik $F_{W, \lambda}^{(m)}$ (necentrálne F rozdelenie s df_A a df_e stupňami voľnosti a parametrom necentrality*

λ^2) a (2) necentrálneho $\chi^2_{df_A, \lambda^2}$ testovacích štatistík $u_{LR, \lambda}^{(m)}$ (necentrálne χ^2 rozdelenie s df_A stupňami voľnosti a parametrom necentrality λ^2), kde $\alpha = 0.05$, $K = 6$, $\lambda^2 = \sum_{j=1}^J (\mu_j - \hat{\mu})^2 / (\sigma_e^2 / K)$, $m = 1, 2, \dots, M$, pri $M = 1000$ opakovaníach. Vypočítajte silu v prípade (1) a (2). Okomentujte výsledok.

Riešenie v  (riešenie pozri na obrázku 8.3)

Na základe výsledkov príkladu 252 je možné konštatovať, že sila testu pomerom vierohodnosti pri danej alternatíve je väčšia ako sila ANOVA F -testu.



Obr. 8.3: Histogramy vygenerovaných testovacích štatistík za platnosti alternatívnej hypotézy v relatívnej škále superponované s teoretickými krivkami hustoty F_W (vľavo) a U_{LR} (vpravo)

Príklad 253 (testy o rovnosti stredných hodnôt; simulačná štúdia) Na základe simulačnej štúdie preverte, že ak (a) $Y_j \sim N(\mu_j, \sigma^2)$, kde $\mu_j = 1, \sigma^2 = 1/4$, $j = 1, 2, \dots, J$ a (b) $Y_j \sim [(1-p)N(\mu_j, \sigma^2) + pN(\mu_j, \sigma_1^2)]$, kde $p = 0.05$ a $\sigma_1^2 = 1$, potom testovacia štatistika (1) F_W má $F_{J-1, n-J}$ rozdelenie s $J-1$ a $n-J$ a (2) U_{LR} má χ^2_{J-1} rozdelenie s $J-1$ stupňami voľnosti. Použite rozsahy náhodných výberov $n_j = 10$ a $n_j = 50$ ($n = \sum_{j=1}^J n_j$). Pre každú simuláciu vypočítajte $F_{obs, m}$ a $u_{LR, m}$, $m = 1, 2, \dots, M$, kde $M = 10000$. Superponujte histogram vygenerovaných testovacích štatistík v relatívnej škále s teoretickou krivkou hustoty (1) F_W a (2) U_{LR} .

Riešenie (riešenie (a) pozri na obrázku 8.4)

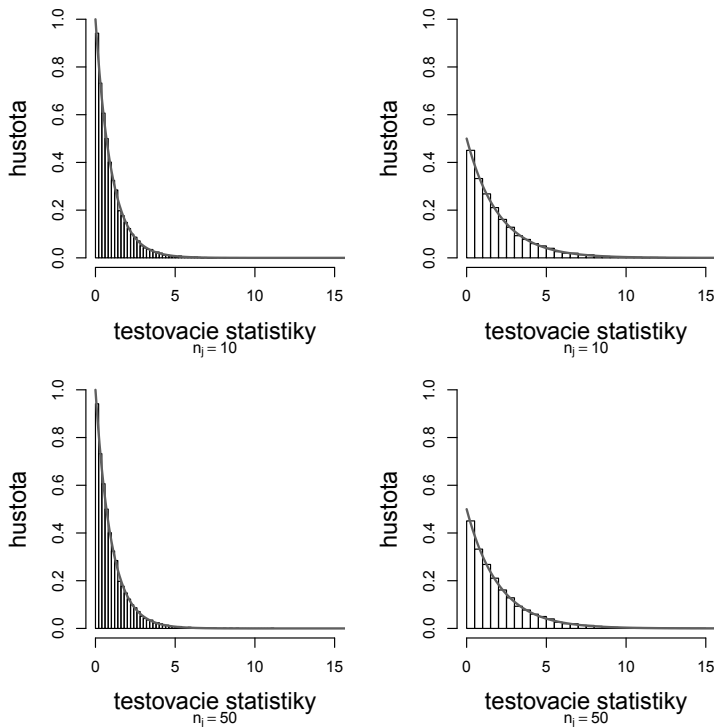
Na základe simulačnej štúdie z príkladu 253 je lepšie používať ANOVA F -test ako test pomerom vierohodnosti pre $n \leq 10$, avšak rozdiely medzi výsledkami sú veľmi malé, pretože obe testovacie štatistiky rýchlo konvergujú k svojim teoretickým rozdeleniam.

8.1.2 Metódy mnohonásobného porovnávania

Ak ANOVA F -test zamietne H_0 , potom je potrebné zistiť, ktoré rozdiely dvojíc stredných hodnôt sú štatisticky signifikantné na nominálnej hladine významnosti α . Môžeme tak urobiť pomocou **post-hoc testov**. Základným predpokladom ich použitia je, rovnako ako pre ANOVA model, splnenie podmienky homogenity rozptylov a normality Y_{ji} a chýb ε_{ji} . Ekvivalentnou H_0 je nasledovná hypotéza $H_0 : \mu_i = \mu_j$ pre $\forall i, j; i < j$. Prepíšme H_0 do všeobecnejšieho tvaru

$$H_0 : \sum_{j=1}^J a_j \mu_j = \sum_{j=1}^J a_j \mu_{0j} \text{ oproti } \sum_{j=1}^J a_j \mu_j \neq \sum_{j=1}^J a_j \mu_{0j} \text{ pre nejaké } \mathbf{a} = (a_1, a_2, \dots, a_J)^T \in \mathcal{A},$$

kde $\mathcal{A} = \{\mathbf{a} : \sum_{j=1}^J a_j = 0\}$ a \mathbf{a} je **vektor kontrastov**. Kontrasty nie sú nezávislé, pozri napr. Casella a Berger (2002). Vo všeobecnosti však môžeme predpokladať, že H_0 generuje podpriestor s hodnotou h . Potom definujeme $H_0 = \cap_{k=1}^h H_{0k}$, kde $h = \binom{J}{2} = J(J-1)/2$, ak ide o všetky párové porovnania.



Obr. 8.4: Histogramy vygenerovaných testovacích štatistík (za platnosti nulovej hypotézy) v relatívnej škále superponované s teoretickými krivkami hustoty F_W (vľavo) a U_{LR} (vpravo)

V prípade, že J -ta z porovnaných populácií je **kontrolná** (charakterizovaná μ_J) a ostatné majú byť porovnávané len s touto kontrolnou populáciou a nie medzi sebou, potom volíme $h = J - 1$ a zaujímate sa len napr. o rozdiely tvaru $|\bar{y}_{j\cdot} - \bar{y}_{J\cdot}|$, kde $j = 1, 2, \dots, J - 1$. Najprv testujeme H_0 viacvýberovým ANOVA F -testom na hladine významnosti α použitím ANOVA F -štatistiky. Ak H_0 nezamietame, nepokračujeme ďalej. Ak H_0 zamietame, chceme identifikovať, ktorú z hypotéz $\mathbf{a}^T \boldsymbol{\mu} = \mathbf{a}^T \boldsymbol{\mu}_0 = 0$, kde $\boldsymbol{\mu} = (\mu_1, \dots, \mu_J)^T$, zamietame (pre fixné \mathbf{a}). Počet hypotéz h poznáme vopred, ale množiny $\mathcal{H}_0 = \{k : H_{0k} = 0\}$ a $\mathcal{H}_1 = \{k : H_{0k} = 1\}$, t.j. množiny nezamietnutých a zamietnutých nulových hypotéz z množiny všetkých nulových hypotéz $\mathcal{H} = \mathcal{H}_0 \cup \mathcal{H}_1 = \{1, 2, \dots, h\}$, kde $h = h_0 + h_1$, $h_0 = \text{card}\{\mathcal{H}_0\}$ a $h_1 = \text{card}\{\mathcal{H}_1\}$, dopredu nepoznáme.

Pre $H_{0,ij} : \mu_i = \mu_j, i < j$, bude vektor kontrastov \mathbf{a}_k mať na i -tom mieste -1 , na j -tom mieste 1 , ostatné sú nuly, napr.

$$\mathbf{a}_1 = (1, -1, 0, \dots, 0)^T, \mathbf{a}_2 = (0, 1, -1, \dots, 0)^T, \dots, \mathbf{a}_{J-1} = (0, 0, \dots, 1, -1)^T,$$

z čoho vyplýva, že

$$\mathbf{a}_1 \Rightarrow \mu_1 = \mu_2, \mathbf{a}_2 \Rightarrow \mu_2 = \mu_3, \dots, \mathbf{a}_{J-1} \Rightarrow \mu_{J-1} = \mu_J,$$

čo implikuje $\mu_1 = \mu_2 = \dots = \mu_J = \mu$.

Pre nejaký vektor \mathbf{a} je stredná hodnota $E[\sum_{j=1}^J a_j \bar{Y}_{j\cdot}] = \sum_{j=1}^J a_j \mu_j$ a rozptyl $\text{Var}[\sum_{j=1}^J a_j \bar{Y}_{j\cdot}] = \sigma_e^2 \sum_{j=1}^J \frac{a_j^2}{n_j}$. Potom

$$Z_W = \frac{\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0}}{\sqrt{\sigma_e^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}} \mathcal{D} N(0, 1).$$

Rozptyl σ_e^2 nepoznáme a musíme ho odhadnúť. Výberový rozptyl v j -tej populácii je rovný $S_j^2 = \frac{1}{n_j-1} \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2$, kde $j = 1, 2, \dots, J$, sú nezávislé. Potom platí $(n_j - 1)S_j^2/\sigma_e^2 \sim \chi_{n_j-1}^2$. Keďže v modeloch \mathcal{F}_{H_0} a \mathcal{F}_{H_1} predpokladáme rovnosť rozptylov, potom môžeme písať $\hat{\sigma}_e^2$ ako $s^2 = \frac{1}{n-J} \sum_{j=1}^J (n_j - 1)s_j^2 = \frac{1}{n-J} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2 = \frac{1}{n-J} SS_{e,\text{obs}}$, kde $n - J = \sum_{j=1}^J (n_j - 1)$. Potom $(n - J)S^2/\sigma_e^2 \sim \chi_{n-J}^2$. Navyše S^2 je nezávislé na \bar{Y}_j ., a teda môžeme písať

$$T_{\mathbf{a}} = \frac{\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0}{\sqrt{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}} = \frac{\sum_{j=1}^J a_j \bar{Y}_j - \sum_{j=1}^J a_j \mu_{j0}}{\sqrt{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}} \stackrel{\mathcal{D}}{\sim} t_{n-J},$$

kde je matica plánu \mathbf{X} použitá bez prvého stĺpca (charakterizujúceho celkovú strednú hodnotu μ) a má preto rozmery $n \times J$ (podobne aj ďalej v celej kapitole 8). Realizáciou $T_{\mathbf{a}}$ je $t_{\mathbf{a}}$, p-hodnota = $\Pr(T_{\mathbf{a}} \geq |t_{\mathbf{a}}| | H_0)$ a H_0 zamietame, ak $|t_{\mathbf{a}}| \geq t_{n-J}(\alpha/2)$; $t_{n-J}(\alpha/2)$ je kritická hodnota t rozdelenia t stupňami voľnosti. $T_{\mathbf{a}} = T_{LSD}$ je **Waldova testovacia štatistika**, často nazývaná aj **Fisherova LSD štatistika** (z angl. *least significant difference*, t.j. najmenší signifikantný rozdiel) a test **viacvýberový Fisherov LSD test o lineárnom kontraste** $\sum_{j=1}^J a_j \mu_j$. Potom môžeme definovať **Waldov** $100 \times (1 - \alpha)\%$ empirický **IS pre nejakú lineárnu kombináciu** $\sum_{j=1}^J a_j \mu_j$ (nazývaný aj **empirický IS Fisherovho typu**) ako

$$\left(\sum_{j=1}^J a_j \bar{y}_j - t_{n-J}(\alpha/2) \sqrt{s^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}, \sum_{j=1}^J a_j \bar{y}_j + t_{n-J}(\alpha/2) \sqrt{s^2 \sum_{j=1}^J \frac{a_j^2}{n_j}} \right).$$

Označme

$$T_{\mathbf{a}}^2 = \frac{(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} = \frac{\left(\sum_{j=1}^J a_j \bar{Y}_j - \sum_{j=1}^J a_j \mu_{j0} \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}} = \frac{\left(\sum_{j=1}^J a_j (\bar{Y}_j - \mu_{j0}) \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}.$$

Potom

$$\sup_{\mathbf{a}: \sum_{j=1}^J a_j = 0} T_{\mathbf{a}}^2 = \frac{\sum_{j=1}^J n_j ((\bar{Y}_j - \bar{Y}_{..}) - (\mu_{j0} - \mu))^2}{S^2} = (J - 1)F_W,$$

kde $\bar{Y}_{..} = \sum_{j=1}^J n_j \bar{Y}_j / \sum_{j=1}^J n_j$ a $\mu = \sum_{j=1}^J n_j \mu_{j0} / \sum_{j=1}^J n_j$. Navyše

$$\sup_{\mathbf{a}: \sum_{j=1}^J a_j = 0} T_{\mathbf{a}}^2 \stackrel{\mathcal{D}}{\sim} (J - 1)F_{J-1, n-J}.$$

Čitateľ a menovateľ $(J - 1)F_W$ sú nezávislé. Tiež platí $S^2 \sim \sigma_e^2 \chi_{n-J}^2 / (n - J)$ a

$$1/\sigma_e^2 \left(\sum_{j=1}^J n_j ((\bar{Y}_j - \bar{Y}_{..}) - (\mu_{j0} - \mu))^2 \right) \sim \chi_{J-1}^2.$$

Scheffe ukázal, že

$$F_{\mathbf{a}} = \frac{(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} = \frac{(\sum_{j=1}^J a_j \bar{Y}_j - \sum_{j=1}^J a_j \mu_{j0})^2}{S^2 \sum_{j=1}^J a_j^2 / n_j} \stackrel{\mathcal{D}}{\sim} (J - 1)F_{J-1, n-J},$$

kde H_0 zamietame, ak $F_{\mathbf{a}} \geq (J - 1)F_{J-1, n-J}(\alpha)$, kde $F_{J-1, n-J}(\alpha)$ je kritická hodnota F rozdelenia s $J - 1$ a $n - J$ stupňami voľnosti. Je potrebné zdôrazniť, že H_0 musí platiť pre všetky kontrasty \mathbf{a} simultánne a H_0 zamietame, ak zamietame hypotézu o suprémé $T_{\mathbf{a}}^2$, t.j. zamietame H_0 v ANOVA F -teste. $F_{\mathbf{a}}$ sa nazýva **Waldova testovacia štatistika**, často nazývaná aj **Scheffeho štatistika** a test **viacvýberový Scheffeho test nulovosti všetkých kontrastov**. Realizáciou $F_{\mathbf{a}}$ je $F_{\mathbf{a}, \text{obs}}$

a (adjustovaná) p-hodnota = $\Pr(F_{\mathbf{a}} \geq F_{\mathbf{a},\text{obs}} | H_0)$. **Waldove simultánne** $100 \times (1 - \alpha)\%$ **empirické intervaly spoľahlivosti Scheffeho typu** definujeme ako

$$\left(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \sqrt{(J-1)F_{J-1, n-J}(\alpha)} \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \hat{\boldsymbol{\mu}} + \sqrt{(J-1)F_{J-1, n-J}(\alpha)} \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \right),$$

kde pravdepodobnosť pokrytia všetkých IS (simultánne) je rovná $1 - \alpha$. Za simultánnu inferenciu (t.j. testovanie H_{0k}) platíme dĺžkou simultánnych IS Scheffeho typu oproti IS Fisherovho typu, t.j. keďže garantujeme simultánny koeficient spoľahlivosti $1 - \alpha$, simultánne IS Scheffeho typu môžu byť dosť široké (platí $t_{n-J}(\alpha/2) \leq \sqrt{(J-1)F_{J-1, n-J}(\alpha)}$). Z čoho vyplýva, že Scheffeho testy majú menšiu silu ako t -testy (Casella a Berger, 2002).

Tukey ukázal, že

$$\sup_{\mathbf{a}: \sum_{j=1}^J a_j = 0} T_{\mathbf{a}} = \frac{\bar{Y}_{\max \cdot} - \bar{Y}_{\min \cdot}}{S \sqrt{\frac{1}{2} \left(\frac{1}{n_{\max} \bar{Y}_{\max \cdot}} + \frac{1}{n_{\min} \bar{Y}_{\min \cdot}} \right)}} \stackrel{\mathcal{D}}{\sim} q_{J, n-J},$$

kde $\bar{Y}_{\max \cdot} = \max_{\forall j} \bar{Y}_j$. a jemu prislúchajúci rozsah n_{\max} , $\bar{Y}_{\min \cdot} = \min_{\forall j} \bar{Y}_j$. a jemu prislúchajúci rozsah n_{\min} . Potom

$$F_{\mathbf{a}} = \frac{(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \stackrel{\mathcal{D}}{\sim} \frac{1}{2} q_{J, n-J}^2,$$

kde H_0 zamietame, ak $F_{\mathbf{a}} \geq \frac{1}{2} q_{J, n-J}^2(\alpha)$, kde $q_{J, n-J}(\alpha)$ je kritická hodnota **studentizovaného rozpätia** s J a $n - J$ stupňami voľnosti. Je potrebné opäť zdôrazniť, že H_0 musí platiť pre všetky kontrasty \mathbf{a} simultánne a H_0 zamietame, ak zamietame hypotézu o suprémne $T_{\mathbf{a}}$. $F_{\mathbf{a}}$ sa nazýva **Waldova testovacia štatistika**, často nazývaná aj **Tukeyho HSD štatistika** (alebo **Tukey-Kramerova štatistika**; HSD z angl. *honest significant difference*, t.j. „skutočný“ signifikantný rozdiel) a test **viacvýberový Tukeyho HSD test nulovosti všetkých kontrastov**. Realizáciou $F_{\mathbf{a}}$ je $F_{\mathbf{a},\text{obs}}$ a (adjustovaná) p-hodnota = $\Pr(F_{\mathbf{a}} \geq F_{\mathbf{a},\text{obs}} | H_0)$. **Waldove simultánne** $100 \times (1 - \alpha)\%$ **empirické intervaly spoľahlivosti Tukeyho typu** definujeme ako

$$\left(\mathbf{a}^T \hat{\boldsymbol{\mu}} - q_{J, n-J}(\alpha) \sqrt{\frac{1}{2} \hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \hat{\boldsymbol{\mu}} + q_{J, n-J}(\alpha) \sqrt{\frac{1}{2} \hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \right).$$

Príklad 254 (test trendu v jednofaktorovom ANOVA modeli) *Majme jednofaktorový ANOVA model, v ktorom chceme testovať H_0 o lineárnom trende, kde $\alpha_1 < \alpha_2 < \dots < \alpha_J$ a navyše $\alpha_j = a_j$. Ak napr. $J = 3$, potom $H_0 : \alpha_2 - \alpha_1 = \alpha_3 - \alpha_2$ alebo $H_0 : \alpha_1 - 2\alpha_2 + \alpha_3 = 0$, kde $\mathbf{a} = (1, -2, 1)^T$.*

Definícia 97 (chyba porovnávania α_c) *Chyba porovnávania (comparison-wise error, CWER) α_c je pravdepodobnosť zamietnutia práve jednej H_{0k} , keď táto H_{0k} je pravdivá, t.j. ide o pravdepodobnosť, že nastane práve jedna CHPD v jednom párovom porovnaní.*

Definícia 98 (experimentálna chyba α_e) *Experimentálna chyba (experiment-wise error, EWER) α_e je pravdepodobnosť zamietnutia aspoň jednej H_{0k} , keď všetky H_{0k} sú pravdivé, t.j. ide o pravdepodobnosť, že nastane aspoň jedna CHPD medzi všetkými h nezávislými párovými porovnaniami. Táto chyba je kontrolovaná na nominálnej hladine významnosti α .*

Z definícií 97 a 98 vyplýva, že $\Pr(\text{CHPD})$ jedného testu je rovná α_c a pravdepodobnosť správneho rozhodnutia je $1 - \alpha_c$. Za predpokladu, že máme h nezávislých párových porovnaní, bude mať náhodná premenná V (počet CHPD) binomické rozdelenie, t.j. $V \sim \text{Bin}(h, \alpha_c)$. Keďže α_e je pravdepodobnosť, že nastane aspoň jedna CHPD medzi všetkými h nezávislými párovými porovnaniami, môžeme ju definovať nasledovne

$$\alpha = \alpha_e = \Pr(V \geq 1) = 1 - \Pr(V = 0) = 1 - \binom{J}{2} \alpha_c^0 (1 - \alpha_c)^h = 1 - (1 - \alpha_c)^h.$$

Z tejto rovnosti vyplýva, že ak sa počet párových porovnaní zväčšuje, α_e sa blíži k jednotke (pozri tabuľku 8.1). Ak $h = 1$ (dvojvýberový prípad), potom $\alpha = \alpha_e = \alpha_c$.

Tabuľka 8.1: Experimentálna chyba α_e ako funkcia α_c a h

α_c/h	2	5	10	20	50
0.01	0.0199	0.0490	0.0956	0.1821	0.3950
0.05	0.0975	0.2262	0.4013	0.6415	0.9231
0.10	0.1900	0.4095	0.6513	0.8784	0.9948

Zamerajme sa na hodnotenie **zovšeobecnenej pravdepodobnosti CHPD** v podobe

1. **pravdepodobnosti najmenej jednej CHPD**, kde V je počet zamietnutých pravdivých H_{0k} (*family-wise error rate*, FWER: metódy napr. Fisher (1935) LSD, Tukey (1949, 1953, 1991) HSD, Scheffe (1953), Bonferroni (1936), Šidák (1967), Holm (1979), Hochberg (1988)); $\text{FWER} = \Pr(V \geq 1)$; **FWER adjustované (upravené) p-hodnoty** sú definované nasledovne

$$\tilde{p}_k = \inf \{ \alpha : H_{0k} \text{ zamietame na FWER} = \alpha \};$$

2. **očakávanej hodnoty podielu CHPD medzi zamietnutými hypotézami**, $\text{FDR} = E[V/R]$, ak $R > 0$ alebo 0, ak $R = 0$, kde R je počet zamietnutých pravdivých a nepravdivých H_0 , $\text{FDP} = V/R$ (*false discovery rate*, FDR, *false discovery proportion*, FDP: metódy napr. Benjamini a Hochberg (1995), Benjamini a Yekutieli (2001)); **FDR adjustované p-hodnoty** sú definované nasledovne

$$\tilde{p}_k = \inf \{ \alpha : H_{0k} \text{ zamietame na FDR} = \alpha \};$$

Kontrola FWER a FDR znamená nasledovné: $\text{FWER} \leq \alpha$ a $\Pr(\text{FDP} > \gamma) \leq \alpha$, kde $\gamma, \alpha \in (0, 1)$. Rovnako je možné zovšeobecniť aj silu testu (pozri napr. Dudoit a van der Laan, 2008).

Aby bolo možné robiť simultánnu inferenciu, je potrebné modifikovať kritickú hodnotu $t_{n-J}(\alpha/2)$ rozdelenia Fisherovej LSD štatistiky pomocou substitúcie $\alpha/2$ použitím jedno- a viackrokových metód. (**Jednokroková Bonferroniho**, resp. **Šidákova metóda** sú založené na princípe zmenšenia argumentu $\alpha/2$ kritickej hodnoty t -rozdelenia s $n - J$ stupňami voľnosti (obojsmerný test) na základe Bonferroniho, resp. Šidákovej nerovnosti, $\Pr(\cup_{k=1}^h A_k) \leq \sum_{k=1}^h \Pr(A_k)$, $\Pr(\cup_{k=1}^h A_k) \leq 1 - \alpha$, resp. $\Pr(\cap_{k=1}^h A_k) \geq \prod_{k=1}^h \Pr(A_k)$, $\Pr(\cap_{k=1}^h A_k) \geq 1 - \alpha$, na $\alpha/(2h)$, resp. $1 - (1 - \alpha/2)^{1/h}$, kde A_k je najaká udalosť. Bonferroniho metóda je *konzervatívnejšia* ako Šidákova (vedie ku menšiemu počtu zamietnutí, t.j. kritické hodnoty sú väčšie), lebo platí $(1 - \alpha)^{1/h} < 1 - \alpha/h$ pre všetky $\alpha > 0, h > 1$, teda $t_{n-J}(\alpha/h) > t_{n-J}(1 - (1 - \alpha)^{1/h})$. Rozdiel je ale zanedbateľný. V súvislosti s kontrolou FWER a adjustovanými p-hodnotami platí pre Bonferroniho nerovnosť

$$\text{FWER} = \Pr(V > 0) = \Pr\left(\cup_{k=1}^{h_0} (\tilde{P}_k \leq \alpha)\right) \leq \sum_{k=1}^{h_0} \Pr(\tilde{P}_k \leq \alpha) \leq \sum_{k=1}^{h_0} \frac{\alpha}{h} = h_0 \frac{\alpha}{h} \leq \alpha.$$

a pre Šidákovu nerovnosť

$$\begin{aligned} \Pr(V = 0) &= \Pr\left(\cap_{k=1}^{h_0} (\tilde{P}_k \geq \alpha)\right) = \prod_{k=1}^{h_0} \Pr(\tilde{P}_k \geq \alpha) \\ &= \prod_{k=1}^{h_0} \Pr(P_k \geq 1 - (1 - \alpha)^{1/h}) = 1 - (1 - \alpha)^{h_0/h}, \end{aligned}$$

z ktorej vyplýva, že $\text{FWER} = \Pr(V > 0) = 1 - \Pr(V = 0) = (1 - \alpha)^{h_0/h} \leq \alpha$.

Ak použijeme vyššie uvedené postupy na h párových porovnaní, potom pravdepodobnosť, že aspoň raz chybné zamietneme jednu z rovností $\mu_i = \mu_j$, ktorá platí, nie je väčšia ako α . Ak ide o vyvážené triedenie, kde $n_1 = n_2 = \dots = n_J$, potom je táto pravdepodobnosť presne rovná α . T.j. ak sú všetky hypotézy pravdivé, pravdepodobnosť identifikácie, že niektorá z nich je nepravdivá, nie je viac ako α , pretože α je pravdepodobnosť zamietnutia ANOVA F -testu. Taktiež ANOVA F -test je test všetkých $\mathbf{a}_k^T \boldsymbol{\mu} = 0, k = 1, 2, \dots, h$, a ak je tento test zamietnutý, ešte nemusí nastať situácia, že niektorá z vyššie spomenutých metód nezamietne nejakú hypotézu. Práve pre túto vlastnosť je experimentálna chyba menšia ako α . Ale ak ANOVA F -test zamietajú nulovú hypotézu, potom Scheffeho metóda bude zamietat

H_0 aspoň pre jeden kontrast.

Nech $SS(\mathbf{a}_k^T \boldsymbol{\mu}) = \left(\sum_{j=1}^J a_{kj} \bar{y}_j - \sum_{j=1}^J a_{kj} \mu_j \right)^2 / \left(\sum_{j=1}^J a_{kj}^2 / n_j \right)$. LSD metóda je silnejšia ako Scheffeho metóda. Scheffeho metóda zamietá H_0 , ak $SS(\mathbf{a}_k^T \boldsymbol{\mu}) / MS_e > h F_{h, df_e}(\alpha)$, LSD metóda zamietá H_0 , ak $SS(\mathbf{a}_k^T \boldsymbol{\mu}) / MS_e > F_{1, df_e}(\alpha)$. Navyše platí, že $h F_{h, df_e}(\alpha) > F_{1, df_e}(\alpha)$.

Ak H_0 zamietneme ANOVA F -testom, potom je LSD metóda silnejšia ako Šidákova a Bonferroniho metóda, pretože $F_{1, df_e}(\alpha/h) > F_{1, df_e}(1 - (1 - \alpha)^{1/h}) > F_{1, df_e}(\alpha)$. Bonferroniho metóda je dizajnovaná na konečné množstvo hypotéz, a teda nie je prekvapujúce, že je silnejšia ako Scheffeho metóda pre testovanie h hypotéz, ak h nie je príliš veľké.

Príklad 255 (Studentov t -test vs. Tukeyho LSD metóda) Pomocou simulačnej štúdie, vygenerujte $M = 10000$ náhodných výberov z $N(0, 1)$ pre $n = 24$, $J = 6$, vypočítajte t -štatistiky (1) Fisherove $T_{LSD, m, j}$, $m = 1, 2, \dots, M$, $j = 1, 2, \dots, 4$, a (2) maximum Fisherových štatistik $\max_{v, j}(T_{LSD, m, j})$, čo je Tukeyho štatistika $T_{HSD, m}$. Nakreslite hustoty (1) a (2), odhadnuté pomocou funkcie `density()`, do jedného obrázka spolu s ich korešpondujúcimi kvantilmi.

Riešenie v \mathbb{R} (pozri obrázok 8.5)

```

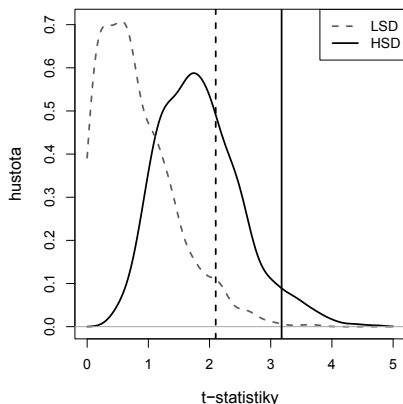
1380 | x <- factor(rep(LETTERS[1:6], rep(4, 6)))
1381 | n <- 24
1382 | J <- 6
1383 | alfa <- 0.05
1384 | model.sim <- summary(lm(rnorm(24)~x))
1385 | model.sim$coef[,1] # regresne koeficienty
1386 | # (Intercept)      xB      xC      xD      xE      xF
1387 | # -0.1517165    0.4501536    0.1832767    0.1540238    0.2710701    -0.1914448
1388 | model.sim$sig # 1.063496 odmocnina z MSE
1389 | model.sim$coef[2,1]*sqrt(2)/model.sim$sig # 0.9493587; t-statistika pre A a B
1390 | kvantil.t <- qt(1-alfa/2, n-J) # 2.100922; kvantil t-rozdelenia
1391 | # rozsah t-statistik
1392 | rozsah.t.stat <- range(c(0, model.sim$coef[-1,1])) # -0.1914448  0.4501536
1393 | # maximum t-statistik
1394 | (rozsah.t.stat[2]-rozsah.t.stat[1])*sqrt(2)/model.sim$sig # 0.8531835
1395 | # simulacia pre M=1000
1396 | M <- 1000
1397 | TESTSTAT <- matrix(0, M, 2)
1398 | for(i in 1:M){
1399 |   model.sim <- summary(lm(rnorm(24)~x))
1400 |   TESTSTAT[i, 1] <- abs(model.sim$coef[2,1]*sqrt(2)/model.sim$sig)
1401 |   rozsah.t.stat <- range(c(0, model.sim$coef[-1,1]))
1402 |   TESTSTAT[i, 2] <- (rozsah.t.stat[2]-rozsah.t.stat[1])*sqrt(2)/model.sim$sig
1403 | }
1404 | # podiel signifikantnych t-statistik , porovnanie A a B
1405 | sum(TESTSTAT[,1] > kvantil.t)/M # 0.05
1406 | # podiel signifikantnych max t-statistik
1407 | sum(TESTSTAT[,2] > kvantil.t)/M # 0.315
1408 | # kriticka hodnota nad ktorou uz zamietame
1409 | quantile(TESTSTAT[,2], 1-alfa) # 3.158423
1410 | # kvantil studentizovaneho rozpatia
1411 | kvantil.qt <- qtkey(1-alfa, J, n-J)/sqrt(2) # 3.178035
1412 | # obrazok
1413 | windows(5,5)
1414 | par(mar=c(4.5, 4.5, 1, 1))
1415 | hust.max <- density(TESTSTAT[,2], from=0, to=5)
1416 | hust.AB <- density(TESTSTAT[,1], from=0, to=5)
1417 | matplot(hust.AB$x, cbind(hust.max$y, hust.AB$y), type="l", lwd=2,
1418 |         xlab="t-statistiky", ylab="hustota", cex.lab=1.2)
1419 | abline(h=0, col="grey")
1420 | abline(v=kvantil.t, lty=2, lwd=2)
1421 | abline(v=kvantil.qt, lwd=2)
1422 | legend("topright", c("LSD", "HSD"), col=c("red", "black"), lty=c(2,1), lwd=c(2,2))

```

Porovnanie LSD a HSD metódy pomocou simulácie 1000 náhodných výberov z $N(0, 1)$, kde $n = 24$, $J = 6$, ukazujú, že použitie LSD vedie ku zvýšeniu $\Pr(\text{CHPD})$ až na $\alpha_{LSD} = 0.32 \gg \alpha$ bez použitia ANOVA F -testu (pozri obrázok 8.5), t.j. použitie kritických hodnôt $t_{n-J}(\alpha/2)$ namiesto $q_{J, n-J}(\alpha)$ pri teste maximálneho rozdielu stredných hodnôt vedie ku 32% riziku zamietnutia H_0 , keď H_0 platí.

Všeobecne LSD je metóda silnejšia ako ostatné metódy na detekciu pravdivých $\mathbf{a}_k^T \boldsymbol{\mu} \neq \mathbf{a}_k^T \boldsymbol{\mu}_0$, ale ak nastane $\mathbf{a}_k^T \boldsymbol{\mu} = \mathbf{a}_k^T \boldsymbol{\mu}_0$, potom je vyššia $\Pr(\text{CHPD})$, ako pri iných metódach, t.j. pravdepodobnosť, že takúto hypotézu identifikujeme ako rozdielnu od nuly.

Čím je menšia hodnota (dimenzia) h podpriestoru konečného počtu hypotéz, tým je väčšia sila Scheffeho testu. Majme dva podpriestory, jeden s dimenziou h_A a druhý s dimenziou h_B , kde $h_A > h_B$. Je garantované, že experimentálna chyba nepresiahne α . Silnejšia procedúra je tá, ktorá pravdivo zamietá častejšie. Na základe Scheffeho metódy zamietame v prvom prípade, ak $SS(\mathbf{a}_k^T \boldsymbol{\mu}) / MS_e > h_A F_{h_A, df_e}(\alpha)$ a v druhom prípade, ak $SS(\mathbf{a}_k^T \boldsymbol{\mu}) / MS_e > h_B F_{h_B, df_e}(\alpha)$. Keďže $h_A > h_B$, potom



Obr. 8.5: Odhadnuté hustoty vybraných t -štatistík T_{LSD} (pre rozdiel populácií A a B) a maximálnych t -štatistík (T_{HSD}) spolu s korešpondujúcimi teoretickými kritickými hodnotami $t_{n-J}(0.025)$, resp. a $q_{J,n-J}(0.05)$

$h_A F_{h_A, df_e}(\alpha) \geq h_B F_{h_B, df_e}(\alpha)$, teda očakávame viac zamietnutí v podpriestore s dimenziou h_B a navyše táto procedúra je silnejšia (Christensen, 2002). Jednou z výhod Scheffeho metódy je, že ide o možný test akejkolvek hypotézy v podpriestore, môžeme sa pozrieť do dát a vybrať H_0 a test zostáva validný. Táto metóda je najvhodnejšia na testovanie vybraných kontrastov, ale $\Pr(\text{CHPD})$ je za platnosti H_0 výrazne pod nominálnou α , sila testu je tiež dosť nízka v porovnaní s inými metódami.

Všeobecne môžeme písať nasledovné

$$hF_{h, df_e}(\alpha) > F_{1, df_e}(\alpha/h) > F_{1, df_e}(1 - (1 - \alpha)^{1/h}) > \frac{q_{J, df_e}^2(\alpha)}{2} > F_{1, df_e}(\alpha), h > 1,$$

z čoho vyplýva pre silu nasledovné

$$(1 - \beta)_{\text{LSD}} > (1 - \beta)_{\text{HSD}} > (1 - \beta)_{\text{Šidák}} > (1 - \beta)_{\text{Bonferroni}} > (1 - \beta)_{\text{Scheffe}}$$

a pre $\Pr(\text{CHPD})$

$$\Pr(\text{CHPD})_{\text{LSD}} > \Pr(\text{CHPD})_{\text{HSD}} > \Pr(\text{CHPD})_{\text{Šidák}} > \Pr(\text{CHPD})_{\text{Bonferroni}} > \Pr(\text{CHPD})_{\text{Scheffe}},$$

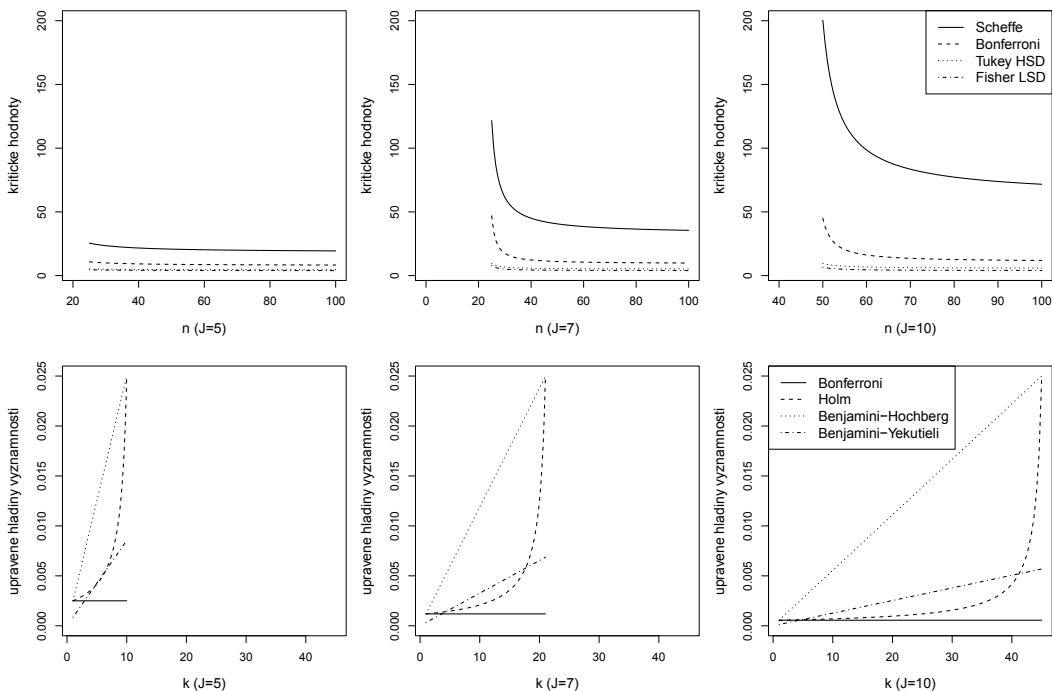
pričom sa rozdiely zväčšujú so zväčšujúcim sa J (pozri obrázok 8.6).

Tukeyho HSD nie je natoľko ovplyvnená malým rozsahom n pri veľkých J ako Bonferroniho a Šidákovu metódu. Použitie Scheffeho metódy nie je pri takejto situácii vhodné (kritické hodnoty sú príliš vysoké, pozri obrázok 8.6, prvý riadok). Pri fixnom počte pozorovaní n je sila všetkých metód pri danej alternatíve vyššia pri nižšom J (pozri obrázok 8.1).

Ďalšou skupinou metód sú **sekvenčne zamietajúce (viackrokové) metódy** založené na Bonferroniho a Šidákovom princípe. Hlavným princípom je zoradenie p -hodnôt do neklesajúcej postupnosti vypočítaných na základe napr. T_{LSD} , kde $p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(h)}$. Ďalej nech $\alpha_1 \leq \alpha_2 \leq \dots \leq \alpha_h$ sú konstanty a $k = 1, 2, \dots, h$.

Ak zamietanie prebieha nasledovne – ak $p_{(1)} > \alpha_1$, potom nezamietame žiadnu H_0 , inak $p_{(1)} \leq \alpha_1, \dots, p_{(r)} \leq \alpha_r$ a $H_{0(1)}, \dots, H_{0(r)}$ sú zamietnuté, kde $r \leq h$ je najväčší index spĺňajúci nerovnosť – hovoríme o **step-down procedúre** (začíname s najmenšou p -hodnotou a pokračujeme zamietaním, pokiaľ sú korešpondujúce p -hodnoty malé). Holm (1979) navrhol na základe Bonferroniho princípu tzv. **Holm-Bonferroniho** $\alpha_k = \alpha / (h - k + 1)$ a Dudoit a van der Laan (2008) navrhli na základe Šidákovho princípu tzv. **Holm-Šidákovu** $\alpha_k = 1 - (1 - \alpha)^{1/(h-k+1)}$.

Ak zamietanie prebieha nasledovne – ak $p_{(h)} \leq \alpha_h$, potom zamietame všetky H_0 , inak $p_{(1)} > \alpha_1, \dots, p_{(r+1)} > \alpha_{r+1}$ a $H_{0(1)}, \dots, H_{0(r+1)}$ nie sú zamietnuté, kde r je najmenší index spĺňajúci nerovnosť – hovoríme o **step-up procedúre** (začíname s najväčšou p -hodnotou a pokračujeme neza-



Obr. 8.6: Kritické hodnoty – Scheffeho $hF_{h,df_e}(\alpha)$, Bonferroniho $F_{1,df_e}(\alpha/h)$, Tukeyho HSD $q_{J,n-J}^2(\alpha)$ a Fisherove LSD $F_{1,df_e}(\alpha)$, $J = 5, 7, 10$, pre rôzne $n < 100$, kde $n - J > 0$ (prvý riadok); upravené hladiny významnosti α_k – Bonferroniho $\alpha_k = \alpha/h$, Holmovo $\alpha_k = \alpha/(h - k + 1)$, Benjamini-Hochbergovo $\alpha_k = k\alpha/h$, Benjamini-Yekutieliho $\alpha_k = k\alpha/(h \sum_{l=1}^h 1/l)$, $J = 5, 7, 10$, pre vzrastajúce $k = 1, 2, \dots, h$ (druhý riadok)

mietaním pokiaľ sú korešpondujúce p-hodnoty veľké). Hochberg (1988) navrhol na základe Bonferroniho metódy tzv. **Hochberg-Bonferroniho** $\alpha_k = \alpha/(h - k + 1)$, na základe Šidákovho princípu tzv. **Hochberg-Šidákov** $\alpha_k = 1 - (1 - \alpha)^{1/(h-k+1)}$, Benjamini a Hochberg (1995) navrhli tzv. **Benjamini-Hochbergove** $\alpha_k = k\alpha/h$, Benjamini a Yekutieli (2001) navrhli tzv. **Benjamini-Yekutieliho** $\alpha_k = k\alpha/(h \sum_{l=1}^h 1/l)$. Konštanty α_k pre $k = 1$ a $k = h$ sú pre prvé dve metódy rovnaké, ale pre $k \neq 1, h > 0$, Benjamini-Hochbergove α_k sú väčšie, čo indikuje častejšie zamietanie. So zväčšujúcim sa počtom porovnávaných skupín sa sklon priamky, prechádzajúcej bodmi (k, α_k) Benjamini-Hochbergových α_k , znižuje. Hochberg-Bonferroniho (Holm-Bonferroniho) α_k sa so zvyšujúcim sa J približujú hodnote α_k jednokrokovej Bonferroniho metódy s výnimkou vysokých indexov k , čo hovorí o *liberálnosti* (vedie ku väčšiemu počtu zamietnutí, t.j. kritické hodnoty sú menšie), podobne ako aj jednokroková Bonferroniho metóda (pozri obrázok 8.6, druhý riadok). Benjamini-Yekutieliho α_k boli navrhnuté pre prípady závislosti testovacích štatistík, čo je častý prípad pri aplikácii mnohonásobného porovnávania pri mnohorozmerných (h -rozmerných) problémoch napr. v genetike (závislosť porovnávaných génov) a antropológii (asymetria dlhých kostí), kde pri dvojvýberovom alebo párovom prípade aplikujeme najprv Hotellingov T^2 -test a potom h post-hoc dvojvýberových Studentových t -testov pre rozdiel stredných hodnôt, pri viacvýberovom prípade najprv MANOVA F -test a potom h post-hoc ANOVA F -testov s príslušnou korekciou α_k podľa výberu metódy.

Adjustované hladiny významnosti α_k sú definované nasledovne

- Bonferroniho $\alpha_k = \alpha/h$,
- Šidákov $\alpha_k = 1 - (1 - \alpha)^{1/h}$,
- Holm-Bonferroniho *step-down* $\alpha_k = \alpha/(h - k + 1)$,

- Holm-Šidákove *step-down* $\alpha_k = 1 - (1 - \alpha)^{1/(h-k+1)}$,
- Hochberg-Bonferroniho *step-up* $\alpha_k = \alpha/(h - k + 1)$,
- Hochberg-Šidákove *step-up* $\alpha_k = 1 - (1 - \alpha)^{1/(h-k+1)}$,
- Benjamini-Hochbergove *step-up* $\alpha_k = k\alpha/h$,
- Benjamini-Yekutieliho *step-up* $\alpha_k = k\alpha/(h \sum_{l=1}^h 1/l)$.

Argument $\alpha/2$ kritickej hodnoty $t_{n-J}(\alpha/2)$ sa substituuje α_k . Potom budú **Waldove simultánne** $100 \times (1 - \alpha)\%$ **empirické intervaly spoľahlivosti Fisherovho typu** definované nasledovne

$$\left(\mathbf{a}^T \hat{\boldsymbol{\mu}} - t_{n-J}(\alpha_k) \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \hat{\boldsymbol{\mu}} + t_{n-J}(\alpha_k) \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \right).$$

Adjustované p-hodnoty p_k sú definované nasledovne (Yekutieli a Benjamini, 1999)

- Bonferroniho $\tilde{p}_k = \min \{hp_k, 1\}$,
- Šidákove $\tilde{p}_k = 1 - (1 - p_k)^h$,
- Holm-Bonferroniho *step-down* $\tilde{p}_{(j)} = \max_{k=1, \dots, j} \{ \min \{ (h - k + 1)p_{(k)}, 1 \} \}$,
- Holm-Šidákove *step-down* $\tilde{p}_{(j)} = \max_{k=1, \dots, j} \{ (1 - (1 - p_{(k)})^{h-k+1}) \}$,
- Hochberg-Bonferroniho *step-up* $\tilde{p}_{(j)} = \min_{k=j, \dots, h} \{ \min \{ (h - k + 1)p_{(k)}, 1 \} \}$,
- Hochberg-Šidákove *step-up* $\tilde{p}_{(j)} = \min_{k=j, \dots, h} \{ (1 - (1 - p_{(k)})^{h-k+1}) \}$,
- Benjamini-Hochbergove *step-up* $\tilde{p}_{(j)} = \min_{k=j, \dots, h} \{ \min \{ \frac{h}{k} p_{(k)}, 1 \} \}$,
- Benjamini-Yekutieliho *step-up* $\tilde{p}_{(j)} = \min_{k=j, \dots, h} \{ \min \{ \frac{h \sum_{l=1}^h 1/l}{k} p_{(k)}, 1 \} \}$.

Metódy kontrolujúce FWER sú konzervatívnejšie, metódy kontrolujúce FDR sú liberálnejšie (Shaffer, 1995). Viackrokové metódy sú menej konzervatívne než jednokrokové. Teda pri fixovanej nominálnej α použitie FDR metódy vedie ku vyššej sile post-hoc testov pri danej alternatíve. FDR je sľubnou alternatívou ku FWER, aj napriek vyššiemu počtu CHPD, pokiaľ ich počet je malý v porovnaní so všetkými zamietnutými hypotézami (pozri napr. Dudoit a van der Laan, 2008). Pri malom počte porovnávaných stredných hodnôt (a teda malom počte post-hoc testov) je vhodné použiť napr. Bonferroniho metódu alebo Tukey HSD test. Pri veľkom počte porovnávaných stredných hodnôt je vhodnejšie použiť sekvenčné metódy. Pri mnohorozmerných problémoch je vhodné použiť metódu Benjamini a Yekutieli (2001).

Mnohonásobné porovnávanie v \mathbb{R}

Na Tukeyho HSD metódu použijeme funkciu `TukeyHSD(aov(), ordered=FALSE)`, kde argument `ordered` ponechá pôvodné poradie hypotéz H_{0k} . Výstupom je tabuľka obsahujúca odhady rozdielov stredných hodnôt $\bar{y}_i - \bar{y}_j$, dolné a horné hranice Waldových simultánnych $100 \times (1 - \alpha)\%$ empirických IS Tukeyho typu a adjustované p-hodnoty \tilde{p}_k . Na jednokrokové a viackrokové metódy (výpočet adjustovaných p-hodnôt) použijeme funkciu `pairwise.t.test(y,x,p.adjust="metoda", pool.sd=TRUE)`, kde argument `pool.sd=TRUE` predstavuje použitie $\hat{\sigma}_e^2$ a argument `p.adjust="metoda"` špecifikuje metódu nasledovne

1. Bonferroniho `p.adjust="bonferroni"`,
2. Holm-Bonferroniho `p.adjust="holm"`,
3. Hochberg-Bonferroniho `p.adjust="hochberg"`,

4. Benjamini-Hochbergove $p.adjust="BH"$ a

5. Benjamini-Yekutieliho $p.adjust="BY"$.

Funkcia $lm()$ má prednastavené kontrasty párových porovnaní s prvou populáciou, $\alpha_j - \alpha_1$, kde $J > 1$, kedy použijeme vstupné argumenty y a x . Pokiaľ by sme chceli testovať nulovosť jednotlivých α_j , použijeme vstupné argumenty $y - \text{mean}(y)$ a $x - 1$ (argument $x - 1$ znamená model bez interceptu μ).

Minimálny rozsah K môžeme počítať aj na základe post-hoc testov, kde použijeme koeficient necentrality definovaný na základe (1) $\lambda = \sqrt{(J-1)\sigma_A^2/(\sigma_e^2/K)}$ alebo (2) $\lambda = |\delta|/\sqrt{2\sigma_e^2/K}$. Potom

1. Fisherova LSD metóda, kde minimálny rozsah bude riešením iteračných rovníc

$$F_{1,J(K-1),\lambda^2}(\beta) = F_{1,J(K-1)}(1 - \alpha),$$

2. Tukeyho HSD metóda, kde minimálny rozsah bude riešením iteračných rovníc

$$F_{1,J(K-1),\lambda^2}(\beta) = \frac{q_{J,J(K-1)}^2(1 - \alpha)}{2},$$

3. Šidákova metóda, kde minimálny rozsah bude riešením iteračných rovníc

$$F_{1,J(K-1),\lambda^2}(\beta) = F_{1,J(K-1)}((1 - \alpha)^{1/h}),$$

4. Bonferroniho metóda, kde minimálny rozsah bude riešením iteračných rovníc

$$F_{1,J(K-1),\lambda^2}(\beta) = F_{1,J(K-1)}(1 - \alpha/h),$$

5. Scheffeho metóda, kde minimálny rozsah bude riešením iteračných rovníc

$$F_{1,J(K-1),\lambda^2}(\beta) = (J - 1)F_{J-1,J(K-1)}(1 - \alpha),$$

Príklad 256 (minimálny rozsah; post-hoc testy) *Majme štyri populácie, ktorých stredné hodnoty sú $\mu_1 = 390$, $\mu_2 = 405$, $\mu_3 = 415$ a $\mu_4 = 410$. Predpokladajme, že $X \sim N(\mu_j, \sigma_e^2)$. Vypočítajte minimálny rozsah K , ak $\sigma_e^2 = 20^2$ a $\alpha = 0.05$, použitím (1) Fisherovej LSD metódy, (2) Tukeyho HSD metódy, (3) Šidákovej metódy, (4) Bonferroniho metódy a (5) Scheffeho metódy. Výsledky porovnajte s K vypočítaným v príklade 250. Funkcie nazvite nasledovne (1) `minimalny.rozsah.Fisher()`, (2) `minimalny.rozsah.Tukey()`, (3) `minimalny.rozsah.Sidak()`, (4) `minimalny.rozsah.Bonferroni()` a (5) `minimalny.rozsah.Scheffe()`.*

Riešenie

(1) Fisherova LSD metóda – minimálny rozsah $K = 10$ a $n = KJ = 40$.

(2) Tukeyho HSD metóda – minimálny rozsah $K = 15$ a $n = KJ = 60$.

(3) Šidákova metóda – minimálny rozsah $K = 15$ a $n = KJ = 60$.

(4) Bonferroniho metóda – minimálny rozsah $K = 15$ a $n = KJ = 60$.

(5) Scheffeho metóda – minimálny rozsah $K = 16$ a $n = KJ = 64$.

Porovnaním všetkých použitých metód dostaneme nasledovné poradie minimálnych rozsahov

$$n_{\text{LSD}} < n_{\text{HSD}} = n_{\text{Šidák}} = n_{\text{Bonferroni}} < n_{\text{Scheffe}}.$$

Vzťahy medzi n korešpondujú poradiu kritických hodnôt. Výpočet je ovplyvnený malými rozsahmi K , zaokrúhľovaním n na nula desatinných miest a voľbou h pri Bonferroniho a Šidákovej metóde. Toho dôsledkom sú aj odlišné hodnoty sily, ktorá pre dané n pri rôznych metódach prvýkrát prekročí hranicu 0.8.

Príklad 257 (jednorozmerný prípad) Majme koncentráciu stroncia Sr (mg/ml) v piatich vodných celkoch (pozri tabuľku 8.2). Otestujte rovnosť stredných hodnôt ANOVA F-testom pomocou funkcií (1) `aov()` (2) `oneway.test()` a (3) `lm()`. Ak je H_0 zamietnutá na $\alpha = 0.05$, potom použite (1) Tukeyho HSD metódu (T_{HSD} štatistiku), vypočítajte adjustované p-hodnoty, simultánne 95% empirické IS Tukeyho typu pre všetky párové porovnania rozdielov stredných hodnôt a zobrazte ich graficky. (2) Vypočítajte adjustované p-hodnoty a Waldove simultánne 95% empirické IS Fisherovho typu pre všetky párové porovnania rozdielov stredných hodnôt (a) Bonferroniho metódou, (b) Holmovou step-down metódou, (c) Hochbergovou step-up metódou, (d) Benjamini-Hochbergovou step-up metódou a (e) Benjamini-Yekutieliho step-up metódou. (3) Po náhľade na dáta vhodne zadefinujte kontrasty a aplikujte na ne Scheffeho metódu.

Tabuľka 8.2: Koncentrácia stroncia Sr (mg/ml) v piatich vodných celkoch

A (1)	B (2)	C (3)	D (4)	E (5)
28.2	39.6	46.3	41.0	56.3
33.2	40.8	42.1	44.1	54.1
36.4	37.9	43.5	46.4	59.4
34.6	37.1	48.8	40.2	62.7
29.1	43.6	43.7	38.6	60.0
31.0	42.4	40.1	36.3	57.3

Riešenie (aj v , pozri obrázok 8.7)

```


1423 K <- 6
1424 J <- 5
1425 VodCelk <- factor(rep(LETTERS[1:J], rep(K, J)))
1426 ConcStr.1 <- c(28.2, 33.2, 36.4, 34.6, 29.1, 31.0)
1427 ConcStr.2 <- c(39.6, 40.8, 37.9, 37.1, 43.6, 42.4)
1428 ConcStr.3 <- c(46.3, 42.1, 43.5, 48.8, 43.7, 40.1)
1429 ConcStr.4 <- c(41.0, 44.1, 46.4, 40.2, 38.6, 36.3)
1430 ConcStr.5 <- c(56.3, 54.1, 59.4, 62.7, 60.0, 57.3)
1431 ConcStr <- c(ConcStr.1, ConcStr.2, ConcStr.3, ConcStr.4, ConcStr.5)
1432 mean(ConcStr) # 43.16
1433 PRIEM.ConcStr <- tapply(ConcStr, VodCelk, mean)
1434 round(PRIEM.ConcStr, 2)
1435 #   A   B   C   D   E
1436 #32.08 40.23 44.08 41.10 58.30
1437 PRIEM.str <- tapply(ConcStr~mean(ConcStr), VodCelk, mean)
1438 round(PRIEM.str, 2)
1439 #   A   B   C   D   E
1440 # -11.08 -2.93 0.92 -2.06 15.14
1441 # obrazok — model FH0 a FH1
1442 windows(10, 5)
1443 par(mfcol=c(1, 2), mar=c(5, 4.5, 1, 1))
1444 plot(1:30, ConcStr, type="n", ylab="Sr_(mg/ml)", xlab="poradie",
1445      sub="nulovy_ANOVA_model", cex.lab=1.2)
1446 for(i in 1:30) lines(c(i, i), c(mean(ConcStr), ConcStr[i]), col="grey", lwd=2)
1447 abline(mean(ConcStr), 0, lwd=2)
1448 points(1:30, ConcStr, pch=16)
1449 plot(1:30, ConcStr, type="n", ylab="Sr_(mg/ml)", xlab="poradie",
1450      sub="ANOVA_model", cex.lab=1.2)
1451 for(i in 1:6) lines(c(i, i), c(PRIEM.ConcStr[1], ConcStr[i]), col="grey", lwd=2)
1452 for(i in 7:12) lines(c(i, i), c(PRIEM.ConcStr[2], ConcStr[i]), col="grey", lwd=2)
1453 for(i in 13:18) lines(c(i, i), c(PRIEM.ConcStr[3], ConcStr[i]), col="grey", lwd=2)
1454 for(i in 19:24) lines(c(i, i), c(PRIEM.ConcStr[4], ConcStr[i]), col="grey", lwd=2)
1455 for(i in 25:30) lines(c(i, i), c(PRIEM.ConcStr[5], ConcStr[i]), col="grey", lwd=2)
1456 lines(c(1, 6), c(PRIEM.ConcStr[1], PRIEM.ConcStr[1]), lwd=2)
1457 lines(c(7, 12), c(PRIEM.ConcStr[2], PRIEM.ConcStr[2]), lwd=2)
1458 lines(c(13, 18), c(PRIEM.ConcStr[3], PRIEM.ConcStr[3]), lwd=2)
1459 lines(c(19, 24), c(PRIEM.ConcStr[4], PRIEM.ConcStr[4]), lwd=2)
1460 lines(c(25, 30), c(PRIEM.ConcStr[5], PRIEM.ConcStr[5]), lwd=2)
1461 points(1:30, ConcStr, pch=16)
1462
1463 StrMOD01 <- aov(ConcStr~VodCelk)
1464 summary(StrMOD01) # ANOVA tabuľka
1465 oneway.test(ConcStr~VodCelk, var.equal=TRUE) # vysledky ANOVA F-testu
1466 StrMOD02 <- lm(ConcStr~VodCelk)
1467 summary(StrMOD02) # vysledky ANOVA F-testu
1468 anova(StrMOD02) # ANOVA tabuľka
1469 StrMOD03 <- lm(ConcStr~mean(ConcStr)~VodCelk-1)
1470 summary(StrMOD03)$coef # efekty faktora VodCelk
1471 sqrt((summary(StrMOD03)$sig^2/K) # 1.275748; odmocnina z (MSe/K)
1472 anova(StrMOD03) # ANOVA tabuľka
1473
1474 # Tukeyho HSD metoda pre vybrany kontrast B-A
1475 lambda.AB <- c(-1, 1, 0, 0, 0)

```

```

1476 citatel.AB <- sum(lambda.AB*PRIEM.ConcStr) # 8.15
1477 sigmasq.e.hat <- (summary(StrMOD03)$sig)^2 # 9.7652
1478 menovatel.AB <- sqrt(sigmasq.e.hat/2*sum(lambda.AB^2/K)) # 1.275748
1479 t.LSD.AB <- citatel.AB/menovatel.AB # 6.388408
1480 qtkey(0.95,J,K*J-J) # 4.153363
1481 p.hodn <- 1-ptkey(t.LSD.AB,J,K*J-J) # 0.001129311
1482 IS.AB <- citatel.AB+c(-1,1)*qtkey(0.95,J,K*J-J)*menovatel.AB
1483 # 2.851355 13.448645
1484 mp.Tukey <- TukeyHSD(aov(ConcStr~VodCelk),ordered=FALSE) # tab. 41
1485 # graficke znazornenie simultannuch IS
1486 IS.Tukey <- mp.Tukey$VodCelk[,2:3]
1487 mu.a.hat <- mp.Tukey$VodCelk[,1]
1488 range.x <- range(IS.Tukey)
1489 h <- J*(J-1)/2
1490 windows(5,5)
1491 par(mar=c(5,4.5,1,1))
1492 plot(mu.a.hat,1:h,type="n",xlab="Sr_(mg/ml)",ylab="",sub="Waldove_simultanne_95%_empiricke_IS_Tukeyho_typu",
1493      xlim=range.x,bty="n",axes=FALSE,cex.lab=1.2)
1494 abline(v=0,lty=2)
1495 for(j in 1:h) abline(h=j,col="gray")
1496 for(j in 1:h) arrows(mu.a.hat[h-j+1],j,IS.Tukey[h-j+1,1],j,length=0.05,angle=90,lwd=2)
1497 for(j in 1:h) arrows(mu.a.hat[h-j+1],j,IS.Tukey[h-j+1,2],j,length=0.05,angle=90,lwd=2)
1498 points(rev(mu.a.hat),1:h,pch=16)
1499 axis(1)
1500 axis(2,labels=rownames(mp.Tukey$VodCelk),at=h:1,las=2)
1501 box()
1502 # parove porovnavania
1503 mp.Bonf <- pairwise.t.test(ConcStr,VodCelk,p.adjust="bonferroni",pool.sd=TRUE)
1504 mp.Holm <- pairwise.t.test(ConcStr,VodCelk,p.adjust="holm",pool.sd=TRUE)
1505 mp.Hoch <- pairwise.t.test(ConcStr,VodCelk,p.adjust="hochberg",pool.sd=TRUE)
1506 mp.BH <- pairwise.t.test(ConcStr,VodCelk,p.adjust="BH",pool.sd=TRUE)
1507 mp.BY <- pairwise.t.test(ConcStr,VodCelk,p.adjust="BY",pool.sd=TRUE)
1508 mp.all <- cbind(mp.Tukey$VodCelk[,4],
1509                na.omit(c(mp.Bonf$p.value)),na.omit(c(mp.Holm$p.value)),
1510                na.omit(c(mp.Hoch$p.value)),na.omit(c(mp.BH$p.value)),
1511                na.omit(c(mp.BY$p.value)))
1512 rownames(mp.all) <- rownames(mp.Tukey$VodCelk)
1513 colnames(mp.all) <- c("Tukey_HSD","Bonferroni","Holm","Hochberg","Benjamini-Hochberg","Benjamini-Yekutieli")
1514 round(mp.all,10) # tab. 42
1515 # Scheffeho metoda
1516 lambda.1 <- c(0,1/3,1/3,1/3,-1)
1517 citatel.1 <- sum(lambda.1*PRIEM.ConcStr) # -16.49444
1518 sigmasq.e.hat <- (summary(StrMOD03)$sig)^2 # 9.7652
1519 menovatel.1 <- sqrt(sigmasq.e.hat*sum(lambda.1^2/K)) # 1.473107
1520 S1 <- abs(citatel.1)/menovatel.1 # 11.19704
1521 qf(0.95,J-1,K*J-J) # 2.75871
1522 krit.hodn <- sqrt((J-1)*qf(0.95,J-1,K*J-J)) # 3.321873
1523 F.stat <- citatel.1^2/((J-1)*menovatel.1^2) # 31.34345
1524 p.hodn <- 1-pf(S1,J-1,K*J-J) # 2.411503e-05

```




Obr. 8.7: Rozptylové grafy ANOVA modelov – \mathcal{F}_{H_0} (vľavo) a \mathcal{F}_{H_1} (vpravo)

Celkový aritmetický priemer je rovný $\bar{y} = 43.16$. Aritmetické priemery koncentrácií Sr v jednotlivých vodných celkoch sú nasledovné: $\bar{y}_1 = 32.08$, $\bar{y}_2 = 40.23$, $\bar{y}_3 = 44.08$, $\bar{y}_4 = 41.10$ a $\bar{y}_5 = 58.30$, pre $n_j = 6$, $j = 1, 2, \dots, 6$. Centrované aritmetické priemery sú rovné $-\bar{y}_1 - \bar{y} = -11.08$, $\bar{y}_2 - \bar{y} = -2.93$, $\bar{y}_3 - \bar{y} = 0.92$, $\bar{y}_4 - \bar{y} = -2.06$ a $\bar{y}_5 - \bar{y} = 15.14$. Pre aritmetické priemery platí $\bar{y}_1 < \bar{y}_2 < \bar{y}_4 < \bar{y}_3 < \bar{y}_5$. ANOVA tabuľka je nasledovná

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi	$SS_{A,obs} \doteq 2193.442$	$J - 1 = 4$	$MS_{A,obs} \doteq 548.361$
vnútri súborov	$SS_{e,obs} \doteq 244.130$	$n - J = 25$	$MS_{e,obs} \doteq 9.765$
celkovo	$SS_{T,obs} \doteq 2437.572$	$n - 1 = 29$	

Z ANOVA tabuľky vypočítame $F_W \doteq 56.2$, čo je väčšie ako $F_{J-1, n-J}(\alpha) = F_{4,25}(0.05) \doteq 2.76$ (p-hodnota $\ll 0.05$), t.j. H_0 zamietame na $\alpha = 0.05$. Ďalej sme zistili (Tukeyho HSD metódou), že $\mu_1 \neq \mu_2 = \mu_4 = \mu_3 \neq \mu_5$ (pozri tabuľku 8.3 a 8.4 a graf 8.8).



Obr. 8.8: Waldove simultanne 95% empirické IS Tukeyho typu pre rozdiely stredných hodnôt

Tabuľka 8.3: Výsledky Tukey HSD metódy – rozdiely aritmetických priemerov $\bar{y}_i. - \bar{y}_j.$, dolná a horná hranica Waldových simultánných 95% empirických IS Tukeyho typu pre $\mu_i - \mu_j$ (DH a HH), adjustované p-hodnoty \tilde{p}_k

	$\bar{y}_i. - \bar{y}_j.$	DH	HH	\tilde{p}_k
B-A	8.15	2.85	13.45	0.00112931
C-A	12.00	6.70	17.30	0.00000534
D-A	9.02	3.72	14.32	0.00033392
E-A	26.22	20.92	31.52	<0.00000001
C-B	3.85	-1.45	9.15	0.23762175
D-B	0.87	-4.43	6.17	0.98848032
E-B	18.07	12.77	23.37	<0.00000001
D-C	-2.98	-8.28	2.32	0.47910996
E-C	14.22	8.92	19.52	0.00000029
E-D	17.20	11.90	22.50	0.00000001

Po náhlade na dáta použijeme nasledovné tri vektory kontrastov \mathbf{a}_k , nim prislúchajúce odhady efektov $\mathbf{a}_k^T \hat{\boldsymbol{\mu}} = \sum_{j=1}^J a_{kj} \bar{y}_j.$, ich rozptyly $s^2 \mathbf{a}_k^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_k = s^2 \sum_{j=1}^J a_{kj}^2 / n_j$ a Scheffeho testovacie štatistiky $\sqrt{(J-1)F} = |\mathbf{a}_k^T \hat{\boldsymbol{\mu}}| / \sqrt{s^2 \mathbf{a}_k^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_k}$, kde $k = 1, 2$ a 3 :

- $\mathbf{a}_1 = (0, \frac{1}{3}, \frac{1}{3}, \frac{1}{3}, -1)^T$, $\mathbf{a}_1^T \hat{\boldsymbol{\mu}} \doteq -9.7$, $s^2 \mathbf{a}_1^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_1 = 1.47^2$, $\sqrt{4F} \doteq 11.20$,
- $\mathbf{a}_2 = (1, -\frac{1}{3}, -\frac{1}{3}, -\frac{1}{3}, 0)^T$, $\mathbf{a}_2^T \hat{\boldsymbol{\mu}} \doteq -16.5$, $s^2 \mathbf{a}_2^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_2 = 1.47^2$, $\sqrt{4F} \doteq 6.60$,
- $\mathbf{a}_3 = (\frac{1}{2}, -\frac{1}{3}, -\frac{1}{3}, -\frac{1}{3}, \frac{1}{2})^T$, $\mathbf{a}_3^T \hat{\boldsymbol{\mu}} \doteq 3.4$, $s^2 \mathbf{a}_3^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_3 = 1.16^2$, $\sqrt{4F} \doteq 2.93$.

Scheffeho kritická hodnota je rovná $\sqrt{(J-1)F_{J-1, n-J}(\alpha)} = \sqrt{4F_{4,25}(0.05)} \doteq 3.32$. Potom $H_{0k} : \mathbf{a}_k^T \boldsymbol{\mu} = 0$ oproti $H_{1k} : \mathbf{a}_k^T \boldsymbol{\mu} \neq 0$ zamietame, ak $k = 1, 2$, a nezamietame, ak $k = 3$.

Tabuľka 8.4: Adjustované p-hodnoty pre Tukeyho HSD (THSD) metódu, Bonferroniho (B) metódu, Holm-Bonferroniho metódu (HB step-down), Hochberg-Bonferroniho metódu (HB step-up), Benjamini-Hochbergovu (BH) metódu a Benjamini-Yekutieliho (BY) metódu

	THSD	B	HB step-down	HB step-up	BH	BY
B-A	0.00112931	0.00130222	0.00052089	0.00052089	0.00018603	0.00054488
C-A	0.00000534	0.00000572	0.00000343	0.00000343	0.00000114	0.00000335
D-A	0.00033392	0.00037498	0.00018749	0.00018749	0.00006250	0.00018305
E-A	<0.00000001	<0.00000001	<0.00000001	<0.00000001	<0.00000001	<0.00000001
C-B	0.23762175	0.42841263	0.12852379	0.12852379	0.05355158	0.15685087
D-B	0.98848032	1.00000000	0.63514400	0.63514400	0.63514400	1.00000000
E-B	<0.00000001	<0.00000001	<0.00000001	<0.00000001	<0.00000001	<0.00000001
D-C	0.47910996	1.00000000	0.22143936	0.22143936	0.12302187	0.36032714
E-C	0.00000029	0.00000031	0.00000022	0.00000022	0.00000008	0.00000023
E-D	0.00000001	0.00000001	0.00000001	0.00000001	<0.00000001	0.00000001

8.1.3 Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch

Nech $Y_{ji}(\mu_j, \sigma_j^2)$, kde existuje aspoň jedna dvojica $i \neq j$ taká, že $\sigma_i^2 \neq \sigma_j^2$ a zároveň σ_j^2 sú neznáme. Potom F_W štatistika nemá F rozdelenie s $J-1$ a $n-J$ stupňami voľnosti a musí byť modifikovaná nasledovne

$$F_W = \frac{\sum_{j=1}^J \hat{w}_j \left(\bar{Y}_j - \bar{Y}^{(w)} \right)^2}{J-1 + \frac{J-2}{J+1} \sum_{j=1}^J \frac{(1-\hat{h}_j)^2}{n_j-1}} \stackrel{\mathcal{D}}{\sim} F_{J-1, df_w},$$

$\hat{w}_j = n_j/s_j^2$, $\hat{h}_j = \frac{\hat{w}_j}{\sum_{i=1}^J \hat{w}_i}$, $j = 1, 2, \dots, J$ a $\hat{\mu} = \bar{Y}^{(w)} = \sum_{j=1}^J \hat{h}_j \bar{Y}_j$. Počet stupňov voľnosti

$$df_{w_1} = \frac{J^2 - 1}{3 \sum_{j=1}^J \frac{(1-\hat{h}_j)^2}{n_j-1}},$$

čo zaokrúhľime na najbližšie nižšie celé číslo, t.j. $df_w = \lfloor df_{w_1} \rfloor$. F_W sa nazýva **Fisherova testovacia štatistika** (alebo presnejšie **Welchova ANOVA F -štatistika**) a test **viacvýberový F -test s Welchovou aproximáciou stupňov voľnosti o rovnosti stredných hodnôt** $\mu_1, \mu_2, \dots, \mu_J$ (alebo **Welchov ANOVA F -test**). Realizáciou F_W je F_{obs} a p-hodnota = $\Pr(F_W \geq F_{\text{obs}} | H_0)$. Na porovnanie ANOVA modelu pri rôznych rozptyloch s ANOVA modelom pri rovnakých rozptyloch – s^2 definujeme ako vážený priemer výberových rozptylov s_j^2 , $j = 1, 2, \dots, J$, teda

$$s^2 = \frac{\sum_{j=1}^J (n_j - 1) s_j^2}{\sum_{j=1}^J (n_j - 1)} = \frac{\sum_{j=1}^J (n_j - 1) s_j^2}{n - J}.$$

Potom $\mathbf{Y}_j \sim N_{n_j}(\mathbf{X}_j \boldsymbol{\beta}, \boldsymbol{\Sigma}_j)$, kde $\boldsymbol{\Sigma}_j = \sigma_j^2 \mathbf{I}_{n_j \times n_j}$, vektor chýb $\boldsymbol{\varepsilon}_j \sim N_{n_j}(\mathbf{0}, \boldsymbol{\Sigma}_j)$, vektor parametrov $\hat{\boldsymbol{\beta}} \sim N_{J+1}(\boldsymbol{\beta}, (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1})$, kde $\boldsymbol{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_J^2)$ a maximálne vierohodný odhad $\hat{\boldsymbol{\beta}}$ vypočítame pomocou **zovšeobecnenej metódy najmenších štvorcov**, t.j. $\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y}$.

Waldov $100 \times (1 - \alpha)\%$ empirický IS pre nejakú lineárnu kombináciu $\sum_{j=1}^J a_j \mu_j$ (nazývaný aj **empirický IS Fisherovho typu**) ako

$$\left(\sum_{j=1}^J a_j \bar{y}_j - t_{df_w}(\alpha/2) \sqrt{\sum_{j=1}^J \frac{a_j^2 s_j^2}{n_j}}, \sum_{j=1}^J a_j \bar{y}_j + t_{df_w}(\alpha/2) \sqrt{\sum_{j=1}^J \frac{a_j^2 s_j^2}{n_j}} \right).$$

Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Scheffeho typu definujeme ako

$$\left(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \sqrt{(J-1)F_{J-1, df_w}(\alpha)} \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \hat{\boldsymbol{\mu}} + \sqrt{(J-1)F_{J-1, df_w}(\alpha)} \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right),$$

kde $\widehat{\Sigma} = \mathbf{S} = \text{diag}(s_1^2, s_2^2, \dots, s_J^2)$. Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Tukeyho typu definujeme ako

$$\left(\mathbf{a}^T \widehat{\boldsymbol{\mu}} - q_{J, df_w}(\alpha) \sqrt{\frac{1}{2} \mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \widehat{\boldsymbol{\mu}} + q_{J, df_w}(\alpha) \sqrt{\frac{1}{2} \mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right).$$

Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Fisherovho typu definované nasledovne

$$\left(\mathbf{a}^T \widehat{\boldsymbol{\mu}} - t_{df_w}(\alpha_k) \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \widehat{\boldsymbol{\mu}} + t_{df_w}(\alpha_k) \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right).$$

ANOVA model v \mathbb{R}

Funkciu `oneway.test()` je možné použiť aj v prípade, že rozptyly nie sú rovnaké, ak nastavíme argument `var.equal=FALSE`.

Mnohonásobné porovnávanie v \mathbb{R}

Na jedнокrokové a viackrokové metódy (výpočet adjustovaných p-hodnôt) použijeme podobne ako predtým funkciu `pairwise.t.test(y,x,p.adjust="metoda")`, avšak argument `pool.sd=FALSE`.

Príklad 258 (Tukeyho HSD metóda) Naprogramujte v \mathbb{R} Tukeyho HSD metódu za predpokladu nerovnosti rozptylov.

Príklad 259 (viacvýberový jednorozmerný prípad) Majme dáta `anova-newborns.txt` a premennú pôrodná hmotnosť hodnoteného dieťaťa `weight.C` (v gramoch). V dáta sa nachádzajú odľahlé pozorovania, preto je potrebné ich pred výpočtami winsorizovať v každej skupine zvlášť (pozri kapitolu 3.1 a 3.2). Otestujte

- sexuálny dimorfizmus (t.j. rozdiely stredných hodnôt – chlapci mínus dievčatá),
- sexuálny dimorfizmus u (1) prvorođených detí, (2) druhorođených detí a (3) detí narodených v treťom a ďalšom poradí, ako aj rozdiely medzi (1) a (2), (2) a (3) u každého pohlavia zvlášť (premená `prch.N`),
- sexuálny dimorfizmus u detí, ktorých matky mali (1) základné vzdelanie, (2) vzdelanie stredné bez maturity, (3) vzdelanie stredné s maturitou a (4) vysokoškolské, ako aj rozdiely medzi (1) a (2), (2) a (3), (3) a (4) u každého pohlavia zvlášť (premená `edu.M`).

Na testovanie použite


- dvojvýberové Studentove t -testy, kde $T_W \stackrel{\mathcal{D}}{\sim} t_{df}$, (1.1) $df = n_1 + n_2 - 2$ a (1.2) df sú Welchove stupne voľnosti z dvojvýberového Studentovho t -testu s Welchovou aproximáciou stupňov voľnosti,
- viacvýberové Fisherove LSD testy, kde $T_{LSD} \sim t_{df}$, (2.1) $df = n - J$ a (2.2) $df = df_w$ sú Welchove stupne voľnosti z Welchovho ANOVA F -testu ((a) $J = 2$ a počet porovnávaní $h = 1$; (b) $J = 6$ a počet porovnávaní $h = 7$; (c) $J = 8$ a počet porovnávaní $h = 10$),
- viacvýberové Tukeyho HSD testy pri homogenite a nehomogenite rozptylov ((a) $J = 2$, (b) $J = 6$ a (c) $J = 8$).

Ďalej vypočítajte

- Waldove $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti pre rozdiel stredných hodnôt s použitím kritických hodnôt $t_{df}(\alpha/2)$, kde df je z (1.1) a (1.2).
- Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Tukeyho typu pre rozdiel stredných hodnôt, kde df je z (2.1) a (2.2).

Novorodenci mužského pohlavia majú systematicky o niečo vyššiu pôrodnú hmotnosť než novorodené dievčatá (259a, pozri graf 8.9; e.g. Kumar a kol., 2013). Súčasne existujú nezanedbateľné rozdiely v rade znakov medzi súrodencami narodenými v rôznom poradí. Napríklad prvorođení chlapci aj dievčatá majú v pupočnej krvi výrazne vyššie hladiny pohlavných hormónov než novorodenci narodení vo vyššom poradí (Maccoby a kol., 1979). Čo sa týka pôrodnej hmotnosti, prvorođení mávajú o niečo nižšiu pôrodnú hmotnosť než druhorođení. Rozdiely medzi pohlaviami sa vysvetľujú špecifickými faktormi z pohlavných chromozómov a odlišnými hladinami pohlavných hormónov, ktoré ovplyvňujú prenatálnu diferenciaciu a rast celého tela. Rozdiely medzi novorodencami narodenými v rôznom poradí sa hľadajú v mechanizmoch (imunitná interakcia matky s predchádzajúcimi potomkami, stres

matky so zvyšujúcou sa paritou), ktoré cez matku ovplyvňujú embryo a plod v jej maternici (e.g. Bogaert a Skorska, 2011). V našom prípade máme k dispozícii pôrodnú hmotnosť (premenná *weight.C*) novorodených dievčat a chlapcov a chceme zistiť, ako tieto dva faktory (pohlavie a poradie narodenia) ovplyvňujú pôrodnú hmotnosť. Chceme vedieť, či sa líšia novorodenci narodení v inom poradí, u každého pohlavia zvlášť, v pôrodnej hmotnosti (premenná *prch.N*, f-1 prvorodené dievčatá, f-2 druhorodené dievčatá, f-3 dievčatá narodené v treťom a vyššom poradí; obdobne chlapci); a ďalej či existuje sexuálny dimorfizmus v pôrodnej hmotnosti v rámci každého poradia narodenia zvlášť (príklad 259b; obrázok 8.12).




Obr. 8.9: Krabicové diagramy pôrodnej hmotnosti pre dievčatá a chlapcov

Celkovo vidíme väčšie rozptyly u chlapcov (pozri obrázok 8.10, tabuľku rozptylov neuvádzame), čo môže odpovedať faktu, že samčie pohlavie je všeobecne variabilnejšie. Preto je v tomto prípade potrebné vopred počítať s nehomogenitou rozptylov. Na základe krabicových diagramov (graf 8.10) a aritmetických priemerov je možné konštatovať, že dimorfizmus by mohol byť štatisticky významný až vo vyššom poradí. Organizmus matky je pravdepodobne plne prispôbený reprodukčnej funkcii až pri druhom a treťom poradí. Podľa niektorých štúdií však poradie narodenia nie je jediným faktorom v hre, rolu hrá tiež vek matky (súvisí so vzdelaním – matky s vyšším vzdelaním sa v našej populácii v priemere začínajú reprodukovať neskôr; vzdelanie matiek je výrazným faktorom reprodukcie, pokiaľ sú matky stále vo vzdelávacom systéme, po jeho opustení už menej; Šťastná, 2010) a medzipôrodný interval; tehotenstvo vo príliš krátkom medzipôrodnom intervale je stresujúce, po extrémne dlhom medzipôrodnom intervale sa môže fyziologicky blížii situácii prvého tehotenstva (prehľad Rousso a kol., 2002). Pokiaľ budú väčšie rozptyly u jedného pohlavia než u druhého, toto pohlavie môže byť citlivejšie na niektorý z uvedených prenatalných faktorov. Ešte výraznejším faktorom však môže byť skrytá heterogenita v dátach, spôsobená sociálnymi a etnickými rozdielmi. Pokiaľ sú v dátach skryté rôzne sociálne/etnické skupiny líšiace sa priemernou pôrodnou hmotnosťou a súčasne majúce odlišnú normu v počte detí v rodine (ktorý môže negatívne súvisieť i so vzdelaním matky), bude v rôznom poradí narodenia rôzne zastúpenie každej z týchto skupín, čo ovplyvní porovnávané stredné hodnoty a pravdepodobne aj rozptyly. Rozsiahle demografické štúdie pôrodnej hmotnosti založené na vzorcoch z moderných mestských populácií s veľkou pravdepodobnosťou (nekontrolovaného) mnohoetnického zloženia sú týmto faktorom pravdepodobne vždy ovplyvnené.


Ďalej chceme zistiť, či existujú rozdiely v pôrodnej hmotnosti (premenná *weight.C*) medzi deťmi narodenými matkám s rôznym stupňom vzdelania (premenná *edu.M*, pre novorodené dievčatá: f-1 základné, f-2 stredné bez maturity, f-3 stredné s maturitou a f-4 vysokoškolské; obdobne m-1, m-2, m-3 a m-4 pre chlapcov; príklad 259c; obrázok 8.12).

Biologické rozdiely medzi novorodencami jednotlivých skupín môžu byť dané napr. neskorším začiatkom reprodukcie u žien s vyšším vzdelaním (pozri graf 8.11). Vzhľadom na to, že dosiahnuté vzdelanie môže súvisieť aj s celkovým počtom detí (a dáta obsahujú ženy rôzneho veku, parity, atď.), je možné, že dve vyššie kategórie zahŕňajú vyššiu proporciu prvorodených, zatiaľ čo dve nižšie kategórie vyššiu proporciu detí narodených vo vyššom poradí (a tak hmotnejšiu než pri zložení odpovedajúcemu vyšším dvom kategóriám). Bolo by preto vhodné sledovať vplyv všetkých troch faktorov súčasne (pohlavie,



Obr. 8.10: Krabicové diagramy pôrodnej hmotnosti pre dievčatá a chlapcov podľa počtu predchádzajúcich detí biologickej matky

poradie narodenia, vzdelanie matky). Pokiaľ existuje nejaká súvislosť medzi dosiahnutým vzdelaním matky a počtom detí, a súčasne sa skryté sociálne/etnické skupiny líšia v počte detí i pôrodnej hmotnosti, je pravdepodobné, že výsledky budú ovplyvnené tiež sociálnym/etnickým zložením vzorky, ktoré ale v našich dátach nemáme pod kontrolou. Výsledky potom môžu byť rôzne ovplyvnené počtom detí, vzdelaním a priemernou hmotnosťou novorodencov v jednotlivých sociálnych/etnických skupinách.




Obr. 8.11: Krabicové diagramy pôrodnej hmotnosti pre dievčatá a chlapcov podľa vzdelania biologickej matky

Post-hoc testy ukazujú (pozri obrázok 8.12), že nemôžeme zamietnuť nulovú hypotézu v žiadnej porovnávaní dvojici populácií ani pri predpoklade homogenity rozptylov a ani pri nehomogenite rozptylov. Prejavuje sa len predpokladaná tendencia k sexuálnemu dimorfizmu s vyššími hodnotami u chlapcov a u oboch pohlaví tendencia k vyššej hmotnosti u druhorodených oproti prvorodeným, a tiež naopak tendencia k nižšej hmotnosti u detí vo vyššom poradí oproti druhorodeným.

Jediný štatisticky významný rozdiel (pozri obrázok 8.13) bol zistený medzi synmi matiek so základným a stredným vzdelaním bez maturity (m-2 vs m-1), kedy vyššia priemerná hmotnosť bola zaznamenaná u matiek s vyšším vzdelaním. Celkovo je však z porovnania susedných skupín podľa vzdelania matiek v rámci pohlavia zrejme, že pôrodná hmotnosť buď nesúvisí so vzdelaním matiek vôbec, alebo vidíme aspoň tendenciu k vyššej pôrodnej hmotnosti u novorodencov matiek so vzdelaním o stupeň vyšším (4 zo 6 rozdielov sú pozitívne). Čo sa týka sexuálneho dimorfizmu v žiadnej kategórii podľa vzdelania matiek nebola pôrodná hmotnosť štatisticky významne rozdielna medzi pohlaviami, aj keď

je viditeľný trend k vyššej hodnote u chlapcov. Výnimkou sú deti matiek s najnižším vzdelaním, kde nie je ani žiadna tendencia k rozdielu. Detailné vysvetlenie výsledkov by bolo možné pri doplnení informácií v zmysle vyššie uvedených súvislostí s etnickým/sociálnym zložením vzorky.



Obr. 8.12: Waldove simultánne 95% empirické intervaly spoľahlivosti Tukeyho typu pre rozdiely stredných hodnôt pôrodnej hmotnosti (pohlavie dieťaťa vs počet predchádzajúcich detí biologickej matky) – za predpokladu homogenity rozptylov (vľavo) a nehomogenity rozptylov (vpravo); rozdiely v dĺžke toho istého intervalu spoľahlivosti pri rôznych predpokladoch sa líšia od 0.63 po 14.52 v závislosti od odchýlky hodnôt rozptylov použitých na ich výpočet a od rozdielov stupňov voľnosti df_w (newinsorizované dáta)

Príklad 260 (dvojvýberový mnohorozmerný prípad) *Majme dáta anova-head.txt a premenné (1) dĺžka hlavy head.L, (2) šírka hlavy head.W, (3) šírka dolnej čeľuste bigo.W a (4) šírka tváre bizyg.W (všetky v milimetroch). V dátach sa nachádzajú odľahlé pozorovania, preto je potrebné ich pred výpočtami winsorizovať v každej skupine zvlášť (pozri kapitolu 3.1 a 3.2). Otestujte sexuálny dimorfizmus (t.j. rozdiely stredných hodnôt premenných (1) až (4) – muži mínus ženy; premenná sex) nasledovne:*

(a) použite štyri dvojvýberové Studentove t -testy (nezávisle pre každú premennú), kde $T_W \stackrel{D}{\sim} t_{df}$, (1) $df = n_1 + n_2 - 2$ a (2) df sú Welchove stupne voľnosti z dvojvýberového Studentovho t -testu s Welchovou aproximáciou stupňov voľnosti,

(b) použite štyri viacvýberové Fisherove LSD testy, kde $T_{LSD} \sim t_{df}$, (1) $df = n - J$ a (2) $df = df_w$ sú Welchove stupne voľnosti z Welchovho ANOVA F -testu ($J = 2$ a počet porovnávaní $h = 4 \times \frac{J(J-1)}{2} = 4$).

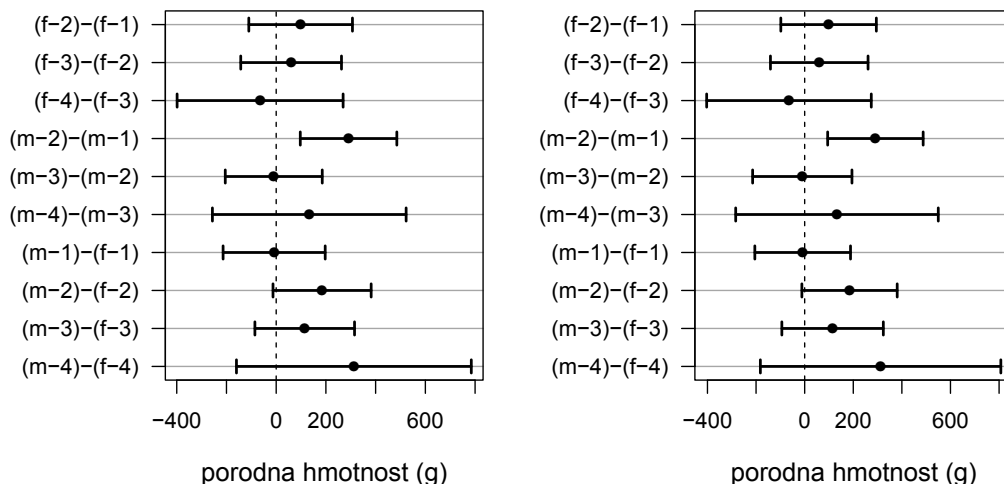
Vypočítajte

(c) Waldove $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti pre rozdiel stredných hodnôt s použitím kritických hodnôt $t_{df}(\alpha/2)$, kde df je z (1) a (2) z (a).

(d) Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Fisherovho typu pre rozdiel stredných hodnôt s použitím Benjamini-Yekutieliho kritických hodnôt $t_{df}(\alpha_k)$, kde $\alpha_k = 1, 2, \dots, h$, df je z (1) a (2) z (b).

(f) Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Tukeyho typu pre rozdiel stredných hodnôt, kde $J = 4$.

U človeka existuje výrazný dimorfizmus vo výške postavy (veľkosti tela), ktorý sa ale z veľkej časti utvára v puberte a adolescencii pod vplyvom odlišných hladín gonadálnych steroidných hormónov. Nový systém a s ním i skelet neurokránia naopak rastie najvýraznejšie v období pred pubertou. Spolu s výrazne sa zvyšujúcimi priemernými hodnotami u mužov však môže v puberte a adolescencii narastať medzi mužmi viac než medzi ženami tiež variabilita, napríklad v prípade kľúčnej kosti môže byť rozsah hodnôt niektorých veľkostných ukazovateľov takmer dvojnásobný oproti ženám (e.g. Singh



Obr. 8.13: Waldove simultánne 95% empirické intervaly spoľahlivosti Tukeyho typu pre rozdiely stredných hodnôt pôrodnej hmotnosti (pohlavie dieťaťa vs vzdelanie biologickej matky) – za predpokladu homogenity rozptylov (vľavo) a nehomogenity rozptylov (vpravo); rozdiely v dĺžke toho istého intervalu spoľahlivosti pri rôznych predpokladoch sa líšia od 2.51 po 54.40 v závislosti od odchýlky hodnôt rozptylov použitých na ich výpočet a od rozdielov stupňov voľnosti df_w (newinsorizované dáta)

a Jit, 1996). V rozmeroch lebky by tak vo výsledku mohli byť medzipohlavné rozdiely percentuálne väčšie v znakoch rastúcich prevažne v období puberty (t.j. skôr rozmery tvárovej časti, v dolnej polovici tváre), ale vzhľadom na rastúci rozptyl by to nemuselo mať vplyv na veľkosť efektu medzipohlavných rozdielov (štandardizovaný rozdiel stredných hodnôt, vztiahnutý na združenú smerodajnú odchýlku a teda aj štatistickú významnosť testu rozdielu stredných hodnôt).

Krabicové diagramy (pozri obrázok 8.14) naznačujú, že vo všetkých štyroch rozmeroch sa pravdepodobne bude nachádzať podľa predpokladu sexuálny dimorfizmus. Grafy tiež súčasne poukazujú na to, že v šírke dolnej čeľuste majú muži (vizuálne posudzované) skutočne väčší rozptyl než ženy, čo opäť odpovedá predpokladu väčšej variability pubertálneho/adolescentného rastu medzi mužmi než medzi ženami.

Príklad 261 (viacvýberový mnohorozmerný prípad) Majme dáta *anova-head.txt* a premenné (1) dĺžka hlavy *head.L*, (2) šírka hlavy *head.W*, (3) šírka dolnej čeľuste *big.W* a (4) šírka tváre *bi-zyg.W* (všetky v milimetroch). V dátach sa nachádzajú odľahlé pozorovania, preto je potrebné ich pred výpočtami winsorizovať v každej skupine zvlášť (pozri kapitolu 3.1 a 3.2). Otestujte rozdiely v stredných hodnotách medzi (premenné *sex* a *sexor*)

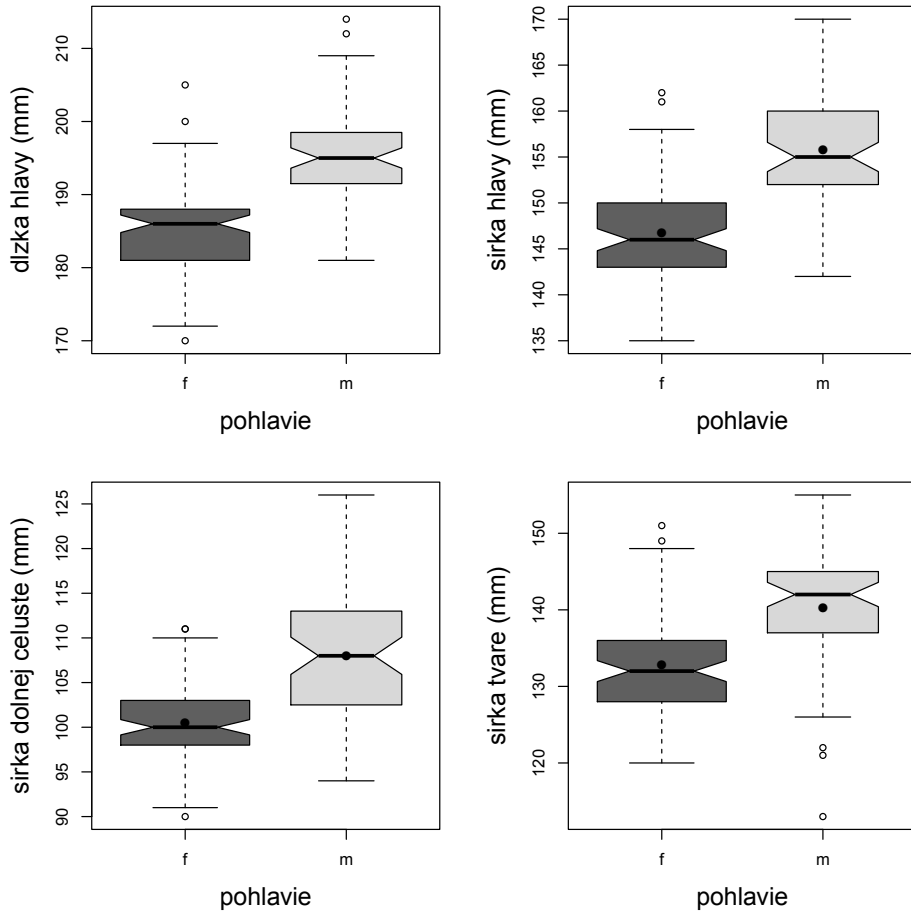
- *f-op* – ženami so sexuálnou orientáciou výlučne na opačné pohlavie,
- *f-sa* – ženami s bisexuálnou alebo homosexuálnou orientáciou,
- *m-op* – mužmi so sexuálnou orientáciou výlučne na opačné pohlavie a
- *m-sa* – mužmi s bisexuálnou alebo homosexuálnou orientáciou.

Testovanie vykonajte nasledovne:

(a) použijete 24 dvojvýberových Studentových *t*-testov (nezávisle pre každú premennú), kde $T_W \stackrel{D}{\sim} t_{df}$, (1) $df = n_1 + n_2 - 2$ a (2) df sú Welchove stupne voľnosti z dvojvýberového Studentovho *t*-testu s Welchovou aproximáciou stupňov voľnosti,

(b) použijete 24 viacvýberových Fisherových LSD testov, kde $T_{LSD} \sim t_{df}$, (1) $df = n - 4$ a (2) $df = df_w$ sú Welchove stupne voľnosti z Welchovho ANOVA *F*-testu ($J = 4$, počet porovnávaní $h = 4 \times \frac{J(J-1)}{2} = 4 \times 6 = 24$),

(c) použijete (1) ANOVA *F*-test a (2) Welchov ANOVA *F*-test pre všetky štyri premenné.



Obr. 8.14: Krabicové diagramy pre ženy a mužov – dĺžka hlavy (vľavo hore), šírka dolnej čeľuste (vľavo dole), šírka hlavy (vpravo hore) a šírka tváre (vpravo dole)

Vypočítajte

(d) Waldove $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti pre rozdiel stredných hodnôt s použitím kritických hodnôt $t_{df}(\alpha/2)$, kde df je z (1) a (2) z (a).

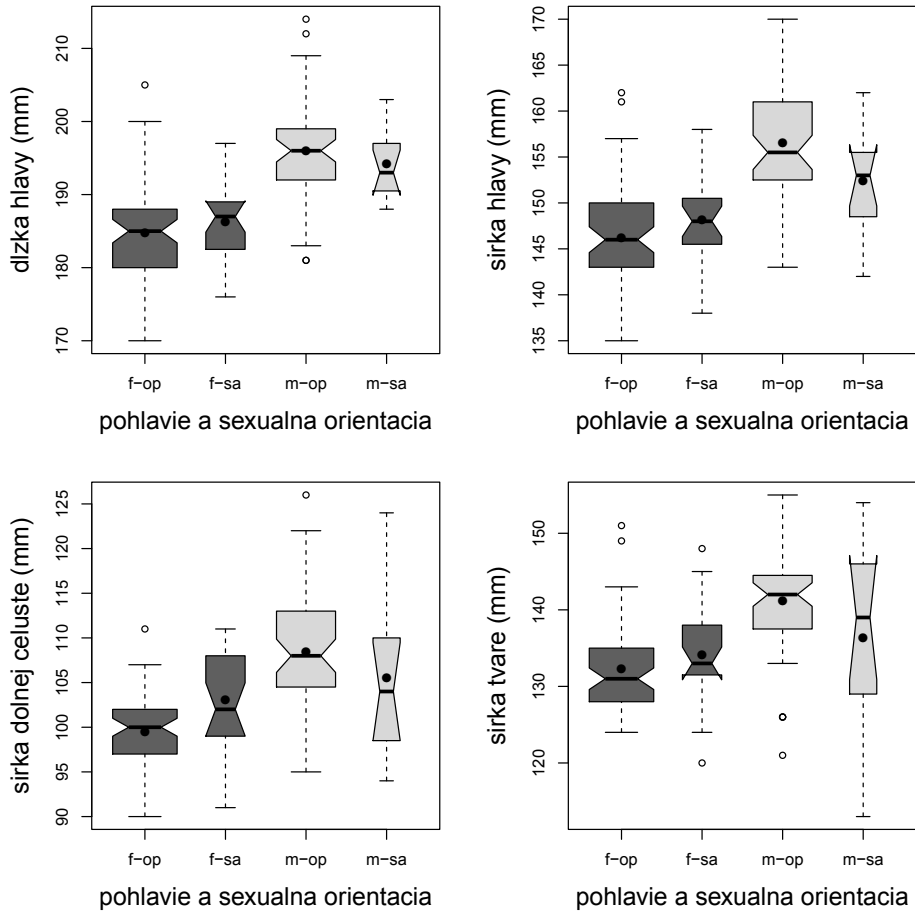
(e) Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Fisherovho typu pre rozdiel stredných hodnôt s použitím Benjamini-Yekutieliho kritických hodnôt $t_{df}(\alpha_k)$, kde $\alpha_k = 1, 2, \dots, h$, df je z (1) a (2) z (b).

(f) Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Tukeyho typu pre rozdiel stredných hodnôt, kde $J = 4$.

Okrem sexuálneho dimorfizmu, t.j. rozdielov definovaných biologickým pohlavím (založených na odlišnej kombinácii pohlavných chromozómov a odlišných hladinách pohlavných hormónov prenatálne aj v puberte) ale existujú rozdiely spojené so *sexuálnou orientáciou* (pozri obrázok 8.15). Napriek tomu, že presný mechanizmus vzniku rozdielov v sexuálnej orientácii nie je doteraz známy, v súčasnej dobe sa teórie i nepriame empirické dôkazy klonia na stranu biologických hypotéz a k sexuálnej orientácii nezmeniteľne determinovanej už v prenatálnom období. Z odlišných frekvencií a ďalších súvislostí sexuálnej

orientácie u mužov a u žien je zrejme, že mechanizmy nastavenia finálnej sexuálnej orientácie môžu byť u mužov a žien odlišné. U žien (veľmi zjednodušene povedané) zaznamenané dôkazy (napr. vrodená adrenálna hyperplázia) nasvedčujú tomu, že na vznik ženskej homosexuality vplýva nerovnováha (zvýšené hladiny) prenatálnych androgénov. U mužov sú v tomto ohľade dôkazy ešte nejednoznačnejšie. Boli však nájdené dôkazy naznačujúce, že sexuálna orientácia mužov súvisí s dedičnými faktormi na X-chromozóme od matky. Je možné, že variant niektorého (zatiaľ hypotetického) génu na X-chromozóme je reprodukčne veľmi výhodný, pokiaľ sa nachádza v ženskom tele (t.j. zvyšuje reprodukčnú úspešnosť žien – nositeľiek, čím prispieva k udržaniu svojej frekvencie v populácii), ale feminizuje telo a mozog mužských nositeľov, ak ho od matky zdedil syn (získa práve ten jej X-chromozóm, ktorý je nositeľom tejto výhodnej formy). Nepriame dôkazy (LeVay, 1991) nasvedčujú, že niektoré hypotalamické jadrá mužských homosexuálov majú feminizované kvantitatívne vlastnosti, iné štúdie tieto výsledky spochybňujú (Swaab a kol., 1992) a poukazujú na metodicky diskutabilné vzorkovanie a vzťah medzi zistenými asociáciami (súvislosťami, vzťahmi, koreláciami) a predpokladanými kauzálnymi závislosťami. Čo sa týka telesnej stavby, ako u ženských, tak aj u mužských homosexuálov nájdeme feminínne a maskulínne telesné formy (ženy: *butch* a *femme lesbians*). Obmedzené množstvo dostupných štúdií ukazuje u oboch pohlaví zmes maskulínnejších i feminínnejších foriem znakov oproti heterosexuálnym porovnávacím populáciám. Prevalha výsledkov však naznačuje, že feminínnejšie znaky u mužských homosexuálov a maskulínnejšie znaky u ženských homosexuálov celkovo prevládajú, t.j. homosexuálni jedinci sa zdajú byť v určitej miere posunutí smerom k norme opačného pohlavia (napr. Nedoma a Freund, 1961; Bogaert a Blanchard, 1996; Weill, 2009). V našom prípade chceme zistiť, či okrem pohlavia sledované 4 rozmery hlavy súvisia tiež s pohlavnou orientáciou. Ak platí vyššie uvedený predpoklad, dimorfizmus u heterosexuálnych jedincov by mal byť väčší než u jedincov homosexuálnych. Vzhľadom na to, že pohlavná orientácia by sa mala zakladať už prenatálne, zistené rozdiely by mohli mať raný ontogenetický pôvod (pokiaľ nie je po narodení rast týchto telesných partíí ovplyvnený externými faktormi inak u /neskôr v dospelosti/ homosexuálnych a heterosexuálnych jedincov).

Výsledky (obrázok 8.16) sú do značnej miery v zhode s vyššie uvedenými predpokladmi. Vo všetkých štyroch rozmeroch je štatisticky významný dimorfizmus a číselne najvyšší medzipohlavný rozdiel nájdený medzi heterosexuálnymi mužmi a ženami. Všetky ostatné medzipohlavné rozdiely (heterosexuálni muži vs. homosexuálne ženy, heterosexuálne ženy vs. homosexuálni muži, homosexuálni muži vs. homosexuálne ženy) sú celkovo číselne menšie a v 4 z 12 týchto porovnaní nie sú štatisticky významné (čo sa ale dá očakávať, vzhľadom na početne menšiu vzorku homosexuálov). Rozdiely medzi homosexuálmi a heterosexuálmi v rámci každého pohlavia sú celkovo malé a štatisticky nevýznamné (až na hranične významný rozdiel v šírke dolnej čeľuste medzi homosexuálnymi a heterosexuálnymi ženami, kedy čeľusť homosexuálnych žien je širšia), aj tu platí vyššie uvedený komentár k veľkosti vzorky. Evidentne je však vo všetkých rozmeroch viditeľný trend k posunu rozdielu v zmysle posunu hodnôt homosexuálnej vzorky k hodnotám obvyklejším u opačného pohlavia (maskulinizácia homosexuálnych žien a feminizácia homosexuálnych mužov). Výsledky sa podobajú výsledkom zistených v iných antropometrických premenných (porovnanie Weill, 2009). Tento trend sa zdá najvýraznejší v šírke čeľusti u žien a šírke tváre u mužov. Výsledky teda naznačujú, že faktor sexuálnej orientácie súvisí viac s rastom tváre než mozgovne. Vzhľadom na výraznejší rast tejto časti hlavy v puberte a adolescencii možno usudzovať na nejakú prenatálnu súvislosť medzi sexuálnou orientáciou a pubertálnym/adolescentným rastom. U oboch rozmerov tváre súčasne vidíme (obrázok 8.15, i keď opäť s rezervou vzhľadom na veľkosť vzorky), že rozptyl vo vzorke homosexuálov sa zdá byť väčší, t.j. akoby zahŕňal ako formy obvyklé pre dané pohlavie, tak aj formy posunuté smerom k opačnému pohlaviu (v dôsledku čoho je však posunutá v priemere celá skupina). Obmedzením testovanej vzorky sú iste výrazne odlišné počty homosexuálnych a heterosexuálnych jedincov, predovšetkým malý počet prípadov vzorky homosexuálov. Na druhej strane však celé dáta predstavujú prirodzenú skupinu mladých dospelých ľudí, väčšinou vysokoškolských študentov, vrátane prirodzeného zastúpenia ne-heterosexuálnych jedincov, bez akýchkoľvek apriorných vplyvov sexuálnej orientácie na vznik vzorky (vrátane anonymného dotazníka sexuálnej orientácie). Pokiaľ by mal mať výber štatisticky príhodné vlastnosti (predovšetkým veľkosť), bolo by nutné zámerné hľadať jedincov oboch skupín a sexuálnu orientáciu dopredu zisťovať. Ďalej by sa museli zaistiť rovnaké kritéria výberu u oboch skupín z hľadiska sledovaných rozmerov (čo vzhľadom na celý rad (sub)kultúrnych a iných rozdielov nemusí byť práve triviálna úloha). Nemenej podstatnou oblasťou metodiky je samotná klasifikácia sexuálnej orientácie. Zlúčenie jedincov všetkých 6 kategórií Kinseyho škály (Kinsey a kol., 1948) s nejednoznačne heterosexuálnou orientáciou (všetci mimo výlučne heterosexuálnych jedincov) do jednej kategórie ne-heterosexuáli (pozri popis dát anova-head.txt) môže zakrývať ďalšiu variabilitu v rámci našej početne malej „homosexuálnej“ skupiny.



Obr. 8.15: Krabicové diagramy pre ženy a mužov podľa sexuálnej orientácie – dĺžka hlavy (vľavo hore), šírka dolnej čeluste (vľavo dole), šírka hlavy (vpravo hore) a šírka tváre (vpravo dole)

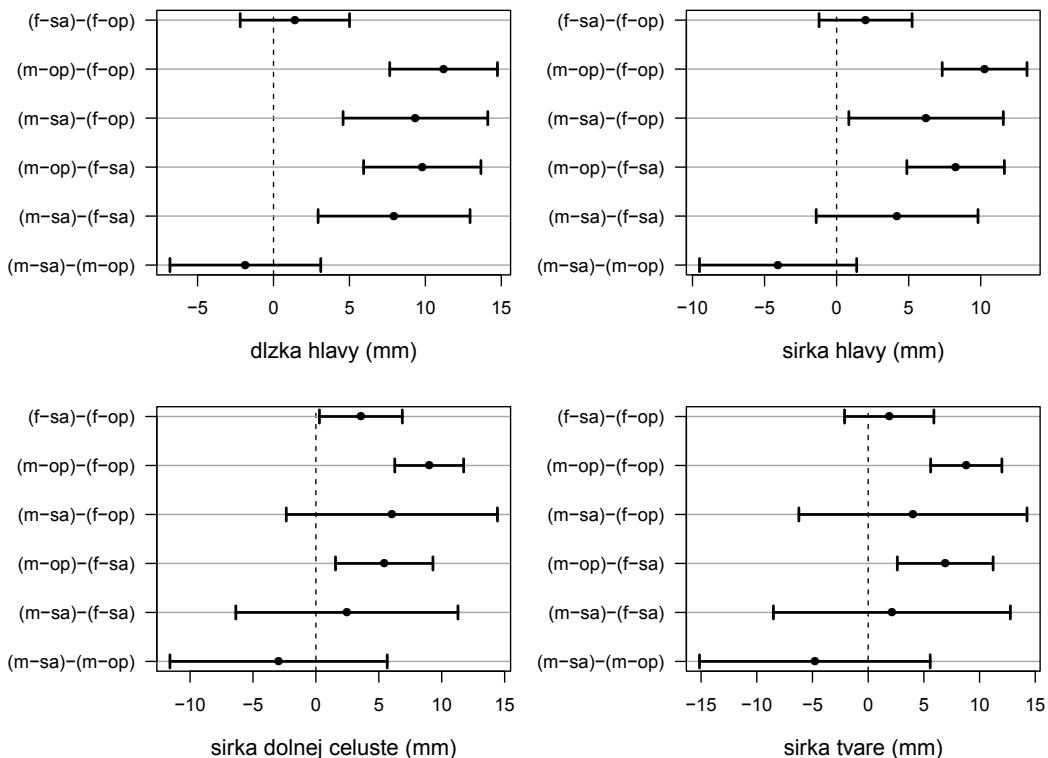
8.2 Asymptotické testy o rozptyloch

V tejto kapitole sa budeme zaoberať testami o homogenite (rovnosti) viacerých rozptylov. Najprv odvodíme testovaciu štatistiku pomerom vierohodnosti a následne Bartlettovu modifikáciu tejto štatistiky (Bartlett, 1937). Hypotézy definujeme nasledovne $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma^2$ oproti $H_1 : \sigma_i^2 \neq \sigma_j^2 \neq \sigma^2$ pre aspoň jedno $i < j, i = 1, 2, \dots, J - 1; j = 2, 3, \dots, J$.

Test pomerom vierohodnosti o homogenite rozptylov.

Nech $Y_j \sim N(\mu_j, \sigma_j^2)$, kde $j = 1, 2, \dots, J$, $\theta = (\mu_1, \mu_2, \dots, \mu_J, \sigma_1^2, \sigma_2^2, \dots, \sigma_J^2)^T$. Logaritmus funkcie vierohodnosti má tvar

$$l(\theta | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) = - \sum_{j=1}^J \frac{n_j}{2} \ln(2\pi\sigma_j^2) - \sum_{j=1}^J \frac{1}{2\sigma_j^2} \left(\sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2 \right).$$



Obr. 8.16: Waldove simultánne 95% empirické intervaly spoľahlivosti Tukeyho typu pre rozdiely stredných hodnôt – dĺžka hlavy (vľavo hore), šírka dolnej čeluste (vľavo dole), šírka hlavy (vpravo hore) a šírka tvare (vpravo dole); newinsorizované dáta

MLE θ je rovný $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \dots, \mu_J, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \dots, \hat{\sigma}_J^2)^T$, kde

$$\hat{\mu}_j = \bar{y}_j, \hat{\sigma}_j^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2,$$

t.j. $\Theta_1 = \{\theta : \sigma_i^2 \neq \sigma_j^2 \neq \sigma^2; i < j, i = 1, 2, \dots, J - 1; j = 2, 3, \dots, J\}$ pre aspoň jedno i a j . Za platnosti H_0 je $\theta_0 = (\hat{\mu}_1, \hat{\mu}_2, \dots, \hat{\mu}_J, \tilde{\sigma}^2, \tilde{\sigma}^2, \dots, \tilde{\sigma}^2)^T$, kde (pozri Mood a kol., 1987)

$$\tilde{\sigma}^2 = \frac{\sum_{j=1}^J n_j \hat{\sigma}_j^2}{\sum_{j=1}^J n_j},$$

t.j. $\Theta_0 = \{\theta : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma^2\}$. Logaritmus funkcie vierohodnosti pre $\hat{\theta}$ bude mať tvar

$$\begin{aligned} l(\hat{\theta} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) &= - \sum_{j=1}^J \frac{n_j}{2} \ln(2\pi\hat{\sigma}_j^2) - \sum_{j=1}^J \frac{1}{2\hat{\sigma}_j^2} \left(\sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2 \right) \\ &= - \sum_{j=1}^J \frac{n_j}{2} \ln(2\pi\hat{\sigma}_j^2) - \sum_{j=1}^J \frac{n_j \hat{\sigma}_j^2}{2\hat{\sigma}_j^2}. \end{aligned}$$

Logaritmus funkcie vierohodnosti pre θ_0 bude mať tvar

$$\begin{aligned} l(\theta_0 | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) &= -\sum_{j=1}^J \frac{n_j}{2} \ln(2\pi\tilde{\sigma}^2) - \sum_{j=1}^J \frac{1}{2\tilde{\sigma}^2} \left(\sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2 \right) \\ &= -\sum_{j=1}^J \frac{n_j}{2} \ln(2\pi\tilde{\sigma}^2) - \frac{1}{\tilde{\sigma}^2} \sum_{j=1}^J \frac{n_j \hat{\sigma}_j^2}{2} \end{aligned}$$

Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J)) &= l(\hat{\theta} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) - l(\theta_0 | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) \\ &= -\sum_{j=1}^J \frac{n_j}{2} \ln \hat{\sigma}_j^2 - \sum_{j=1}^J \frac{n_j}{2} + \sum_{j=1}^J \frac{n_j}{2} \ln \left(\frac{\sum_{j=1}^J n_j \hat{\sigma}_j^2}{\sum_{j=1}^J n_j} \right) + \sum_{j=1}^J \frac{n_j}{2} \\ &= \frac{1}{2} \sum_{j=1}^J n_j \ln \left(\frac{\sum_{j=1}^J n_j \hat{\sigma}_j^2}{\hat{\sigma}_j^2 \sum_{j=1}^J n_j} \right) = \frac{1}{2} \sum_{j=1}^J n_j \ln \left(\frac{\tilde{\sigma}^2}{\hat{\sigma}_j^2} \right). \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_J)) \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$.

Nech $J = 2$ a $n_1 = n_2$. Nech $F_{\text{obs}} = \frac{\sum_{i=1}^{n_1} (y_{1i} - \bar{y}_1)^2}{\sum_{i=1}^{n_2} (y_{2i} - \bar{y}_2)^2}$, čo je špeciálny prípad F_{obs} z kapitoly 7.2. Potom

$$\frac{\tilde{\sigma}_1^2}{\hat{\sigma}_1^2} = \frac{1}{2} \left(1 + \frac{1}{F_{\text{obs}}} \right) \text{ a } \frac{\tilde{\sigma}_2^2}{\hat{\sigma}_2^2} = \frac{1}{2} (1 + F_{\text{obs}})$$

a testovacia štatistika pomerom vierohodnosti

$$u_{LR} = n \ln \left(\frac{\tilde{\sigma}^2}{\hat{\sigma}_1^2} \right) + n \left(\frac{\tilde{\sigma}^2}{\hat{\sigma}_2^2} \right) = 2n \ln \frac{1}{2} + n \left(\ln \left(1 + \frac{1}{F_{\text{obs}}} \right) + \ln(1 + F_{\text{obs}}) \right),$$

čo je veľké číslo, ak $1/F_{\text{obs}}$ alebo F_{obs} je veľké, t.j. F_{obs} je malé alebo veľké. Prvá derivácia U_{LR} podľa F je rovná $\frac{n}{1+F} \left(-\frac{1}{F} + 1 \right)$, čo je rovné nule, ak $F_{\text{obs}} = 1$. Keďže funkcia je rastúca pre malé a veľké F_{obs} , dosahuje u_{LR} v bode $F_{\text{obs}} = 1$ minimum. Ak $F_{\text{obs}} = 0$, potom $u_{LR} = 0$.

Bartlett (1937) modifikoval testovaciu štatistiku pomerom vierohodnosti nasledovne

$$U_B = \frac{U_{LR}^{(\text{alt})}}{C} \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2,$$

kde

$$U_{LR}^{(\text{alt})} = \sum_{j=1}^J (n_j - 1) \ln \left(\frac{\tilde{S}^2}{S_j^2} \right), \tilde{s}^2 = \frac{\sum_{j=1}^J (n_j - 1) S_j^2}{\sum_{j=1}^J (n_j - 1)},$$

S_j^2 sú výberové rozptyly a

$$C = 1 + \frac{1}{3(J-1)} \left(\sum_{j=1}^J \frac{1}{n_j - 1} - \frac{1}{\sum_{j=1}^J (n_j - 1)} \right).$$

U_B konverguje ku χ_{J-1}^2 rozdeleniu rýchlejšie ako U_{LR} .

Príklad 262 (testy o homogenite rozptylov) Naprogramujte v \mathbb{R}

(a) test pomerom vierohodnosti o homogenite rozptylov a

(b) Bartlettovu modifikáciu testu pomerom vierohodnosti o homogenite rozptylov. Funkciu nazvite `testy.o.rozpty`
Test (b) porovnajte s výsledkom funkcie `bartlett.test()`.

Riešenie v \mathbb{R}

```

1527 "testy.o.rozptyloch" <- function(vec.n,vec.s2){
1528   J <- length(vec.n)
1529   mle.s2 <- (vec.n-1)*vec.s2/vec.n
1530   pooled.s2 <- sum((vec.n-1)*vec.s2)/sum(vec.n)
1531   u.LR <- sum(vec.n*log(pooled.s2/mle.s2))
1532   p.hodn <- 1-pchisq(u.LR,df=J-1)
1533   VYSL.LR.test <- c(pooled.s2,u.LR,p.hodn)
1534   names(VYSL.LR.test) <- c("s2","test-stat","p-hodnota")
1535   pooled.s2 <- sum((vec.n-1)*vec.s2)/sum(vec.n-1)
1536   u.LR.alt <- sum((vec.n-1)*log(pooled.s2/vec.s2))
1537   menovatel <- 1+(sum(1/(vec.n-1))-1/sum(vec.n-1))/(3*(J-1))
1538   u.B <- u.LR.alt/menovatel
1539   p.hodn <- 1-pchisq(u.B,df=J-1)
1540   VYSL.B.test <- c(pooled.s2,u.B,p.hodn)
1541   names(VYSL.B.test) <- c("s2","test-stat","p-hodnota")
1542   VYSL <- list(VYSL.LR.test,VYSL.B.test)
1543   return(VYSL)
1544 }

```

Príklad 263 (testy o homogenite rozptylov; simulačná štúdia) Na základe simulačnej štúdie preverte, že ak (a) $Y_j \sim N(\mu_j, \sigma^2)$, kde $\mu_j = j$, $\sigma^2 = 1/4$, $j = 1, 2, \dots, J$ a (b) $Y_j \sim [(1-p)N(\mu_j, \sigma^2) + pN(\mu_j, \sigma_1^2)]$, kde $p = 0.05$ a $\sigma_1^2 = 1$, potom testovacia štatistika (1) U_{LR} a (2) U_B má χ_{J-1}^2 rozdelenie s $J-1$ stupňami voľnosti. Použite rozsahy náhodných výberov $n_j = 10$ a $n_j = 50$. Pre každú simuláciu vypočítajte $u_{LR,m}$ a $u_{B,m}$, $m = 1, 2, \dots, M$, kde $M = 10000$. Superponujte histogram vygenerovaných testovacích štatistík v relatívnej škále s teoretickou krivkou hustoty (1) U_{LR} a (2) U_B .

Riešenie (riešenie (a) pozri na obrázku 8.17)

Na základe simulačnej štúdie z príkladu 263 je lepšie používať Bartlettovu modifikáciu testu pomerom vierohodnosti o homogenite rozptylov ako test pomerom vierohodnosti pre $n \leq 50$, pretože konvergencia testovacej štatistiky testu pomerom vierohodnost k χ_{J-1}^2 rozdeleniu je pomalšia.

Príklad 264 (testy o homogenite rozptylov) Majme dáta *more-samples-variances-clavicle.txt* a premennú dĺžka kľúčnej kosti u mužov *cla.L* v mm. Otestujte rovnosť rozptylov štyroch populácií pomocou (1) testu pomerom vierohodnosti a (2) Bartlettovej modifikácie testu pomerom vierohodnosti o homogenite rozptylov. Pokiaľ $H_0 : \sigma_1^2 = \sigma_2^2 = \sigma_3^2 = \sigma_4^2 = \sigma^2$ zamietnete, zistíte medzi ktorými rozptylmi je štatisticky signifikantný rozdiel na hladine významnosti α použitím χ_{J-1}^2 (Scheffeho metóda; správny spôsob) a χ_1^2 (nesprávny spôsob).

Riešenie v \mathbb{R}

$u_{LR} \doteq 5.086$ a p-hodnota $\doteq 0.166$

$u_B \doteq 5.075$ a p-hodnota $\doteq 0.166$.

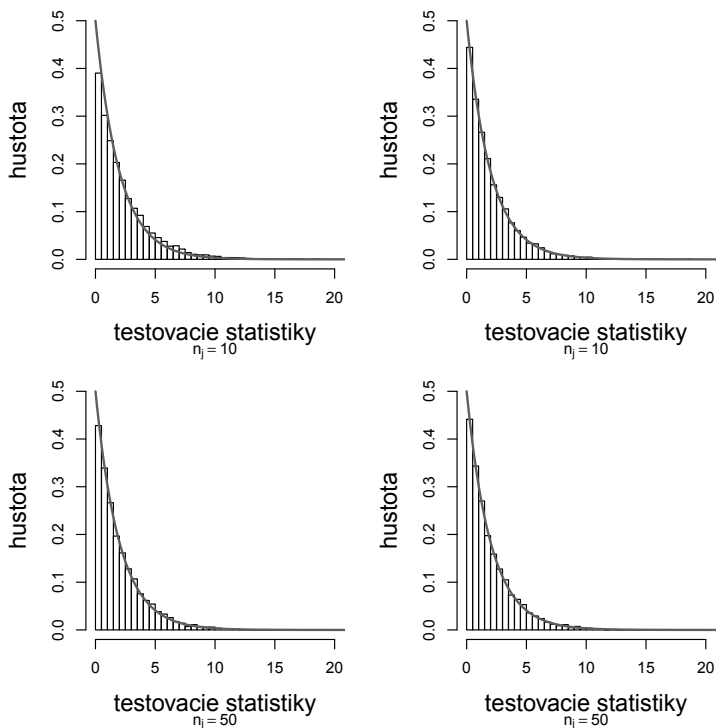
```

1545 DATA <- read.table("more-samples-variances-clavicle.txt",header=TRUE)
1546 names(DATA)
1547 ## [1] "population" "sex" "cla.L"
1548 DATA <- na.omit(DATA)
1549 attach(DATA)
1550 n <- tapply(cla.L,population,length)
1551 # eng gre ind1 ind2
1552 # 70 94 120 81
1553 rozptyly <- tapply(cla.L,population,var)
1554 # eng gre ind1 ind2
1555 #110.46149 83.15546 76.27283 67.57184
1556 "testy.o.rozptyloch(n,rozptyly)
1557 # s2 test-stat p-hodnota
1558 #81.7466134 5.0857782 0.1656227
1559 # s2 test-stat p-hodnota
1560 #82.6523930 5.0747268 0.1664064

```

Predpokladané rozdiely mohli byť teoreticky vyvolané odlišnými faktormi postnatálneho rastu kľúčnej kosti v každej z populácií alebo odlišne diverzným zložením každej populácie z hľadiska vnútorných rozdielov v raste kľúčnej kosti v puberte a adolescencii. I keď v hodnotách rozptylov vidíme relatívne veľké číselné rozdiely, viacvýberový test homogenity rozptylov nezamietol nulovú hypotézu zhody rozptylov dĺžky kľúčnej kosti pravej strany medzi mužmi pochádzajúcimi zo štyroch rôznych populácií. Číselné rozdiely v rozptyle sú teda spôsobené nejakými náhodnými faktormi (vzorkovanie, pmeranie, ap.). Významné rozdiely by sa však mohli prejaviť u kostí ľavej strany, ktorá je u väčšiny ľudí v priebehu postnatálneho rastu zaťažovaná menej a tiež rastie v priemere dlhšie než kľúčna kosť pravej strany

(Mays a kol., 1999), priestor pre vznik systematických rozdielov v rozptyle je tak u nej o niečo väčší. Významné rozdiely by sa tiež mohli prejaviť pri porovnaní mužov a žien (napr. Singh a Jit, 1996), keďže vzorce postnatálneho rastu sú u mužov a žien odlišné a v rade metrických znakov sú muži variabilnejší než ženy (Marini a kol., 1999). Vzhľadom na relatívne mierny veľkostný dimorfizmus a podobné stredné hodnoty metrických znakov u mužov a žien (najbežnejšie od cca 5 do 15 percent) je vhodné porovnávať variabilitu medzi pohlaviami na základe rozptylov v jednotkách odpovedajúcich druhej mocnine jednotiek pôvodného znaku. Pokiaľ by však bol rozdiel medzi strednými hodnotami pre mužov a ženy väčší (napr. v niektorých rozmeroch zápästných kostí; Mastrangelo a kol., 2011), rozdiely stredných hodnôt by mohli mechanicky ovplyvňovať aj rozdiely v rozptyloch. V takom prípade je vhodnejšie porovnanie relatívneho rozptýlenia hodnôt, napr. koeficientu variácie (pozri kapitolu 3.2).



Obr. 8.17: Histogramy vygenerovaných testovacích štatistík (za platnosti nulovej hypotézy) v relatívnej škále superponované s teoretickými krivkami hustoty U_{LR} (vľavo) a U_B (vpravo)

8.3 Asymptotické testy o korelačných koeficientoch

V tejto kapitole sa budeme zaoberať testami o homogenite (rovnosti) viacerých korelačných koeficientov. Najprv odvodíme χ^2 -testovaciu štatistiku testujúcu rovnosť Fisherových Z -transformácií (zovšeobecnenie dvojvýberovej Z -štatistiky z kapitoly 7.3) a následne testovaciu štatistiku pomerom viero-hodnosti. Hypotézy definujeme nasledovne $H_0 : \rho_1 = \rho_2 = \dots = \rho_J = \rho$ oproti $H_1 : \rho_i \neq \rho_j \neq \rho$ pre aspoň jedno $i < j, i = 1, 2, \dots, J - 1; j = 2, 3, \dots, J$.

Z kapitol 6.3 a 7.3 vieme, že výberový korelačný koeficient R má asymptoticky normálne rozdelenie, ale konvergencia k nemu je pomalá (rozdelenie je zošikmené) a tiež, že je lepšie použiť normalizujúcu a rozptyl stabilizujúcu Fisherovu Z -transformáciu korelačného koeficientu, ktorá má asymptoticky

normálne rozdelenie. Potom (Donner a Rosner, 1974)

$$\chi_F^2 = \sum_{j=1}^J \left(\frac{Z_j - \xi_0}{\sqrt{n_j - 3}} \right)^2 = \sum_{j=1}^J (n_j - 3)(Z_j - \xi_0)^2 \stackrel{\mathcal{D}}{\sim} \chi_J^2.$$

kde $Z_j = \frac{1}{2} \ln \frac{1+R_j}{1-R_j}$, $j = 1, 2, \dots, J$, a $\xi_0 = \frac{1}{2} \ln \frac{1+\rho_0}{1-\rho_0}$ a ξ_0 je potrebné odhadnúť nasledovne

$$\tilde{\xi}_0 = \bar{Z} = \frac{\sum_{j=1}^J (n_j - 3)Z_j}{\sum_{j=1}^J (n_j - 3)},$$

z čoho vyplýva že

$$R_F = \tanh \bar{Z} = \frac{\exp(2\bar{Z}) - 1}{\exp(2\bar{Z}) + 1}.$$

Alternatívna verzia výpočtu \bar{Z} je uvedená v práci Hotelling (1953). Potom bude platiť

$$\chi_F^2 = \sum_{j=1}^J (n_j - 3)(Z_j - \bar{Z})^2 \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2.$$

Test pomerom vierohodnosti o rovnosti korelačných koeficientov.

Nech $(X_j, Y_j)^T \sim N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, kde $(X_j, Y_j)^T$ sú nezávislé, $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_J)^T$, $\boldsymbol{\theta}_j = (\mu_{j1}, \mu_{j2}, \sigma_{j1}^2, \sigma_{j2}^2, \rho_j)^T$ a $j = 1, 2, \dots, J$. Logaritmus funkcie vierohodnosti bude mať tvar (Paul, 1989)

$$\begin{aligned} l(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{y}_1, \dots, \mathbf{x}_J, \mathbf{y}_J) &= -n \ln(2\pi) - \sum_{j=1}^J \frac{n_j}{2} \ln(\sigma_{j1}^2 \sigma_{j2}^2) - \sum_{j=1}^J \frac{n_j}{2} \ln(1 - \rho_j^2) \\ &- \sum_{j=1}^J \frac{1}{2(1 - \rho_j^2)} \left(\frac{\sum_{i=1}^{n_j} (x_{ji} - \mu_{j1})^2}{\sigma_{j1}^2} - 2\rho_j \frac{\sum_{i=1}^{n_j} (x_{ji} - \mu_{j1})(y_{ji} - \mu_{j2})}{\sigma_{j1}\sigma_{j2}} \right. \\ &\left. + \frac{\sum_{i=1}^{n_j} (y_{ji} - \mu_{j2})^2}{\sigma_{j2}^2} \right), \end{aligned}$$

kde $n = \sum_{j=1}^J n_j$. MLE $\hat{\boldsymbol{\theta}}_j = (\hat{\mu}_{j1}, \hat{\mu}_{j2}, \hat{\sigma}_{j1}^2, \hat{\sigma}_{j2}^2, \hat{\rho}_j)^T$, kde

$$\begin{aligned} \hat{\mu}_{j1} &= \bar{x}_j, \hat{\mu}_{j2} = \bar{y}_j, \hat{\sigma}_{j1}^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (x_{ji} - \bar{x}_j)^2, \hat{\sigma}_{j2}^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2, \\ \hat{\rho}_j &= \frac{\sum_{i=1}^{n_j} (x_{ji} - \bar{x}_j)(y_{ji} - \bar{y}_j)}{n_j s_{j1} s_{j2}} \end{aligned}$$

a $\Theta_1 = \{\boldsymbol{\theta} : \rho_i \neq \rho_j, i < j, i = 1, 2, \dots, J-1; j = 2, 3, \dots, J\}$ pre aspoň jedno i a j . Za platnosti H_0 je $\boldsymbol{\theta}_{j0} = (\hat{\mu}_{j1}, \hat{\mu}_{j2}, \tilde{\sigma}_{j1}^2, \tilde{\sigma}_{j2}^2, \tilde{\rho})^T$, kde

$$\tilde{\sigma}_{j1}^2 = \frac{\hat{\sigma}_{j1}^2(1 - \hat{\rho}\hat{\rho}_j)}{1 - \hat{\rho}^2}, \tilde{\sigma}_{j2}^2 = \frac{\hat{\sigma}_{j2}^2(1 - \hat{\rho}\hat{\rho}_j)}{1 - \hat{\rho}^2}$$

maximálne vierohodný odhad $\hat{\rho}$ je iteračným riešením rovnice $\sum_{j=1}^J \frac{n_j(\hat{\rho}_j - \hat{\rho})}{1 - \hat{\rho}_j \hat{\rho}} = 0$ (pozri Pearson,

1933) a $\Theta_0 = \{\boldsymbol{\theta} : \rho_1 = \rho_2 = \rho\}$. Logaritmus funkcie vierohodnosti pre $\hat{\boldsymbol{\theta}}$ bude mať tvar

$$\begin{aligned} l(\hat{\boldsymbol{\theta}}|\mathbf{x}_1, \mathbf{y}_1, \dots, \mathbf{x}_J, \mathbf{y}_J) &= -n \ln(2\pi) - \sum_{j=1}^J \frac{n_j}{2} \ln(\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2) - \sum_{j=1}^J \frac{n_j}{2} \ln(1 - \hat{\rho}_j^2) \\ &\quad - \sum_{j=1}^J \frac{1}{2(1 - \hat{\rho}_j^2)} \left(\frac{n_j \hat{\sigma}_{j1}^2}{\hat{\sigma}_{j1}^2} - 2\hat{\rho}_j \frac{n_j \hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2 \hat{\rho}_j}{\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2} + \frac{n_j \hat{\sigma}_{j2}^2}{\hat{\sigma}_{j2}^2} \right) \\ &= -n \ln(2\pi) - \sum_{j=1}^J \frac{n_j}{2} \ln(\hat{\sigma}_{j1}^2 \hat{\sigma}_{j2}^2) - \sum_{j=1}^J \frac{n_j}{2} \ln(1 - \hat{\rho}_j^2) - n. \end{aligned}$$

Logaritmus funkcie vierohodnosti pre $\boldsymbol{\theta}_0$ bude mať tvar

$$\begin{aligned} l(\boldsymbol{\theta}_0|\mathbf{x}_1, \mathbf{y}_1, \dots, \mathbf{x}_J, \mathbf{y}_J) &= -n \ln(2\pi) - \sum_{j=1}^J \frac{n_j}{2} \ln(\tilde{\sigma}_{j1}^2 \tilde{\sigma}_{j2}^2) - \sum_{j=1}^J \frac{n_j}{2} \ln(1 - \tilde{\rho}^2) \\ &\quad - \sum_{j=1}^J \frac{1}{2(1 - \tilde{\rho}^2)} \left(\frac{n_j \tilde{\sigma}_{j1}^2}{\tilde{\sigma}_{j1}^2} - 2\tilde{\rho} \frac{n_j \tilde{\sigma}_{j1}^2 \tilde{\sigma}_{j2}^2 \tilde{\rho}_j}{\tilde{\sigma}_{j1}^2 \tilde{\sigma}_{j2}^2} + \frac{n_j \tilde{\sigma}_{j2}^2}{\tilde{\sigma}_{j2}^2} \right) \\ &= -n \ln(2\pi) - \sum_{j=1}^J \frac{n_j}{2} \ln(\tilde{\sigma}_{j1}^2 \tilde{\sigma}_{j2}^2) - \sum_{j=1}^J n_j \ln \frac{(1 - \tilde{\rho} \tilde{\rho}_j)^2}{(1 - \tilde{\rho}^2)^2} \\ &\quad - \sum_{j=1}^J \frac{n_j}{2} \ln(1 - \tilde{\rho}^2) - n \end{aligned}$$

Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\boldsymbol{\theta}|\mathbf{x}_1, \mathbf{y}_1, \dots, \mathbf{x}_J, \mathbf{y}_J)) &= l(\hat{\boldsymbol{\theta}}|\mathbf{x}_1, \mathbf{y}_1, \dots, \mathbf{x}_J, \mathbf{y}_J) - l(\boldsymbol{\theta}_0|\mathbf{x}_1, \mathbf{y}_1, \dots, \mathbf{x}_J, \mathbf{y}_J) \\ &= -\sum_{j=1}^J \frac{n_j}{2} \ln(1 - \hat{\rho}_j^2) + \sum_{j=1}^J \frac{n_j}{2} \ln(1 - \tilde{\rho}^2) + \sum_{j=1}^J n_j \ln \frac{(1 - \tilde{\rho} \tilde{\rho}_j)^2}{(1 - \tilde{\rho}^2)^2} \\ &= \frac{1}{2} \sum_{j=1}^J n_j \ln \frac{(1 - \tilde{\rho} \tilde{\rho}_j)^2}{(1 - \tilde{\rho}^2)(1 - \hat{\rho}_j^2)}. \end{aligned}$$

Vieme, že testovacia štatistika pomerom vierohodnosti $U_{LR} = -2 \ln(\lambda(\mathbf{X}_1, \mathbf{Y}_1, \dots, \mathbf{X}_J, \mathbf{Y}_J))$
 $\stackrel{D}{\sim} \chi_{J-1}^2$.

Príklad 265 (testy o homogenite korelačných koeficientov) Naprogramujte v \mathbb{R} (a) test pomerom vierohodnosti a (b) χ^2 -test o homogenite korelačných koeficientov. Funkciu nazvite *testy.o.kor.koef()*.

Riešenie v \mathbb{R}

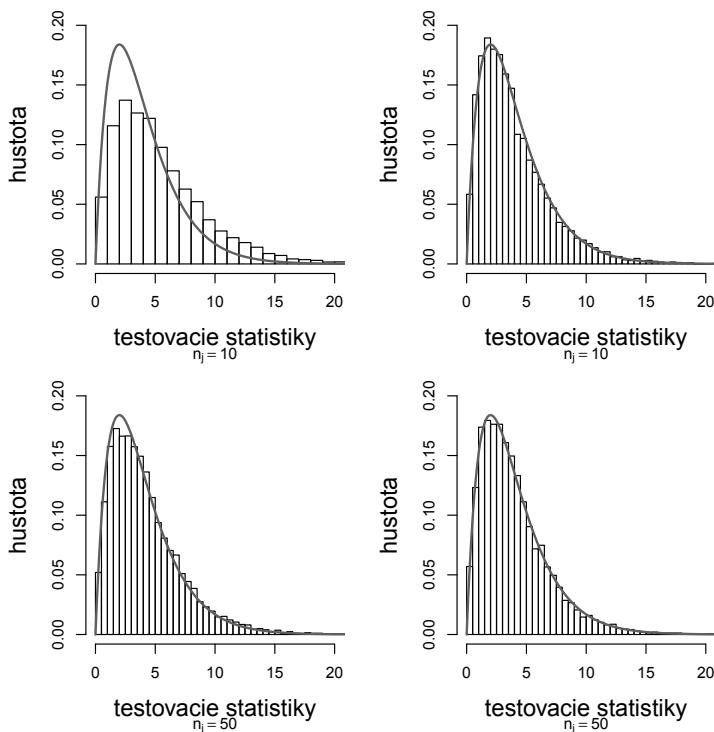
```

1561 "rho.hat" <- function(r,vec.r,vec.n) sum(vec.n*(vec.r-r)/(1-vec.r*r))
1562 "testy.o.kor.koef" <- function(vec.n,vec.r){
1563   J <- length(vec.n)
1564   kor <- unroot(rho.hat,interval=c(-1,1),vec.n=vec.n,vec.r=vec.r)$root
1565   u.LR <- sum(vec.n*log((1-vec.r*kor)^2/((1-kor^2)*(1-vec.r^2))))
1566   p.hodn <- 1-pchisq(u.LR,df=J-1)
1567   VYSL.LR.test <- c(u.LR,p.hodn)
1568   names(VYSL.LR.test) <- c("test-stat","p-hodnota")
1569   xi.j <- atanh(vec.r)
1570   z.bar <- sum((vec.n-3)*xi.j)/sum(vec.n-3)
1571   kor <- (exp(2*z.bar)-1)/(exp(2*z.bar)+1)
1572   #kor <- tanh(z.bar)
1573   chisq.obs <- sum((vec.n-3)*(xi.j-z.bar)^2)
1574   p.hodn <- 1-pchisq(chisq.obs,df=J-1)
1575   VYSL.chisq.test <- c(kor,chisq.obs,p.hodn)
1576   names(VYSL.chisq.test) <- c("rho.hat","test-stat","p-hodnota")
1577   VYSL <- list(VYSL.LR.test,VYSL.chisq.test)
1578   return(VYSL)
1579 }
```

Príklad 266 (testy o homogenite korelačných koeficientov; simulačná štúdia) Na základe simulačnej štúdie preverte, že ak (a) $(X_j, Y_j)^T \sim N_2(\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$, kde $\mu_{j1} = 50, \mu_{j2} = 25, \sigma_{j1}^2 = \sigma_{j2}^2 = 9, \rho = 0, j = 1, 2, \dots, J$ a (b) $pN_2(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1) + (1-p)N_2(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$, kde $p = 0.05$ a $\sigma_1^2 = 1$, potom testovacia štatistika (1) U_{LR} a (2) χ_F^2 má χ_{J-1}^2 rozdelenie s $J-1$ stupňami voľnosti. Použite rozsahy náhodných výberov $n_j = 10$ a $n_j = 50$. Pre každú simuláciu vypočítajte $u_{LR,m}$ a $\chi_{F,obs,m}^2, m = 1, 2, \dots, M$, kde $M = 10000$. Superponujte histogram vygenerovaných testovacích štatistík v relatívnej škále s teoretickou krivkou hustoty (1) U_{LR} a (2) χ_F^2 .

Riešenie (riešenie (a) pozri na obrázku 8.18)

Na základe simulačnej štúdie z príkladu 266 je lepšie používať χ^2 -test o homogenite korelačných koeficientov ako test pomerom vierohodnosti pre $n \leq 50$, pretože konvergencia testovacej štatistiky testu pomerom vierohodnosti k χ_{J-1}^2 rozdeleniu je pomalšia.



Obr. 8.18: Histogramy vygenerovaných testovacích štatistík (za platnosti nulovej hypotézy) v relatívnej škále superponované s teoretickými krivkami hustoty U_{LR} (vľavo) a χ_F^2 (vpravo)

Príklad 267 (testy o homogenite korelačných koeficientov) Majme dáta *more-samples-correlations-skull.txt* a premenné výška nosa (*nose.H*) a šírka nosa (*nose.B*) v mm. (a) Otestujte rovnosť rozptylov piatich populácií pomocou (1) testu pomerom vierohodnosti a (2) χ^2 -testu o homogenite korelačných koeficientov. (b) Pokiaľ $H_0 : \rho_1 = \rho_2 = \rho_3 = \rho_4 = \rho_5 = \rho$ zamietnete, zistite medzi ktorými korelačnými koeficientami je štatisticky signifikantný rozdiel na hladine významnosti α použitím χ_{J-1}^2 (Scheffeho metóda; správny spôsob) a χ_1^2 (nesprávny spôsob). (c) Vypočítajte aj aritmetické priemery a rozptyly jednotlivých populácií. (d) Otestujte nulovosť jednotlivých korelačných koeficientov v každej z piatich populácií na hladine významnosti α použitím χ_{J-1}^2 .

Riešenie v \mathbb{R}
 $u_{LR} \doteq 9.820$ a p -hodnota $\doteq 0.044$
 $\chi^2_{F,obs} \doteq 8.428$ a p -hodnota $\doteq 0.077$.

```

1580 DATA <- read.table("more-samples-correlations-skull.txt", header=TRUE)
1581 names(DATA)
1582 # [1] "id" "pop" "sex" "nose.H" "nose.B" "intorb.B"
1583 DATA <- na.omit(DATA)
1584 attach(DATA)
1585 hladiny <- levels(pop)
1586 # [1] "ban" "cin" "mal" "nem" "per"
1587 vec.n <- tapply(nose.H, pop, length)
1588 vec.n <- table(pop)
1589 #ban cin mal nem per
1590 # 14 19 73 20 46
1591 vec.r <- numeric(5)
1592 for (j in 1:5) vec.r[j] <- cor(DATA[pop==hladiny[j],4], DATA[pop==hladiny[j],5])
1593 names(vec.r) <- hladiny
1594 vec.r
1595 # ban cin mal nem per
1596 #0.67190649 0.01149325 0.18891009 0.59573830 0.13706907
1597 testy.o.kor.koef(vec.n, vec.r)
1598 # rho.hat test-stat p-hodnota
1599 #0.25355680 9.81976444 0.04357567
1600 # rho.hat test-stat p-hodnota
1601 #0.2501608 8.4281651 0.0770948
1602 # zakladne charakteristiky
1603 vec.cov <- matrix(0,5,2)
1604 vec.cov[,1] <- tapply(DATA[,4], pop, var)
1605 vec.cov[,2] <- tapply(DATA[,5], pop, var)
1606 dimnames(vec.cov)[[1]] <- hladiny
1607 vec.mean <- matrix(0,5,2)
1608 vec.mean[,1] <- tapply(DATA[,4], pop, mean)
1609 vec.mean[,2] <- tapply(DATA[,5], pop, mean)
1610 dimnames(vec.mean)[[1]] <- hladiny
1611 TAB.zakl.char <- cbind(vec.mean, vec.cov)
1612 dimnames(TAB.zakl.char)[[2]] <- c("mean(nose.H)", "mean(nose.B)",
1613 "var(nose.H)", "var(nose.B)")
1614 # mean(nose.H) mean(nose.B) var(nose.H) var(nose.B)
1615 #ban 48.92857 26.92857 17.456044 9.917582
1616 #cin 53.00000 25.21053 8.555556 2.730994
1617 #mal 51.82192 26.06849 13.953957 4.509132
1618 #nem 51.85000 24.20000 8.450000 5.852632
1619 #per 50.45652 22.97826 9.364734 2.777295
1620 rho <- 0
1621 tW.obs <- sqrt(vec.n-2)*vec.r/(sqrt(1-vec.r^2))
1622 uLR.obs <- -vec.n*log(1-tW.obs^2/(tW.obs^2+(vec.n-2)))
1623 # ban cin mal nem per
1624 #8.406888343 0.002509969 2.652774161 8.767126374 0.872466639
1625 p.hodn.LR <- 1-pchisq(uLR.obs, df=5-1) # spravny sposob
1626 # ban cin mal nem per
1627 #0.07776037 0.99999921 0.61750345 0.06719122 0.92847727
1628 p.hodn.LR <- 1-pchisq(uLR.obs, df=1) # nespravny sposob
1629 # ban cin mal nem per
1630 #0.003738019 0.960043029 0.103369360 0.003067083 0.350273343

```

Z výsledkov príkladu 267 je zreteľné, že použitie testu pomerom vierohodnosti nie je kvôli nízkym početnostiam vhodné, čo je aj dôvod rozdielu v signifikancii výsledkov použitých testov. Ďalším problémom môžu byť aj veľké rozdiely v rozptyloch (t.j. ich nehomogenita).

Z popisnej štatistiky je zrejma malá vzorka u niektorých populácií a tiež veľké rozdiely v rozptyloch. To môže byť príčinou jednak číselných rozdielov v korelačných koeficientoch samotných a jednak nemožnosti zamietnuť zhodu medzi nimi viacvýberovým testom. Ak by sme testovali nulovú korelačných koeficientov nezávisle pre každú populáciu, zamietli by sme nulovú hypotézu u dvoch populácií (ban a nem), ale nezamietli u dvoch najpočetnejších populácií (mal a per). Keďže ide o viacvýberový problém, žiadnu nulovú hypotézu nezamietame. Na základe dát teda nemôžeme tvrdiť, že medzi dvoma sledovanými rozmermi existuje nejaký vzťah. Súčasne ale vidíme, že (a) všetky korelačné koeficienty sú pozitívne a (b) pozitívna, i keď slabá, je aj závislosť medzi oboma rozmermi u dvoch najpočetnejšie zastúpených populácií (malajská a peruánska). Výsledok správne použitého Scheffeho testu síce na 5% hladine významnosti nezamietol zhodu korelačných koeficientov, významnosť je ale hraničná (p -hodnota = 0.077), čo naznačuje, že pri dostatočne veľkej vzorke by sme rozdiely medzi populáciami mohli nájsť a vysvetlenie tohto rozdielu by bolo treba hľadať v odlišnostiach biologických procesov medzi populáciami a/alebo v procesoch vzniku vzoriek. Táto situácia je žiaľ typická pre metrické porovnanie kostrových vzoriek, ktoré sú (nevyhnutne) výsledkom spracovania populácií zomretých ľudí z pohrebísk (Wood a kol., 1992), kde charakter analyzovaných dát je ovplyvnený celým radom faktorov, od hľadaných biologických procesov a selektívnej mortality, cez pohrebný rítus a tafonomické procesy (zachovalosť a fragmentárnosť pozostatkov), až po rozsah a metodiku archeologického výskumu (čiastkový záchranný výskum – neúplné pohrebiská).

8.4 Asymptotické testy o pravdepodobnostiach

V tejto kapitole sa budeme zaoberať testami o zhode vektora pravdepodobností s nejakým teoretickým vektorom pravdepodobností. Najprv odvodíme testovaciu štatistiku pomerom vierohodností, potom Waldovu a skóre testovaciu štatistiku. Ukážeme, že v posledných dvoch prípadoch ide o χ^2 -test dobrej zhody. Hypotézu definujeme nasledovne $H_0 : \mathbf{p} = \mathbf{p}_0$ oproti $H_1 : \mathbf{p} \neq \mathbf{p}_0$, kde $\mathbf{p} = (p_1, p_2, \dots, p_J)^T$ a $\mathbf{p}_0 = (p_{01}, p_{02}, \dots, p_{0J})^T$. Ďalej sa budeme zaoberať testami o homogenite (rovnosti) viacerých pravdepodobností. Hypotézy definujeme nasledovne $H_0 : p_1 = p_2 = \dots = p_I = p$ oproti $H_1 : p_i \neq p_j \neq p$ pre aspoň jedno $i < j, i = 1, 2, \dots, I-1; j = 2, 3, \dots, I$ (ide o nezávislé pravdepodobnosti z I binomických rozdelení). Nakoniec budeme diskutovať testy homogenity viacerých vektorov pravdepodobností. Pre dva vektory pravdepodobností hypotézy definujeme nasledovne $H_0 : \mathbf{p}_1 = \mathbf{p}_2$ oproti $H_1 : \mathbf{p}_1 \neq \mathbf{p}_2$, kde $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{iJ})^T$.

V prvom prípade môžeme realizácie y_j usporiadať do nasledovnej **kontingenčnej tabuľky** $1 \times J$ **pre početnosti**

	odpoveď 1	odpoveď 2	...	odpoveď J	spolu
	y_1	y_2	...	y_J	N

kde $\sum_{j=1}^J y_j = N$ a **kontingenčnej tabuľky** $1 \times J$ **pre pravdepodobnosti**

	odpoveď 1	odpoveď 2	...	odpoveď J	spolu
	p_1	p_2	...	p_J	1

V druhom prípade ide o špeciálny prípad súčinového multinomického rozdelenia (I nezávislých binomických rozdelení) a nezávislé realizácie y_j môžeme usporiadať do nasledovnej **kontingenčnej tabuľky** $2 \times I$ **pre početnosti**

	skupina 1	skupina 2	...	skupina I
má znak	y_1	y_2	...	y_I
nemá znak	$N_1 - y_1$	$N_2 - y_2$...	$N_I - y_I$
	N_1	N_2	...	N_I

a **kontingenčnej tabuľky** $2 \times I$ **pre pravdepodobnosti**

	skupina 1	skupina 2	...	skupina I
má znak	p_1	p_2	...	p_I
nemá znak	$1 - p_1$	$1 - p_2$...	$1 - p_I$
spolu	1	1	...	1

V treťom prípade ide o špeciálny prípad súčinového multinomického rozdelenia (2 nezávislé multinomické rozdelenia) a realizácie y_{ij} môžeme usporiadať do nasledovnej **kontingenčnej tabuľky** $2 \times J$ **pre početnosti**

	kategória 1	kategória 2	...	kategória J	spolu
skupina 1	y_{11}	y_{12}	...	y_{1J}	N_1
skupina 2	y_{21}	y_{22}	...	y_{2J}	N_2

a **kontingenčnej tabuľky** $2 \times J$ **pre pravdepodobnosti**

	kategória 1	kategória 2	...	kategória J	spolu
skupina 1	$p_{1 1}$	$p_{2 1}$...	$p_{J 1}$	1
skupina 2	$p_{1 2}$	$p_{2 2}$...	$p_{J 2}$	1

Predchádzajúcu tabuľku kvôli zjednodušeniu značenia preznačme nasledovne

	kategória 1	kategória 2	...	kategória J	spolu
skupina 1	p_{11}	p_{12}	...	p_{1J}	1
skupina 2	p_{21}	p_{22}	...	p_{2J}	1

Test pomerom vierohodnosti v multinomickom rozdelení.

Nech $Y \sim Mult_J(N, \mathbf{p})$, kde $\boldsymbol{\theta} = \mathbf{p} = (p_1, p_2, \dots, p_J)^T$. Logaritmus jadra vierohodnosti má tvar

$$l(\boldsymbol{\theta}|\mathbf{y}) = \ln \prod_{j=1}^J p_j^{y_j}.$$

MLE $\boldsymbol{\theta}$ je rovný $\hat{\boldsymbol{\theta}} = \hat{\mathbf{p}} = (\hat{p}_1, \hat{p}_2, \dots, \hat{p}_J)^T$, kde $\hat{p}_j = y_j/N$, t.j. $\Theta_1 = \{\boldsymbol{\theta} : p_j \neq p_{0j}, j = 1, 2, \dots, J\}$ pre aspoň jedno j . Za platnosti H_0 je $\boldsymbol{\theta}_0 = \mathbf{p}_0$ a $\Theta_0 = \{\boldsymbol{\theta} : p_j = p_{0j}, j = 1, 2, \dots, J\}$ pre všetky j . Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{y})) &= l(\hat{\boldsymbol{\theta}}|\mathbf{y}) - l(\boldsymbol{\theta}_0|\mathbf{y}) = \sum_{j=1}^J y_j \ln \frac{y_j}{N} - \sum_{j=1}^J y_j \ln p_{0j} \\ &= \sum_{j=1}^J y_j \ln \frac{\frac{y_j}{N}}{p_{0j}} = \sum_{j=1}^J y_j \ln \frac{y_j}{N p_{0j}} = \sum_j \text{pozorované}_j \times \ln \frac{\text{pozorované}_j}{\text{očakávané}_j}. \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierohodnosti** $U_{LR} = -2 \ln(\lambda(\mathbf{Y})) \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$.

Waldov test v multinomickom rozdelení.

Na základe definície multinomického rozdelenia, definície $\mathcal{I}(\mathbf{p})$ z kapitoly 2, asymptotickej normality $\sqrt{N}(\frac{1}{N}\mathbf{X} - \mathbf{p}_0) \sim N_{J-1}(\mathbf{0}_{J-1}, \boldsymbol{\Sigma}_0)$, rozdelenia kvadratickej formy $N(\frac{1}{N}\mathbf{X} - \mathbf{p}_0)^T \boldsymbol{\Sigma}_0^{-1}(\frac{1}{N}\mathbf{X} - \mathbf{p}_0) \sim \chi_{J-1}^2$ a rovnosti $p_{0J} = 1 - \sum_{j=1}^{J-1} p_{0j}$ (kde vektory pravdepodobností sú $(J-1)$ -rozmerné), môžeme písať

$$\begin{aligned} u_W &= N \sum_{j=1}^{J-1} (\hat{p}_j - p_{0j})^2 / p_{0j} + N \sum_{i=1}^{J-1} \sum_{j=1}^{J-1} (\hat{p}_i - p_{0i})(\hat{p}_j - p_{0j}) / p_{0j} \\ &= N \sum_{j=1}^{J-1} (\hat{p}_j - p_{0j})^2 / p_{0j} + N \left[\sum_{j=1}^{J-1} (\hat{p}_j - p_{0j}) \right]^2 / p_{0J} \\ &= N \sum_{j=1}^{J-1} (\hat{p}_j - p_{0j})^2 / p_{0j} + N (\hat{p}_J - p_{0J})^2 / p_{0J} \\ &= N \sum_{j=1}^J (\hat{p}_j - p_{0j})^2 / p_{0j} = \sum_{j=1}^J \frac{(y_j - N p_{0j})^2}{N p_{0j}} \\ &= \sum_{j=1}^J \frac{(\text{pozorované}_j - \text{očakávané}_j)^2}{\text{očakávané}_j}. \end{aligned}$$

Vieme, že **Waldova testovacia štatistika** $U_W \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$.

Skóre test v multinomickom rozdelení.

Na základe definície multinomického rozdelenia, definície $\mathcal{I}^{-1}(\mathbf{p})$ z kapitoly 2 a rovnosti $p_{0J} = 1 - \sum_{j=1}^{J-1} p_{0j}$ (kde vektory pravdepodobností sú $(J-1)$ -rozmerné), môžeme písať

$$\begin{aligned} u_S &= N \sum_{j=1}^{J-1} \left(\frac{\hat{p}_j}{p_{0j}} - \frac{\hat{p}_J}{p_{0J}} \right)^2 p_{0j} - N \sum_{i=1}^{J-1} \sum_{j=1}^{J-1} \left(\frac{\hat{p}_i}{p_{0i}} - \frac{\hat{p}_J}{p_{0J}} \right) \left(\frac{\hat{p}_j}{p_{0j}} - \frac{\hat{p}_J}{p_{0J}} \right) p_{0i} p_{0j} \\ &= N \sum_{j=1}^{J-1} (B)^2 p_{0j} + A = C + A, \end{aligned}$$

kde $\sum_{j=1}^{J-1} (\hat{p}_j - p_{0j}) = -(\hat{p}_J - p_{0J})$,

$$A = -N \left[\sum_{j=1}^{J-1} \left(\frac{\hat{p}_j}{p_{0j}} - \frac{\hat{p}_J}{p_{0J}} \right) p_{0j} \right]^2 = -N \left(\frac{\hat{p}_J}{p_{0J}} - 1 \right)^2$$

$$B = \frac{\hat{p}_j p_{0J} - \hat{p}_J p_{0j} \pm p_{0J} p_{0j}}{p_{0j} p_{0J}} = [p_{0J} (\hat{p}_j - p_{0j}) - p_{0j} (\hat{p}_J - p_{0J})] / (p_{0j} p_{0J}),$$

$$\begin{aligned} C &= N \left[\sum_{j=1}^{J-1} \frac{1}{p_{0j}} (\hat{p}_j - p_{0j})^2 + \frac{2}{p_{0J}} (\hat{p}_J - p_{0J})^2 + \frac{1}{p_{0J}^2} (1 - p_{0J}) (\hat{p}_J - p_{0J})^2 \right] \\ &= N \left[\sum_{j=1}^J \frac{1}{p_{0j}} (\hat{p}_j - p_{0j})^2 + \frac{1}{p_{0J}^2} (\hat{p}_J - p_{0J})^2 \right]. \end{aligned}$$

Potom

$$u_S = N \sum_{j=1}^J \frac{1}{p_{0j}} (\hat{p}_j - p_{0j})^2 = \sum_{j=1}^J \frac{(y_j - N p_{0j})^2}{N p_{0j}} = \sum_{j=1}^J \frac{(\text{pozorované}_j - \text{očakávané}_j)^2}{\text{očakávané}_j}.$$

Vieme, že **skóre testovacia štatistika** $U_S \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$.

Sila testu. Sila χ^2 testu (Waldovho a skóre testu v multinomickom rozdelení) $1 - \beta$ je definovaná ako

$$1 - \beta = \Pr(\chi_{J-1, \lambda^2}^2 \geq \chi_{J-1}^2(\alpha)),$$

kde $\chi_{J-1}^2(\alpha)$ je kritická hodnota χ_{J-1}^2 rozdelenia s $J-1$ stupňami voľnosti a χ_{J-1, λ^2}^2 náhodná premenná z necentrálneho χ_{J-1}^2 rozdelenia s $J-1$ stupňami voľnosti a parametrom necentrality λ^2 . Potom **minimálny rozsah** N pre nejaký vektor pravdepodobností \mathbf{p} za platnosti alternatívnej hypotézy bude rovný

$$N = \lambda^2 \left(\sum_{j=1}^J N \frac{(p_j - p_{0j})^2}{p_{0j}} \right)^{-1},$$

kde

$$\lambda^2 = \lim_{N \rightarrow \infty} \sum_{j=1}^J N \frac{(p_j - p_{0j})^2}{p_{0j}}$$

a tento parameter necentrality vypočítame iteračným riešením rovníc $1 - \beta = \Pr(\chi_{J-1, \lambda^2}^2 \geq \chi_{J-1}^2(\alpha))$.

Príklad 268 (minimálny rozsah) Naprogramujte v \mathbb{R} funkciu na výpočet minimálneho rozsahu súboru N . Nazvite ju *minimalny.rozsah.multinom()*. Aplikujte na vektory $\mathbf{p} = (0.4, 0.3, 0.2, 0.1)^T$ a $\mathbf{p}_0 = (0.420, 0.366, 0.160, 0.054)^T$.

Riešenie

Parameter necentrality $\lambda^2 = 11.48$ (necentrálneho χ_{J-1}^2 rozdelenia) a minimálny rozsah $N = 185$.

Krvné A a B sú dominanté nad 0 a kodominantné navzájom. Preto pre fenotyp 0 existuje len jeden genotyp 00 ; fenotyp krvnej skupiny A pozostáva z genotypov AA alebo $A0$, fenotyp krvnej skupiny B z genotypov BB alebo $B0$; pre fenotyp AB existuje len jeden genotyp AB . Nech p je pravdepodobnosť výskytu alely 0 , q je pravdepodobnosť výskytu alely A a r je pravdepodobnosť výskytu alely B . Potom $p + q + r = 1$. Za platnosti Hardy-Weinbergovho (HW) zákona môžeme písať

$$(p + q + r)^2 = p^2 + q^2 + r^2 + 2pq + 2pr + 2qr = 1, \text{ kde } p = 1 - q - r.$$

Príklad 269 (populačná genetika; krvné skupiny) *Majme dáta multinom-blood-groups.txt. (a) Pomocou χ^2 -testu dobrej zhody otestuje zhodu početností krvných skupín pre Prahu s Hardy-Weinbergovým zákonom. (b) Nakreslite logaritmus štandardizovanej funkcie vierohodnosti v parametroch q a r pomocou funkcie `contour()`. Dokreslite do obrázku jej maximum v bode $\hat{\boldsymbol{\theta}} = (\hat{q}, \hat{r})^T$. (c) V obrázku zvýraznite vierohodnostnú 95% empirickú elipsu spoľahlivosti pomocou funkcie `polygon()`. (c) Nakreslite stĺpcový diagram relatívnych početností krvných skupín (v %) pre Košice a Prahu.*

Riešenie (pozri tabuľku 8.5, obrázky 8.19)


Nech $(Y_1, Y_2, Y_3, Y_4)^T \sim Mult_4(N, \mathbf{p})$, kde $N = 500$ a $\mathbf{p} = (p_1, p_2, p_3, p_4)^T$. Za platnosti HW zákona $(Y_1, Y_2, Y_3, Y_4)^T \sim Mult_4(N, \mathbf{p}_0)$, kde $N = 500$, $\mathbf{p}_0 = (p_{01}, p_{02}, p_{03}, p_{04})^T$, $p_{01} = p^2$ (genotyp 00), $p_{02} = q^2 + 2qp$ (genotyp AA a A0), $p_{03} = r^2 + 2rp$ (genotyp BB a B0) a $p_{04} = 2qr$ (genotyp AB). Pravdepodobnosti q a r odhadneme pomocou maximalizácie logaritmu funkcie vierohodnosti parametra $\boldsymbol{\theta} = (q, r)^T$, kde po dosadení do jadra logaritmu funkcie vierohodnosti dostaneme

$$l(\boldsymbol{\theta}|\mathbf{x}) = \sum_{j=1}^4 y_j \ln p_j = y_1 \ln(p^2) + y_2 \ln((q^2 + 2qp)^2) + y_3 \ln((r^2 + 2rp)^2) + y_4 \ln((2qr)^2), \text{ kde } p = 1 - q - r.$$

Odhady pravdepodobností výskytu alieli sú $\hat{q} = 0.239$, $\hat{r} = 0.114$ a $\hat{p} = g(\hat{\boldsymbol{\theta}}) = b + \mathbf{a}^T \hat{\boldsymbol{\theta}} = 1 - \hat{q} - \hat{r} = 0.648$ (čo sme mohli urobiť na základe invariantnosti odhadu), kde $\mathbf{a} = (-1, -1)^T$ a $b = 1$. Rozptyly parametrov \hat{q} a \hat{r} vypočítame z hesiánu, t.j. $\widehat{Var}[\hat{q}] = 0.0002$ a $\widehat{Var}[\hat{r}] = 0.0001$. $\widehat{Var}[\hat{p}] = \mathbf{a}^T (\mathcal{I}(\hat{\boldsymbol{\theta}}))^{-1} \mathbf{a} = 0.0003$. Vierohodnostnú 95% empirickú elipsu spoľahlivosti je možné vypočítať pomocou cut-off logaritmu štandardizovanej funkcie vierohodnosti v bode $\log(\exp(-\frac{1}{2}\chi_2^2(0.05))) = \log(0.05) = -2.995732$ (pozri obrázok 8.19).

Tabuľka 8.5: Pozorované početnosti a pravdepodobnosti a očakávané početnosti a pravdepodobnosti (vypočítané pomocou funkcie vierohodnosti) pre Prahu

krvné skupiny	0	A	B	AB
pozorované početnosti y_j	209	184	81	26
pozorované pravdepodobnosti y_j/N	0.4180	0.3680	0.1620	0.0520
očakávané početnosti Np_{0j}	210	183	80	27
očakávané pravdepodobnosti p_{0j}	0.4197	0.3661	0.1600	0.0542



Obr. 8.19: Logaritmus štandardizovanej funkcie vierohodnosti s maximum označeným \bullet a vierohodnostnou 95% empirickou elipsou spoľahlivosti pre $\boldsymbol{\theta}$

1. Hypotézy

- **slovná formulácia** – H_0 : početnosti výskytu krvných skupín sú v zhode s HW zákonom oproti H_1 : početnosti výskytu krvných skupín nie sú v zhode s HW zákonom.
- **matematická formulácia** – $H_0 : \mathbf{p} = \mathbf{p}_0$ oproti $H_1 : \mathbf{p} \neq \mathbf{p}_0$.

2. Testovacia štatistika – $\chi_{\text{obs}}^2 \doteq 0.065$.

```
1631 | chi . obs <- sum((poz . poc - oca . poc)^2 / oca . poc) # 0.06484433
```

3. Zamietacia oblasť – kritická hodnota $\chi_3^2(\alpha) = \chi_3^2(0.05) = 5.991$, potom $\mathcal{W} = (5.991, \infty)$.

```
1632 | qchisq(1 - 0.05, 3) # 7.814728
```

4. Štatistický záver – p-hodnota = 0.664. Keďže p-hodnota nie je menšia ako $\alpha = 0.05$ (ekvivalentne χ_{obs}^2 nepatrí zamietacej oblasti), H_0 nezamietame na hladine významnosti α .

```
1633 | 1 - pchisq(chi . obs, df = 3) # 0.9956928
```

5. Slovný záver – Nemáme dostatok dôkazov na zamietnutie nulovej hypotézy o tom, že početnosti výskytu krvných skupín sú v zhode s HW zákonom.

6. Antropologický záver – Empiricky zistené početnosti krvných skupín AB0 systému vo vzorke pražského obyvateľstva zodpovedajú teoretickým početnostiam vyplývajúcim z HW zákona a daného modelu dedičnosti (alely A a B kodominantné a alela 0 recesívna).

Testovanie na základe hlavných alel AB0 systému nemusí kompletne vyčerpať problematiku variability AB0 systému a rozdielov medzi populáciami vo frekvenciách krvných skupín tohoto systému, pretože alela A sa ďalej delí na imunitne odlišné formy A_1 a A_2 , čím vzniká šesť rôznych fenotypov (0, A_1 , A_2 , B, A_1B , A_2B), a ďalej existuje celý rad menej početných foriem alely A i B. Navyše je molekulárny podklad antigénov krvných skupín AB0 systému (oligosacharidov) prepojený s antigénmi krvných skupín systémov H a Lewis (Mielke a kol., 2011). V prípade štúdia adaptívnych vlastností AB0 systému (vzťah k mikrobiálnym patogénom) u rôznych populácií je potrebné vyššie uvedené vziať do úvahy a adekvátne tomu prispôbiť i štatistický model.

Test pomerom vierohodnosti o homogenite pravdepodobností z I binomických rozdelení.

Nech $Y_i \sim \text{Bin}(N_i, p_i)$, kde $\theta_i = p_i$. Označme $\boldsymbol{\theta} = \mathbf{p} = (p_1, p_2, \dots, p_I)^T$. Logaritmus vierohodnosti má tvar

$$l(\boldsymbol{\theta} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_I) = \ln \prod_{j=1}^I p_j^{y_j} (1 - p_j)^{N_j - y_j}.$$

MLE θ_i je rovný $\hat{\theta}_i = \hat{p}_i$, kde $\hat{p}_i = y_i / N_j$, t.j. $\Theta_1 = \{\boldsymbol{\theta} : p_i \neq p_j, i < j, i = 1, 2, \dots, I - 1; j = 2, 3, \dots, I\}$ pre aspoň jedno i a j . Za platnosti H_0 je $\boldsymbol{\theta}_0 = (\hat{p}, \hat{p}, \dots, \hat{p})^T$, kde $\hat{p} = \sum_{i=1}^I N_i p_i / \sum_{i=1}^I N_i$ a $\Theta_0 = \{\boldsymbol{\theta} : p_1 = p_2 = \dots = p_I = p\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_I)) &= l(\hat{\boldsymbol{\theta}} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_I) - l(\boldsymbol{\theta}_0 | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_I) = \sum_{i=1}^I y_i \ln \hat{p}_i \\ &+ \sum_{i=1}^I (N_i - y_i) \ln(1 - \hat{p}_i) - \sum_{i=1}^I y_i \ln \hat{p} - \sum_{i=1}^I (N_i - y_i) \ln(1 - \hat{p}) \\ &= \sum_{i=1}^I y_i \ln \frac{\hat{p}_i}{\hat{p}} + \sum_{i=1}^I (N_i - y_i) \ln \frac{1 - \hat{p}_i}{1 - \hat{p}}. \end{aligned}$$

Vieme, že testovacia štatistika pomerom vierohodnosti $U_{LR} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_I)) \stackrel{\mathcal{D}}{\sim} \chi_{I-1}^2$. Preznačme p_i na p_{i1} a $1 - p_i$ na p_{i2} . Ekvivalentne preznačíme y_i na y_{i1} , $N_i - y_i$ na y_{i2} .

Potom $\boldsymbol{\theta} = \mathbf{p} = (p_{11}, p_{12}, p_{21}, p_{22}, \dots, p_{I1}, p_{I2})^T$, $\hat{\boldsymbol{\theta}} = \hat{\mathbf{p}} = (\hat{p}_{11}, \hat{p}_{12}, \hat{p}_{21}, \hat{p}_{22}, \dots, \hat{p}_{I1}, \hat{p}_{I2})^T$ a $\boldsymbol{\theta}_0 = \mathbf{p}_0 = (p_{0,11}, p_{0,12}, p_{0,21}, p_{0,22}, \dots, p_{0,I1}, p_{0,I2})^T = (\hat{p}, 1 - \hat{p}, \hat{p}, 1 - \hat{p}, \dots, \hat{p}, 1 - \hat{p})^T$, kde $p_{i1} + p_{i2} = 1$, $y_{i1} + y_{i2} = N_i$ a $i = 1, 2, \dots, I$. Potom dostaneme

$$u_{LR} = 2 \sum_{i=1}^I \sum_{j=1}^2 y_{ij} \ln \frac{\hat{p}_{ij}}{p_{0,i}} = 2 \sum_{i=1}^I \sum_{j=1}^2 \text{pozorované}_{ij} \times \ln \frac{\text{pozorované}_{ij}}{\text{očakávané}_{ij}}.$$

Waldov a skóre test o homogenite pravdepodobností z I binomických rozdelení.

Tieto testy odvodíme podobne ako Waldov a skóre test v multinomickom rozdelení. Dostaneme

$$u_W = u_S = \sum_{i=1}^I \sum_{j=1}^2 \frac{(y_{ij} - N p_{0,ij})^2}{N p_{0,ij}} = \sum_{i=1}^I \sum_{j=1}^2 \frac{(\text{pozorované}_{ij} - \text{očakávané}_{ij})^2}{\text{očakávané}_{ij}}.$$

Vieme, že **Waldova a skóre testovacia štatistika** $U_W = U_S \stackrel{\mathcal{D}}{\sim} \chi_{I-1}^2$.

Príklad 270 (rovnosť I pravdepodobností) Ak $I = 2$, ktorej z testovacích štatistík Z_W alebo $Z_W^{(alt)}$ testu rozdielu pravdepodobností p_1 a p_2 z kapitoly 7.4 je rovná testovacia štatistika $U_W^{1/2}$?

Príklad 271 (rovnosť I pravdepodobností) Ukážte, že $u_W = \frac{1}{\hat{p}(1-\hat{p})} \left(\sum_{i=1}^I y_{ij} \hat{p}_i^2 - N \hat{p}^2 \right)$.

Príklad 272 (rovnosť I pravdepodobností) Majme dáta *more-samples-probabilities-pubis.txt* a premennú výskyt zmien kostného reliéfu (súčet početností premenných *trace.to.small* a *moderate.to.large*) u troch populácií žien. (a) Pomocou (1) χ^2 -testu dobrej zhody (Waldovho a skóre testu) a (2) testu pomerom vierohodnosti otestuje rovnosť v početnostiach žien s výskytom zmien kostného reliéfu u všetkých troch populácií. (b) Nakreslite stĺpcový diagram relatívnych početností absencie a výskytu zmien kostného reliéfu u žien (v %) pre všetky populácie.

Test pomerom vierohodnosti o homogenite dvoch vektorov pravdepodobností.

Nech $Y_i \sim \text{Mult}_J(N_i, \mathbf{p}_i)$, kde $i = 1, 2$, a $\boldsymbol{\theta}_i = \mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{iJ})^T$. Logaritmus jadra vierohodnosti má tvar

$$l(\boldsymbol{\theta} | \mathbf{y}_1, \mathbf{y}_2) = \ln \prod_{i=1}^2 \prod_{j=1}^J p_{ij}^{y_{ij}}.$$

MLE θ_{ij} je rovný $\hat{\theta}_{ij} = \hat{p}_{ij}$, kde $\hat{p}_{ij} = y_{ij}/N_i$, t.j. $\Theta_1 = \{\boldsymbol{\theta} : p_{1j} \neq p_{2j}, j = 1, 2, \dots, J\}$ pre aspoň jedno j . Za platnosti H_0 je $\boldsymbol{\theta}_0 = (\hat{p}_1, \hat{p}_2, \dots, \hat{p}_J, \hat{p}_1, \hat{p}_2, \dots, \hat{p}_J)^T$, kde $p_{0,ij} = \hat{p}_j = \sum_{i=1}^2 N_i p_{ij}/N$, kde $N = \sum_{i=1}^2 N_i$ a $\Theta_0 = \{\boldsymbol{\theta} : p_{1j} = p_{2j}, j = 1, 2, \dots, J\}$. Potom -1 krát prirodzený logaritmus pomeru vierohodnosti bude rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2)) &= l(\hat{\boldsymbol{\theta}} | \mathbf{y}_1, \mathbf{y}_2) - l(\boldsymbol{\theta}_0 | \mathbf{y}_1, \mathbf{y}_2) = \sum_{i=1}^2 \sum_{j=1}^J y_{ij} \ln \hat{p}_{ij} - \sum_{i=1}^2 \sum_{j=1}^J y_{ij} \ln \hat{p}_j \\ &= \sum_{i=1}^2 \sum_{j=1}^J y_{ij} \ln \frac{\hat{p}_{ij}}{\hat{p}_j}. \end{aligned}$$

Potom dostaneme

$$u_{LR} = 2 \sum_{i=1}^2 \sum_{j=1}^J y_{ij} \ln \frac{\hat{p}_{ij}}{p_{0,ij}} = 2 \sum_{i=1}^2 \sum_{j=1}^J \text{pozorované}_{ij} \times \ln \frac{\text{pozorované}_{ij}}{\text{očakávané}_{ij}}.$$

Vieme, že testovacia štatistika pomerom vierohodnosti $U_{LR} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2)) \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$.

Waldov a skóre test o homogenite dvoch vektorov pravdepodobností.


Tieto testy odvodíme podobne ako Waldov a skóre test v multinomickom rozdelení. Dostaneme

$$u_W = u_S = \sum_{i=1}^2 \sum_{j=1}^J \frac{(y_{ij} - Np_{0,ij})^2}{Np_{0,ij}} = \sum_{i=1}^2 \sum_{j=1}^J \frac{(\text{pozorované}_{ij} - \text{očakávané}_{ij})^2}{\text{očakávané}_{ij}}$$

Vieme, že Waldova a skóre testovacia štatistika $U_W = U_S \stackrel{\mathcal{D}}{\sim} \chi_{J-1}^2$.

Príklad 273 (homogenita dvoch vektorov pravdepodobností) *Majme dáta multinom-palmar-lines.txt pre 200 študentov (100 mužov a 100 žien), ktorí boli zaradení do troch kategórií podľa farby vlasov (LiH, MH, DaH) a súčasne do troch kategórií podľa zakončenia troch hlavných dlaňových línií (Hi, Mi, Lo). (a) Pomocou (1) χ^2 -testu dobrej zhody (Waldovho a skóre testu) a (2) testu pomerom vierohodnosti otestuje pre každú farbu vlasov zvlášť pohlavný dimorfizmus v početnostiach zakončení dlaňových línií. (b) Nakreslite stĺpcový diagram relatívnych početností zakončení dlaňových línií (v %) pre každú farbu vlasov.*

Riešenie (čiastočné; pozri obrázok 8.20)



Obr. 8.20: Stĺpcový diagram relatívnych početností zakončení dlaňových línií (v %) pre každú farbu vlasov.

9 Antropologické dátové subory

9.1 Dátový súbor – jednovýberový test o strednej hodnote

Hodnotený súbor: Z archívnych materiálov (Schmidt, 1888) máme k dispozícii pôvodné kranio-metrické údaje o dĺžke a šírke lebky zo starovekej egyptskej populácie (pozri obrázok 9.1). Súčasne máme k dispozícii priemerné hodnoty oboch rozmerov, hodnoty smerodajnej odchýlky a počty prípadov vzorky z novovekej egyptskej populácie (dĺžka lebky: $\bar{x}_m = 177.568$ mm, $\bar{x}_f = 171.962$ mm; $s_m = 7.526$ mm, $s_f = 7.052$ mm; $n_m = 88$, $n_f = 52$ a šírka lebky: $\bar{x}_m = 136.402$ mm, $\bar{x}_f = 131.038$ mm; $s_m = 6.411$ mm, $s_f = 5.361$ mm; $n_m = 87$, $n_f = 52$).

Súbor dát: one-sample-mean-skull-mf.txt

Popis premenných:

id – poradové číslo;

pop – populácie (egant – egyptská staroveká);

sex – pohlavie (m – muž, f – žena);

skull.L – najväčšia dĺžka mozgovne (mm), t.j. priama vzdialenosť kranio-metrických bodov *glabella* a *opisthocranium*;

skull.B – najväčšia šírka mozgovne (mm), t.j. vzdialenosť oboch kranio-metrických bodov *euryon*.

Biologické súvislosti: Výrazná zmena určitého biologického znaku v populácii po uplynutí dlhšieho časového obdobia sa označuje ako sekulárny trend (z latinského *saeculum* – generácia, vek, storočie). Brachycefalizácia, resp. debrachycefalizácia, t.j. relatívne skracovanie či predĺžovanie lebky je jedným z príkladov sekulárneho trendu. Tieto zmeny lebky/hlavy korelujú so zmenami kostí končatín a dávajú sa do súvislostí so zmenami vonkajších životných podmienok i genetického zloženia populácie. Napriek tomu, že pomer šírky a dĺžky lebky závisí od oboch rozmerov, ukazuje sa, že zmeny v tvare lebky ovplyvňujú predovšetkým zmeny v jej šírke.

Ciele:

(a) zistiť, či sa dĺžka lebky starovekej egyptskej populácie líši v strednej hodnote od novovekej egyptskej populácie (zvlášť u mužov a u žien);

(b) zistiť, či sa šírka lebky starovekej egyptskej populácie líši v strednej hodnote od novovekej egyptskej populácie (zvlášť u mužov a u žien).

9.2 Dátový súbor – párový test o strednej hodnote

Hodnotený súbor: Hodnotený súbor predstavujú osteometrické dáta, konkrétne hodnoty vertikálneho priemeru stredy dĺžky tela kľúčnej kosti (*clavicula*) z pohrebiska u Sv. Jakuba v Brne, prevažne z obdobia stredoveku. K dispozícii máme hodnoty rozmeru 40 vybraných jedincov na pravej aj ľavej strane tela z pôvodného merania (Živný, 2010) a z dvoch nových opakovaných meraní (Hupková, nepublikované dáta).

Súbor dát: paired-means-clavicle.txt


Popis premenných:

id – poradové číslo jedinca;

sex – pohlavie (M3 – veľmi pravdepodobne muž, M2 – pravdepodobne muž, M1 – skôr muž, I – indiferentný, F1 – skôr žena, F2 – pravdepodobne žena, F3 – veľmi pravdepodobne žena);

side – strana (R – pravá, L – ľavá);

simd – vertikálny priemer v strede dĺžky tela kľúčnej kosti (*superior-inferior midshaft diameter*), 1.



Obr. 9.1: Znáznorenie premenných najväčšia dĺžka mozgovne (skull.L) a najväčšia šírka mozgovne (skull.B)

meranie (mm) prvého výskumníka (pozri obrázok 9.2);


simd.1 – vertikálny priemer v strede dĺžky tela kľúčnej kosti (*superior-inferior midshaft diameter*), 1. meranie (mm) druhého výskumníka;

simd.2 – vertikálny priemer v strede dĺžky tela kľúčnej kosti, 2. meranie (mm) druhého výskumníka.

Biologické súvislosti: Stranové rozdiely v hrúbke tela kľúčnej kosti môžu odrážať rozdielne zaťažovanie každej zo strán. U malých rozmerov, ako je vertikálny priemer stredu tela kľúčnej kosti, môže hrať významnú úlohu skreslenie skutočnej hodnoty rozmeru vplyvom chyby merania (interindividuálna chyba – viac výskumníkov a intraindividuálna chyba – jeden výskumník, systematická chyba – správnosť merania a náhodná chyba – presnosť merania). Keďže chyba merania môže výrazne ovplyvniť hodnotenie subtilných biologických trendov, ako sú napr. stranové rozdiely ((a)symetria), je veľmi dôležité (ešte pred samotnými analýzami stranových rozdielov) chybu merania kvantifikovať.

Ciele:

- zistiť, či je stredná hodnota vertikálneho priemeru stredu tela kľúčnej kosti prvého a druhého merania zhodná, t.j. zhodnotiť intraindividuálnu chybu merania;
- vypočítať (1) technickú chybu merania, (2) relatívnu technickú chybu merania a (3) koeficient reliability merania (pozri kap. 6.1)
- zistiť, či sa stredná hodnota priemeru prvého (*simd.1*) a druhého opakovaného merania (*simd.2*) líši od strednej hodnoty prvého merania (*simd*), t. j. zhodnotiť interindividuálnu chybu merania;
- zistiť, či je kľúčna kosť v mieste vertikálneho priemeru stredu diaľčy na pravej strane tela vyvinutá inak než na strane ľavej, t.j. či existuje systematická stranová asymetria;
- overiť, či je stredná hodnota stranového rozdielu u oboch pozorovateľov zhodná.



Obr. 9.2: Znáznorenie premennej vertikálny priemer v strede dĺžky tela kľúčnej kosti (simd)

9.3 Dátový súbor – párový test o strednej hodnote

Hodnotený súbor: Hodnotený súbor predstavujú osteometrické dáta kľúčnej kosti (*clavicula*) anglického súboru dokumentovaných skeletov (Parsons, 1916). Konkrétne ide o dĺžku kľúčnej kosti z pravej a ľavej strany tela (pozri obrázok 9.3) v párovom usporiadaní. Jednotlivé kosti bez druhostrannej kosti neboli do súboru zaradené.

Súbor dát: paired-means-clavicle2.txt


Popis premenných:

id – poradové číslo jedinca;
sex – pohlavie (m – muž, f – žena);
length.R – dĺžka kosti z pravej strany (mm);
length.L – dĺžka kosti z ľavej strany (mm).

Biologické súvislosti: V prípade kľúčnej kosti sa ukazuje, že kosť z ľavej strany je v priemere tenšia a súčasne dlhšia než kosť z pravej strany. Rozdiel pravdepodobne vzniká v dôsledku odlišnej doby ukončenia rastu oboch strán v priebehu dospievania (ľavá kosť väčšinou rastie dlhšie; Mays a kol. (1999)) v kombinácii s odlišným zaťažením oboch strán v priebehu života.

Ciele:

(a) zistiť (pre každé pohlavie zvlášť), či je dĺžka kľúčnej kosti na ľavej strane tela dlhšia než na strane pravej.



Obr. 9.3: Znáznornenie premennej dĺžka kosti kľúčnej z ľavej strany (length.L)

9.4 Dátový súbor – jednovýberový test o rozptyle

Hodnotený súbor: Z archívnych materiálov (Schmidt, 1888) máme k dispozícii pôvodné kranio-metrické údaje o dĺžke lebky zo starovekej egyptskej populácie. Súčasne máme k dispozícii priemerné hodnoty oboch rozmerov, hodnoty smerodajnej odchýlky a počty prípadov vzorky z novovekej egyptskej populácie (dĺžka lebky: $\bar{x}_m = 177.568$ mm, $\bar{x}_f = 171.962$ mm; $s_m = 7.526$ mm, $s_f = 7.052$ mm; $n_m = 88$, $n_f = 52$ a šírka lebky: $\bar{x}_m = 136.402$ mm, $\bar{x}_f = 131.038$ mm; $s_m = 6.411$ mm, $s_f = 5.361$ mm; $n_m = 87$, $n_f = 52$).

Súbor dát: one-sample-variance-skull-mf.txt

Popis premenných:

id – poradové číslo;
pop – populácie (egant – egyptská staroveká);
sex – pohlavie (m – muž, f – žena);
skull.L – najväčšia dĺžka mozgovne (mm), t.j. priama vzdialenosť kranio-metrických bodov *glabella* a *opisthocranium* (pozri obrázok 9.1);
skull.B – najväčšia šírka mozgovne (mm), t.j. vzdialenosť oboch kranio-metrických bodov *euryon* (pozri obrázok 9.1).

Biologické súvislosti: Nezamietnutie zhody rozptylov dvoch porovnávaných súborov môže znamenať podobné biologické vlastnosti alebo obdobné vzorkovanie (výber vzorky z populácie).

Ciele:

- (a) zistiť, či sa dĺžka lebky starovekej egyptskej populácie líši v rozptyle od novovekej egyptskej populácie (zvlášť u mužov a u žien).
 (b) zistiť, či sa šírka lebky starovekej egyptskej populácie líši v rozptyle od novovekej egyptskej populácie (zvlášť u mužov a u žien).

9.5 Dátový súbor – jednovýberový test o korelačnom koeficiente

Hodnotený súbor: Vo vyššie uvedenom súbore (Schmidt, 1888) starovekej egyptskej populácie ďalej sledujeme súvislosti dvoch rozmerov tvárovej časti lebky (*splanchnocranium*) a mozgovej časti lebky (*neurocranium*); pozri obrázok 9.4. Súčasne máme k dispozícii hodnoty korelačného koeficientu medzi oboma rozmermi a údaje o počtoch prípadov zo vzorky novovekej egyptskej populácie ($r_m = 0.251$, $r_f = 0.144$; $n_m = 30$, $n_f = 19$).

Súbor dát: one-sample-correlation-skull-mf.txt

Popis premenných:

id – poradové číslo;

pop – populácie (egant – egyptská staroveká);

sex – pohlavie (m – muž, f – žena);


skull.pH – najväčšia výška mozgovne, projekčná vzdialenosť najvyššieho bodu mozgovne k najnižšiemu bodu lebečnej bázy v strednej rovine, kolmá na najväčšiu dĺžku mozgovne (mm);

face.H – morfologická výška tváre, vzdialenosť bodu *nasion* a *gnathion* (mm).

Biologické súvislosti: Rozmery oboch hlavných častí lebky sú počas vývinu riadené inými faktormi. Rast mozgovej časti lebky je spojený s rastom mozgu a prebieha predovšetkým v prvých siedmich či ôsmich rokoch po narodení, potom už rastie len málo. Intenzívny rast tvárovej časti lebky pokračuje aj v priebehu puberty a adolescencie. Napriek tomu spolu obe časti tvoria komplexný funkčný celok (Lieberman, 2011).

Ciele:

- (a) zistiť, či výška mozgovej časti lebky súvisí s výškou tvárovej časti lebky (zvlášť u mužov a žien);
 (b) porovnať, či je v tejto súvislosti rozdiel medzi starovekou a novovekou egyptskou populáciou.



Obr. 9.4: Znáozornenie premenných najväčšia výška mozgovne (skull.pH) a morfologická výška tváre (face.H)

9.6 Dátový súbor – jednovýberový test o lineárno-uhlovom korelačnom koeficiente

Hodnotený súbor: Máme k dispozícii hodnoty troch lineárnych rozmerov a jedného uhla popisujúce výšku a šírku lebky a lebečnej bázy (pozri obrázok 9.5) vypočítané z pôvodných x , y a z súradníc štyroch význačných bodov (*bregma*, *basion*, *porion dx* a *porion sin*) digitalizovaných na 60 vybraných lebkách dospelých jedincov (40 mužov a 20 žien) z kostrovej zbierky z archeologickej lokality Pohansko – Pohřebiště okolo kostela (Jurda, 2008).

Súbor dát: lin-uhl-fm.txt

Popis premenných:

id – poradové číslo;

sex – pohlavie (m – muž, f – žena);

skull.H – výška lebky, vzdialenosť bodov *basion* a *bregma* (mm);

base.H – výška lebečnej bázy, minimálna vzdialenosť bodu *basion* k spojnici pravostranného a ľavostranného bodu *porion* (mm);

base.B – šírka lebečnej bázy na spojnici oboch bodov *porion* (mm);

base.A – uhol, ktorý zvierajú línie prechádzajúce bodom *basion* a pravostranným a ľavostranným bodom *porion* (stupne).

Biologické súvislosti: Sploštenie lebečnej bázy (*platybázia*) je jedným zo znakov používaných v bio-archeologických štúdiách ako indikátor stresu a horších životných podmienok pri rekonštruovaní a hodnotení životných podmienok minulých populácií. Výška lebečnej bázy je u ľudí trpiacich v priebehu vývinu nutričným stresom nižšia než u ľudí, ktorí boli nutričnému stresu vystavení v menšej miere. Podľa práce Angel (1982) ide o dôsledok deformácie nedostatočne nutrične zásobených kostí lebečnej bázy pod hmotnosťou vyššie položených oblastí hlavy a mozgu. Larsen (1997, 19–20) ale uvádza, že chrupavkové elementy lebečnej bázy majú vnútornú rastovú kapacitu dostatočne odolnú voči tlaku a uvedené vysvetlenie splošťovania bázy v dôsledku nutričného stresu nepovažuje za dostatočné.

Ciele:

(a) zistiť, či veľkosť uhla, ktorý zvierajú línia prechádzajúca bodom *basion* a pravostranným bodom *porion* s líniou prechádzajúcou bodom *basion* a ľavostranným bodom *porion* súvisí s niektorým zo sledovaných rozmerov na lebke (zvlášť u mužov a u žien);

(b) zistiť, či sa zistené závislosti líšia u mužov a u žien;

(c) zistiť, či veľkosť tohto uhla súvisí viac s výškou alebo šírkou bázy; ak s výškou bázy, zistiť, ako veľmi súvisí výška bázy s *basion*-*bregmatickou* výškou lebky.

9.7 Dátový súbor – jednovýberový test o uhlovom korelačnom koeficiente

Hodnotený súbor: Máme k dispozícii číselné hodnoty dvoch uhlov na lebke (pozri obrázok 9.6) vypočítané z pôvodných x , y a z súradníc štyroch význačných bodov (*bregma*, *basion*, *nasion* a *prosthion*) digitalizovaných na 60 vybraných lebkách dospelých jedincov (40 mužov a 20 žien) z kostrovej zbierky z archeologickej lokality Pohansko – Pohřebiště okolo kostela (Jurda, 2008).

Súbor dát: uhl-uhl-fm.txt

Popis premenných:


id – poradové číslo;

sex – pohlavie (m – muž, f – žena);

front.A – uhol v bode *nasion*; uhol, ktorý zvierajú línie prechádzajúce bodmi *bregma* a *nasion* s líniou prechádzajúcou bodmi *nasion* a *basion* (stupne);

prog.A – uhol tvárového trojuholníka v bode *prosthion*; uhol, ktorý zvierajú línie prechádzajúce bodmi *basion* a *prosthion* s líniou prechádzajúcou bodmi *prosthion* a *nasion* (stupne).

Biologické súvislosti: Uhol *nasion* popisuje oblasť predného neurokrania, uhol tvárového trojuholníka v *prosthion* vyjadruje stupeň alveolárneho prognatizmu hornej čeľuste a stupeň vývoja hornej časti



Obr. 9.5: Znáznorenie premenných výška lebky (*skull.H*), výška lebečnej bázy (*base.H*), šírka lebečnej bázy (*base.B*) a uhol, ktorý zvierajú línie prechádzajúce oboma bodmi *porion* s vrcholom v bode *basion* (*base.A*)

splanchnokrania. I keď mozgová (*neurocranium*) a tvárová (*splanchnocranium*) časť lebky spolu tvoria komplexný funkčný celok, počas vývinu sú riadené inými faktormi (Lieberman, 2011).

Ciele:

- zistiť, či súvisí veľkosť uhla nasia s veľkosťou uhla tvárového trojuholníka v prosthiu (zvlášť u mužov a u žien);
- zistiť, či sa zistená závislosť líši u mužov a u žien.

9.8 Dátový súbor – jednovýberový test o pravdepodobnosti

Hodnotený súbor: Sekundárny pomer pohlaví (šanca narodenia chlapca; anglicky *secondary sex ratio, odds ratio*) je pomer počtu novorodencov mužského pohlavia a počtu novorodencov ženského pohlavia. V priemere sa udáva hodnota 1.06 pre Českú republiku a 1.05 pre celosvetovú populáciu (Cheng a kol., 2007); sumárny údaj pre 220 národov z celého sveta). V priebehu jedného roka sa v krajskej nemocnici narodilo 729 chlapcov a 674 dievčat (Alánová, 2008).

Súbor dát: one-sample-probability-sexratio.txt


Popis premenných:

sex – pohlavie novorodenca (m – mužské, f – ženské).

Biologické súvislosti: Je známe, že v ľudských populáciách je sekundárny pomer pohlaví systematicky vychýlený v prospech chlapcov. Nerovná sa teda presne jednej (1.00), ako by to vyplývalo z princípu genetického určenia pohlavia pomocou pohlavných chromozómov. O príčinách a mechanizme vychýlenia sekundárneho pomeru pohlaví, rovnako ako o význame medzi populačných rozdielov v pomere pohlaví sa diskutuje (James, 2006, 2008).

Ciele:

- testovať, či sa pomer pohlaví líši od vyrovnaného pomeru (1.00);
- či sa pomer pohlaví líši od celosvetového priemeru (1.05);
- či sa pomer pohlaví líši od tabelového priemeru pre Českú republiku (1.06).



Obr. 9.6: Znáznornenie premenných uhol v bode *nasion* (*front.A*) a uhol tvárového trojuholníka v bode *prosthion* (*prog.A*)

9.9 Dátový súbor – jednovýberový test o pravdepodobnosti

Hodnotený súbor: Na základe publikovanej štúdie (Hauser, De Stefano a kol., 1989, str. 42–43) máme k dispozícii údaje o frekvencii výskytu epigenetického znaku *sutura metopica* (binárny znak) na lebkách Ainov z ostrova Hokkaido – v súbore 184 lebiek bol metopizmus zaznamenaný v 3.3 % prípadov. Súčasne máme k dispozícii percentuálne zastúpenie *sutura metopica* v japonskej populácii, ktorá dnes v Japonsku prevláda – metopizmus bol zaznamenaný v súbore 241 lebiek v 9.1 % prípadov (Mouri, 1976; Hauser, De Stefano a kol., 1989, str. 42–43).

Súbor dát: one-sample-probability-met.txt

Popis premenných:

origin – pôvod jedincov kostrového súboru (Ain – Ainovia, Jap – japonská populácia);

n – počet jedincov v jednotlivých súboroch;

met – počet jedincov s výskytom *sutura metopica*.

Biologické súvislosti: *Sutura metopica* (metopizmus) je epigenetický znak. Predstavuje v dospelosti perzistujúci šev (*sutura interfrontalis*) uprostred čelovej kosti, ktorý v priebehu ontogenézy oddeľuje jej pravú a ľavú časť a normálne sa uzatvára asi do dvoch rokov postnatálneho vývinu. Funkčne môže pretrvávanie švu spôsobovať dlhší rast čelovej kosti do šírky. Podľa niektorých štúdií majú lebky s metopizmom dlhšie transverzálne rozmery (Hauser, De Stefano a kol., 1989, str. 41). Na výskyte sa podieľa v určitej miere dedičnosť a medzi rôznymi populáciami existujú odlišnosti vo frekvencii tohoto znaku (od 0 do 16 %). Ainovia, najstarší obyvatelia severnej oblasti japonských ostrovov, ktorých pôvod je dodnes predmetom výskumu, predstavujú subpopuláciu v mnohých znkoch odlišnú od majoritnej japonskej populácie.

Ciele:

(a) zistiť, či sa či sa frekvencia výskytu *sutura metopica* u Ainov líši od frekvencie v prevládajúcej japonskej populácii.

9.10 Dátový súbor – dvojjvýberový test o rozdiel stredných hodnôt

Hodnotený súbor: Máme k dispozícii údaje o pôrodnej hmotnosti prvorođených a druhođených chlapcov, novorodencov narodených v krajskej nemocnici v priebehu jedného roka (Alánová, 2008).

Novorodencov narodených vo vyššom poradí sme z tohto porovnania vylúčili.

Súbor dát: two-samples-means-birth.txt

Popis premenných:

o.sib.N – počet starších súrodencov (0 – žiadny, 1 – jeden);
birth.W – pôrodná hmotnosť (g).

Biologické súvislosti: Z niektorých štúdií vyplýva, že medzi prvorodenými a druhorodenými novorodencami môžu byť rozdiely v pôrodnej hmotnosti. Prvorodení by potom mali mať nižšiu pôrodnú hmotnosť než deti narodené ako druhé v poradí (Seidman a kol., 1988; Swamy a kol., 2012).

Ciele:

(a) zistiť, či sa pôrodná hmotnosť prvorodených a druhorodených chlapcov z jednej pôrodnice a sezóny v priemere líši.

9.11 Dátový súbor – dvojitýberový test o rozdieloch stredných hodnôt

Hodnotený súbor: Z archívnych materiálov (Schmidt, 1888) máme k dispozícii pôvodné kranio-metrické údaje 215 dospelých mužov a 107 dospelých žien zo starovekej egyptskej populácie o basion–bregmatickej výške lebky (pozri obrázok 9.7). Súčasne máme k dispozícii priemerné hodnoty basion–bregmatickej výšky ($\bar{x}_m = 133.977$ mm; $\bar{x}_f = 126.942$ mm), hodnoty smerodajnej odchýlky ($s_m = 5.171$ mm; $s_f = 4.430$ mm) a počty prípadov ($n_m = 87$, $n_f = 52$) vzorky z novovekej egyptskej populácie.

Súbor dát: two-samples-means-skull.txt

Popis premenných:

id – poradové číslo;
pop – populácie (egant – egyptská staroveká);
sex – pohlavie (m – muž, f – žena);
skull.H – výška lebky, vzdialenosť bodov *basion* a *bregma* (mm).

Biologické súvislosti: Rozdiely medzi dospelými mužmi a ženami vo veľkosti lebky bývajú v ľudských populáciách systematicky posunuté v prospech mužov (väčšie hodnoty u mužov), i keď väčšinou nedosahujú takej miery ako v puberte a adolescencii výrazne rozvinutý dimorfizmus rozmerov postkraniálneho skeletu (Dadejová a kol., 2011). Miera dimorfizmu môže tiež kolísať medzi populáciami, pričom zmeny/rozdiely môžu byť spôsobené zmenami u jedného, druhého alebo oboch pohlaví.

Ciele:

(a) vyjadriť mieru medzipohlavných rozdielov pomocou **indexu sexuálneho dimorfizmu**


$$ISD = \frac{\bar{x}_m - \bar{x}_f}{\bar{x}_m};$$

(b) zistiť, či sa stredné hodnoty basion–bregmatickej výšky lebky u mužov a u žien líšia;

(c) zistiť, či sa líšia stredné hodnoty basion–bregmatickej výšky starovekej od stredných hodnôt novovekej, zvlášť u mužov a zvlášť u žien.

9.12 Dátový súbor – dvojitýberový test o podiele rozptylov

Hodnotený súbor: Z archívnych materiálov (Schmidt, 1888) máme k dispozícii pôvodné kranio-metrické údaje 215 dospelých mužov a 107 dospelých žien zo starovekej egyptskej populácie o basion–bregmatickej výške lebky (pozri obrázok 9.7). Súčasne máme k dispozícii priemerné hodnoty ($\bar{x}_m = 133.977$ mm; $\bar{x}_f = 126.942$ mm), hodnoty smerodajnej odchýlky ($s_m = 5.171$ mm; $s_f = 4.430$ mm) a počty prípadov ($n_m = 87$, $n_f = 52$) tohto znaku u vzorky z novovekej egyptskej populácie.



Obr. 9.7: Znáornenie premennej výška lebky (skull.H)

Súbor dát: two-samples-variances-skull.txt

Popis premenných:

id – poradové číslo;

pop – populácie (egant – egyptská staroveká);

sex – pohlavie (m – muž, f – žena);

skull.H – výška lebky, vzdialenosť bodov *basion* a *bregma* (mm).

Biologické súvislosti: Rozdiel v rozptyle rovnakého znaku v dvoch populáciách môže znamenať odlišnosť vo variabilite alebo odlišnosti v spôsobe výberu subjektov.

Ciele:

- (a) zistiť, či sa muži a ženy zo starovekej egyptskej populácie líšia v rozptyle výšky lebky;
- (b) zistiť, či sa muži a ženy z novovekej egyptskej populácie líšia v rozptyle výšky lebky;
- (c) zistiť, či sa muži zo starovekej a novovekej egyptskej populácie líšia v rozptyle výšky lebky;
- (d) zistiť, či sa ženy zo starovekej a novovekej egyptskej populácie líšia v rozptyle výšky lebky.

9.13 Dátový súbor – dvojvýberový test o rozdiel korelačných koeficientov

Hodnotený súbor: Máme k dispozícii súbor hodnôt dĺžky trupu (rozdiel akromiálnej a spinálnej výšky tela) a dĺžky dolnej končatiny (spinálna výška tela) mladých dospelých jedincov (pozri obrázok 9.8; zdroj ¹), prevažne študentov vysokých škôl z Brna a Ostravy (Kráľík, nepublikované dáta).

Súbor dát: two-samples-correlations-trunk.txt

Popis premenných:

sex – pohlavie (m – muž, f – žena);

lowex.L – dĺžka dolnej končatiny (mm);

tru.L – dĺžka trupu (mm).


Biologické súvislosti: Rozmery trupu sú u žien priestorovo zásadné z hľadiska tehotenstva a miesta pre rastúci plod. Muži takéto obmedzenia nemajú. Preto napríklad u žien prevláda dýchanie hrudné,

¹Atlas somatoskopických znakov človeka (<http://www.sci.muni.cz/somatoskopie>), upravené

zatiaľ čo u mužov brušné. So zväčšujúcou sa veľkosťou tela v priebehu rastu v puberte a adolescencii by preto mala u dospelých žien narastať úmernejšie aj veľkosť trupu. U mužov by tendencia nemusela byť tak silná. Možno teda predpokladať, že závislosť veľkosti oboch častí tela bude u žien silnejšia než u mužov.

Ciele:

- (a) zistiť, či u mladých dospelých ľudí, bez ohľadu na pohlavie, súvisí dĺžka dolnej končatiny s dĺžkou trupu;
- (b) zistiť, či sa ženy a muži v miere tejto závislosti líšia.



Obr. 9.8: Znáročnenie premenných dĺžka dolnej končatiny (lowex.L) a dĺžka trupu (tru.L)

9.14 Dátový súbor – dvojjvýberový test o rozdiel pravdepodobností

Hodnotený súbor: Máme k dispozícii údaje o počte prvorođených a druhorodených chlapcov a dievčat, novorodencoch narodených v krajskej nemocnici v priebehu jedného roka (Alánová, 2008). Novorodencov narodených vo vyššom poradí sme z tohto porovnanja vylúčili.

Súbor dát: two-samples-probabilities-sexratio.txt

Popis premenných:

sex – pohlavie novorodenca (m – mužské, f – ženské);
o.sib.N – počet starších súrodencov (0 – žiadny, 1 – jeden).

Biologické súvislosti: Sekundárny pomer pohlaví je u človeka systematicky vychýlený v prospech chlapcov. Podľa niektorých evolučných teórií nie je pohlavie potomkov u vtákov a cicavcov náhodné, pretože naň nenáhodne vplýva prostredie a pohlavie predchádzajúcich potomkov regulujúce reprodukčnú úspešnosť rodičov. U človeka niektoré štúdie zaznamenali súvislosti sekundárneho pomeru pohlaví s paritou (Juntunen a kol., 1997), iné však nie (Almagor a kol., 1998).

Ciele:

- (a) zistiť, či je podiel chlapcov a dievčat u skupiny prvorođených a druhorodených detí odlišný.

9.15 Dátový súbor – viacvýberový test o stredných hodnotách, nominálna premenná

Hodnotený súbor: Z archívnych materiálov (Schmidt, 1888) máme k dispozícii pôvodné kranio-metrické údaje o výške hornej časti tváre mužov (pozri obrázok 9.9) z piatich populácií – nemeckej (19 jedincov), malajskej (69 jedincov), čínskej (18 jedincov), peruánskej (44 jedincov) a bantuskej (13 jedincov).

Súbor dát: anova-means-skull.txt

Popis premenných:

id – poradové číslo;

pop – populácie (nem – nemecká, mal – malajská, cin – čínska, per – peruánska, ban – bantuská);


sex – pohlavie (m – muž);

upface.H – výška hornej časti tváre, priama vzdialenosť medzi bodmi *nasion* a *prosthion* (mm).

Biologické súvislosti: Výška hornej časti tváre je jedným z rozmerov, ktoré sa uplatňujú pri hodnotení populačnej afinity (odhade etnickej príslušnosti) vo forenzných aplikáciách, kde sa obvykle rozlišujú tri hlavné kategórie – kaukazoidná, negroidná a mongoloidná. I keď hlavným ukazovateľom populačnej afinity na lebke sú jej morfológické rysy a nie metrické znaky, môžeme vo všeobecnosti povedať, že pre kaukazoidný fenotyp je charakteristická stredná až vysoká a často široká lebka s rôzne širokou a stredne vysokou tvárou; pre negroidný fenotyp dlhá, úzka a nízka lebka s širokou a nízkou tvárou; a pre mongoloidný fenotyp zas dlhá, široká a stredne vysoká lebka s veľmi širokou a vysokou tvárou.

Ciele:

- zistiť, či sú u mužov zo sledovaných populácií rozdiely v strednej hodnote výšky hornej časti tváre;
- zistiť, či prípadné rozdiely odpovedajú tradične uvádzaným rozdielom (najnižšia tvár u negroidných populácií, stredne vysoká u kaukazoidných populácií a vysoká u mongoloidných populácií).



Obr. 9.9: Znáznorenie premennej výška hornej časti tváre (upface.H)

9.16 Dátový súbor – viacvýberový test o stredných hodnotách, nominálna premenná

Hodnotený súbor: Máme k dispozícii antropometrické údaje mladých dospelých ľudí, prevažne študentov vysokých škôl z Brna a Ostravy (Králík, nepublikované dáta), konkrétne údaje o rozme-

roch hlavy (pozri obrázok 9.10; zdroj²), a súčasne zaradenie prípadov do kategórií podľa pohlavia, sexuálnej orientácie a počtu vlastných súrodencov.

Súbor dát: anova-head.txt

Popis premenných:

sex – pohlavie (m – muž, f – žena);

sexor – sexuálna orientácia (op – výlučne na opačné pohlavie, sa – ostatné, t.j. iné než výlučne na opačné pohlavie (bisexuálna, homosexuálna));

obra – existencia staršieho biologického brata (yes – jedinec má staršieho brata, no – jedinec nemá staršieho brata);

body.H – výška postavy (mm);

head.L – dĺžka hlavy, vzdialenosť medzi bodmi *glabella* a *opisthocranium* (mm);

head.W – šírka hlavy, vzdialenosť oboch bodov *euryon* (mm);

bigo.W – šírka dolnej čeľuste, vzdialenosť oboch bodov *gonion* (mm);

bizyg.W – šírka tváre, vzdialenosť oboch bodov *zygion* (mm).


Biologické súvislosti: Pohlavia sa obvykle líšia celým radom telesných rozmerov. Okrem niektorých reprodukčne významných rozmerov v oblasti panvy majú ženy obvykle väčšinu rozmerov menšiu než muži odpovedajúceho veku z rovnakej populácie. Je však známe, že modifikujúci vplyv na tie isté rozmery má celý rad ďalších faktorov, napríklad sexuálna orientácia, poradie narodenia, počet starších súrodencov atď. (i keď sa v miere vplyvu týchto modifikujúcich faktorov rôzne štúdie líšia).

Ciele:

(a) zistiť, či sú jednotlivé rozmery hlavy sexuálne dimorfné, t.j. či sa stredné hodnoty jednotlivých rozmerov medzi mužmi a ženami líšia;

(b) zistiť, či existuje vplyv pohlavia na jednotlivé rozmery hlavy modifikovaný vplyvom sexuálnej orientácie;

(c) zistiť, či existuje vplyv pohlavia na jednotlivé rozmery hlavy modifikovaný vplyvom existencie biologického staršieho brata.



Obr. 9.10: Znáozornenie premenných dĺžka hlavy (*head.L*), šírka hlavy (*head.W*), šírka dolnej čeľuste (*bigo.W*) a šírka tváre *bizyg.W*

²Atlas somatoskopických znakov človeka (<http://www.sci.muni.cz/somatoskopie>), upravené

9.17 Dátový súbor – viacvýberový test o stredných hodnotách, ordinálna premenná

Hodnotený súbor: Máme k dispozícii dáta o pôrodnej hmotnosti v súbore novorodencov z okresnej nemocnice za jeden rok a súčasne údaje o parite matiek (poradie narodenia jednotlivých novorodencov) a vzdelaní matiek (Alánová, 2008).

Súbor dát: anova-newborns.txt

Popis premenných:

edu.M – vzdelanie matky (1 – základné, 2 – stredné bez maturity, 3 – stredné s maturitou, 4 – vysokoškolské);

prch.N – počet predchádzajúcich detí biologickej matky hodnoteného jedinca (hodnoty od 0 po 8, sledujeme však iba tri kategórie: 1 – prvorodené, 2 – druhorodené a 3 – spoločne deti narodené v treťom a ďalšom poradí);

sex.C – pohlavie hodnoteného dieťaťa (m – mužské, f – ženské);

weight.C – pôrodná hmotnosť hodnoteného dieťaťa (g).

Biologické súvislosti: Hmotnosť novorodenca je dôležitý údaj z hľadiska perspektívy jeho ďalšieho vývinu. Závisí na celom rade faktorov, modifikujúci vplyv môže mať napr. parita a vzdelanie matky.

Ciele:

- zistiť, či závisí pôrodná hmotnosť chlapca na poradí, v ktorom sa biologickej matke narodilo;
- zistiť, či súvisí pôrodná hmotnosť chlapca so vzdelaním matky;
- zistiť, či závisí pôrodná hmotnosť dievčaťa na poradí, v ktorom sa biologickej matke narodilo;
- zistiť, či súvisí pôrodná hmotnosť dievčaťa so vzdelaním matky.

9.18 Dátový súbor – viacvýberový test o rozptyloch

Hodnotený súbor: Máme k dispozícii osteometrické dáta o dĺžke kľúčnej kosti (*clavicula*) z pravej strany u štyroch súborov – výberov zo štyroch rôznych populácií: anglickej, dvoch indických a gréckej (pozri obrázok 9.11).

Súbor dát: more-samples-variances-clavicle.txt

Popis premenných:

population – populácia, z ktorej kostrový súbor pochádza: eng – anglická populácia (dáta Parsons, 1916), ind1 – indická populácia z Amritsaru (dáta Jit a Singh, 1966), ind2 – indická populácia z Varanasi (dáta Singh a Gangrade, 1968), gre – grécka populácia z Atén (dáta Králík a kol., 2014);


sex – pohlavie (m – muž);

cla.L – najväčšia dĺžka kosti kľúčnej z pravej strany (mm).

Biologické súvislosti: Osteologické vzorky porovnávaných kostí kľúčnych vznikali v rôznych obdobiach a predstavujú rôznym spôsobom vybraných jedincov z rôzne rozsiahlych populácií. Je preto možné, že sa súbory budú líšiť svojim rozptylom.

Ciele:

- zistiť, či sa štyri porovnávané populácie líšia v rozptyloch dĺžky kľúčnej kosti z pravej strany.



Obr. 9.11: Znáznornenie premennej najväčšia dĺžka kosti kľúčnej z pravej strany (cla.L)

9.19 Dátový súbor – viacvýberový test o korelačných koeficientoch

Hodnotený súbor: Vo vyššie uvedenom súbore (Schmidt, 1888) mužov z piatich rôznych populácií – nemeckej (20 jedincov), malajskej (73 jedincov), čínskej (19 jedincov), peruánskej (46 jedincov) a bantuskej (14 jedincov) – sledujeme súvislosti medzi rozmermi tvárovej časti lebky (*splanchnocranium*), konkrétne medzi výškou a šírkou nosa a medzi šírkou nosa a interorbitálnou šírkou (pozri obrázok 9.12).

Súbor dát: more-samples-correlations-skull.txt

Popis premenných:

id – poradové číslo;

pop – populácie (nem – nemecká, mal – malajská, cin – čínska, per – peruánska, ban – bantuská);

sex – pohlavie (m – muž);

nose.H – výška nosa, t.j. priama vzdialenosť medzi bodom *nasion* a najnižším bodom *apertura piriformis* (mm);


nose.B – šírka nosa, t.j. najväčšia šírka *apertura piriformis*, medzi pravým a ľavým bodom *apertion* (mm);

interorb.B – interorbitálna šírka odpovedajúca priamej vzdialenosti medzi pravým a ľavým bodom *dakryon* (mm).

Biologické súvislosti: Výška a šírka nosa a interorbitálna šírka patria medzi rozmery, ktoré sa uplatňujú pri hodnotení populačnej afinity (odhade etnickej príslušnosti) vo forenzných aplikáciách, kde sa obvykle odlišujú tri hlavné kategórie – kaukazoidná, negroidná a mongoloidná. I keď hlavným ukazovateľom populačnej afinity na lebke sú jej morfológické rysy a nie metrické znaky, vo všeobecnosti možno povedať, že pre kaukazoidný fenotyp je charakteristický vysoký a úzky nosný otvor; pre negroidný fenotyp široký a nízky nosný otvor a široká interorbitálna oblasť; a pre mongoloidný fenotyp široký nosný otvor.

Ciele:

- zistiť, či u jednotlivých skupín súvisí výška so šírkou nosa;
- zistiť, či u jednotlivých skupín súvisí interorbitálna šírka so šírkou nosa;
- zistiť, či sa sledované populácie v miere týchto súvislostí líšia.



Obr. 9.12: Znázornenie premenných výška nosa (nose.H), šírka nosa (nose.B) a interorbitálna šírka (interorb.B)

9.20 Dátový súbor – viacvýberový test o pravdepodobnostiach

Hodnotený súbor: Na základe publikovanej štúdie (Stewart, 1970) máme k dispozícii údaje o frekvencii výskytu troch stupňov zmien kostného reliéfu na vnútornej strane lonovej kosti (*os pubis*) v blízkosti lonovej spony (*symphysis pubica*) u žien z troch kostrových súborov: európskeho pôvodu, afrického pôvodu a Inuitov (pozri obrázok 9.13). Súčasne máme k dispozícii počty jedincov každého z týchto troch súborov.

Súbor dát: more-samples-probabilities-pubis.txt

origin	absence	trace.to.small	moderate.to.large	number.of.cases
European	30	20	10	60
African	56	37	17	110
Inuits	16	6	13	35

Popis premenných:

origin – pôvod jedincov kostrového súboru (European – európsky, African – africký, Inuits – Inuiti);
 absence – početnosti prípadov s neprítomnosťou zmien kostného reliéfu;
 trace.to.small – početnosti prípadov so stopami zmien až malými zmenami kostného reliéfu;
 moderate.to.large – početnosti prípadov so strednými až výraznými zmenami kostného reliéfu;
 number.of.cases – početnosti prípadov v jednotlivých kostrových vzorkách.

Biologické súvislosti: Popôrodné zmeny na kostre sú spornou otázkou, ktorej riešenie má viac než 140 rokov trvajúcu históriu (cf. Mikešová, 2008). Predovšetkým sú s tehotenstvom a/alebo pôrodom spájané zmeny kostného reliéfu na kosti panvovej – tzv. *sulcus praeauricularis* pod dolným okrajom *facies auricularis* a obdobné zmeny na vnútornej strane lonovej kosti v blízkosti *symphysis pubica*. Etiológia týchto zmien však nie je dosiaľ známa. Zreteľne vytvorený *sulcus praeauricularis* vo forme špecifických jamkovitých depresí sa vyskytuje iba u žien, ktoré rodili. Neprítomnosť týchto zmien ale neznamená, že ide o ženu, ktorá nerodila. Môže ísť o muža, o ženu, ktorá nerodila, o ženu, ktorá rodila a zmeny sa u nej nevytvorili alebo sa vytvorili, ale časom došlo k ich vymiznutiu v dôsledku remodelácie kosti. Tieto útvary kostného reliéfu teda nemožno použiť ani na odhad pohlavia (prítomnosť vs. neprítomnosť), ani na stanovenie parity (miera prejavu). Okrem toho sa ženy z rôznych populácií môžu vo výskyte týchto útvarov líšiť.

Ciele:

(a) zistiť, či sa tri sledované populácie líšia vo výskyte každej z troch foriem kostného reliéfu na zadnej (vnútornej) strane kosti lonovej.

9.21 Dátový súbor – viacvýberový test o pravdepodobnostiach


Hodnotený súbor: Pri vyšetrení očnej dúhovky 60 mužov a 60 žien (Horníčková, 1992) bol hodnotený farebný odtieň dúhovky a výskyt rôznych typov útvarov v štruktúre dúhovky. Farba očí bola posudzovaná pomocou lupy podľa vzorkovnice R. Martina (Martin, 1914/1928), ktorá obsahuje 16 farebných odtieňov, a následne kategorizovaná do jednej zo štyroch skupín. Súčasne bol podľa schémy Ziegelmayera (Martin a Saller, 1957–1966, str. 400) hodnotený výskyt koncentrických, kryptovitých a lúčovitých útvarov v štruktúre dúhovky. K dispozícii máme početnosti jednotlivých farebných kategórií pre obe pohlavia a početnosti dúhoviek s lúčovitými útvarmi v jednotlivých farebných kategóriách.

Súbor dát: multinom-iris-color.txt

	H	HZ	ME	M	L.H	L.HZ	L.ME	L.M
m	13	11	24	12	7	5	9	2
f	16	12	26	6	9	7	2	1
sum	29	23	50	18	16	12	11	3

Popis premenných:

sex – pohlavie jedincov vo vzorke (m – muži, f – ženy, sum – obe pohlavia);
 iris.C – farba očnej dúhovky (H – hnedé oči (odtiene 2 – 4), HZ – hnedozelené oči (odtieň 5), ME – melírované oči (odtiene 6 – 8 a 12 – 15), M – modré oči (odtiene 9 – 11));

Obr. 9.13: Kostný reliéf na vnútornej strane *os pubis*

iris.S – štruktúra dúhovky (L.H – hnedé oči s lúčovitými útvarmi, L.HZ – hnedozelené oči s lúčovitými útvarmi, L.ME – melírované oči s lúčovitými útvarmi, L.M – modré oči s lúčovitými útvarmi).

Biologické súvislosti: Farba očí (dúhovky) je daná z veľkej časti dedične. U svetlejších očí (modrých, šedých a zelených) závisí farba očí predovšetkým od množstva pigmentu v dúhovkovej časti sietnice (*pars iridica retinae*), u hnedých očí obsahuje melanocyty aj dúhovková trámčina (*stroma iridis*) a u afrických populácií aj predná hraničná vrstva dúhovky, a to vo veľmi veľkom množstve. Farba dúhovky teda súvisí s obsahom dúhovkovej trámčiny. Jej vnútorná štruktúra však nie je homogénna. Vyskytujú sa v nej rôzne koncentrické, kryptovité (otvory) a radiálne (lúčovité) útvary, ktorých prítomnosť môže do určitej miery súvisieť s pigmentáciou dúhovkovej trámčiny.

Ciele:

- zistiť, či medzi farebnými kategóriami existujú štatisticky významné rozdiely vo výskyte lúčovitých útvarov dúhovky;
- zistiť, či existujú rozdiely vo výskyte lúčovitých útvarov dúhovky medzi pohlaviami.

9.22 Dátový súbor – viacvýberový test o pravdepodobnostiach

Hodnotený súbor: Vo vzorke, ktorú tvorilo 200 študentov (100 mužov a 100 žien), boli štandardnou dermatoglyfickou metodikou snímané dermatoglyfy dlane (Býmová, 1990). Na odtlačkoch bolo hodnotené zakončenie troch hlavných dlaňových línií (D, C a B); pozri obrázok 9.14. Prípady boli podľa vzorca zakončenia (vyústenia proximálnych radiant digitálnych trirádií na štandardne číslovaných polohách okraja dlane) rozdelené do troch kategórií. Súčasne bola hodnotená farba vlasov podľa štandardnej Fischer-Sallerovej (Martin a Saller, 1957–1966, s. 391) stupnice 30 odtieňov, ktoré boli rozdelené do 3 skupín. K dispozícii máme početnosti jedincov v jednotlivých kategóriách, zvlášť pre mužov a ženy.

Súbor dát: multinom-palmar-lines.txt

m	Hi	Mi	Lo	f	Hi	Mi	Lo
LiH	6	6	4	LiH	4	6	6
MH	20	15	7	MH	18	10	10
DaH	18	12	12	DaH	12	22	12

Popis premenných:

sex – pohlavie (m – muži, f – ženy);


palmar.lines – zakončenie troch dľaňových línií (Hi – vysoké (najčastejší vzorec 11 9 7), Mi – stredné (najčastejší vzorec 9 7 5), Lo – nízke (najčastejší vzorec 7 5 5));

hair.C – farba vlasov (LiH – svetlé, MH – stredné, DaH – tmavé).

Biologické súvislosti: Zakončenie hlavných dľaňových línií na okraji dlane odráža celkový smer priebehu epidermálnych líst na dlani, ktorý môže byť niekde medzi transversálnym a longitudinálnym. Vysoké polohy odpovedajú prevažne transversálnemu priebehu, nižšie polohy reprezentujú prevažne šikmý až longitudinálny priebeh epidermálnych líst dlaní. Keďže sa epidermálne lísty vytvárajú prenatálne od 3. mesiaca tehotenstva, finálny priebeh epidermálnych líst v dospelosti odráža epigenetické procesy z tohto obdobia. Približne v rovnakej dobe prebieha migrácia melanocytov z neurálnej lísty do pokožky (*epidermis*) a rozvíjajú sa vlasové folikuly, ktoré predstavujú deriváty kože na iných miestach tela (mimo papilárny terén). Nie je však jasné, akým spôsobom spolu epigenetické procesy v papilárnom teréne kože a mimo papilárneho terénu súvisia. Súčasne je známe, že rozdielne ľudské populácie sa líšia ako v priebehu dľaňových línií (obyvatelia Indie a Predného východu majú skôr vysoké zakončenie, pôvodní obyvatelia rovníkovej Afriky prevažne nízke a obyvatelia východnej Ázie prechodné), tak aj vo farbe kože. Medzipopulačné rozdiely však nemusia byť plne obsiahnuté v rozdieloch medzi ľuďmi v rámci jednej populácie, akokoľvek sú variabilní v študovaných znakoch. Je teda otáznne, či spolu môžu súvisieť priebeh hlavných dľaňových línií a farba vlasov u Európanov s veľmi variabilnou farbou vlasov.

Ciele:

- zistiť, či existuje vzťah medzi farbou vlasov a zakončením hlavných dľaňových línií (zvlášť u mužov a u žien);
- zistiť, či sa zakončenie troch dľaňových línií líši medzi skupinami s odlišnou farbou vlasov;
- zistiť, či sa pohlavia líšia vo farbe vlasov;
- zistiť, či sa početnosť zakončenia hlavných dľaňových línií líšia;
- zistiť, pri akom minimálnom počte jedincov vo vzorke by rovnaké proporcionálne zastúpenie v jednotlivých kategóriách a jednotlivých porovnovaniach dosiahlo štatistickú významnosť na hladine významnosti $\alpha = 0.05$ a pri sile testu $1 - \beta = 0.8$.



Obr. 9.14: Číslovanie pozíc na okraji dlane a príklady vysokého (Hi), stredného (Mi) a nízkeho (Lo) zakončenia troch hlavných dľaňových línií (D, C a B)

9.23 Dátový súbor – viacvýberový test o pravdepodobnostiach

Hodnotený súbor: Vo vzorke, ktorú tvorilo 120 študentov vysokej školy (60 mužov a 60 žien) bola okrem iného hodnotená príľahlosť ušnice (Štouračová, 1992) a sledované medzipohlavné a stranové rozdiely v tomto znaku. Prípady boli podľa príľahlosti ušnice rozdelené do troch kategórií (Titlbachová, 1967, s. 97) zvlášť na pravej a ľavej strane. K dispozícii máme početnosti jedincov v jednotlivých kategóriách.

Súbor dát: multinom-earlobe.txt

	m	R	L	f	R	L
1	22	22	1	38	36	
2	34	34	2	21	24	
3	4	4	3	1	0	

Popis premenných:

sex – pohlavie (m – muži, f – ženy);

side – strana tela (R – pravá, L – ľavá);

earlobe – príľahlosť ušnice (1 – príľahlé, 2 – stredne príľahlé, 3 – odstávajúce).

Biologické súvislosti: Vo veľkosti, tvare a ďalších vlastnostiach ušnice (*auricula*) sa človek líši od ostatných primátov. Už u vyšších primátov má ušnica len rudimentárnu pohyblivosť (za zvukom sa otáča celá hlava), stále sa však uplatňuje pri zachytávaní akustických vln. Ušnica človeka má skrátenu pozdĺžnu os, okraj zvinutý v tzv. *helix*, rozšírené pripojenie k hlave a vytvorený ušný lalôčik (*lobulus auriculae*). Podľa niektorých výskumov (Hulanicka, 1973) sa však uši mužov a žien v niektorých vlastnostiach systematicky líšia. Uši napríklad odstávajú viac mužom než ženám. Nie je však jasné, či je tento rozdiel vedľajším dôsledkom dimorfizmu ontogenézy a výsledného tvaru hlavy alebo odráža funkčné rozdiely v sluchovej percepcii medzi pohlaviami (napr. obvyklý charakter a smer sluchových signálov). Vylúčený ale nie je ani kultúrne podmienený dlhodobý vplyv odlišnej pokrývky hlavy (šatky u žien a klobúky u mužov). Pri hľadaní odpovede treba najskôr zistiť, či je dimorfizmus v príľahlosti ušnice univerzálny jav platný aj v iných ľudských populáciách, t.j. overiť existenciu dimorfizmu v príľahlosti ušnice na iných súboroch.

Ciele:

(a) zistiť, či existuje sexuálny dimorfizmus v príľahlosti ušnice (zvlášť na pravej a ľavej strane);

(b) zistiť, pri akom minimálnom počte jedincov vo vzorke by rovnaké proporcionálne zastúpenie v jednotlivých kategóriách dosiahlo štatistickú významnosť na hladine významnosti $\alpha = 0.05$ a pri sile testu $1 - \beta = 0.8$.

9.24 Dátový súbor – homogenita vektorov pravdepodobností

Hodnotený súbor: V nezávislých výskumoch boli zistené frekvencie krvných skupín AB0 systému (skupina 0, A, B a AB) u 400 obyvateľov Košíc (Slovensko) a 500 obyvateľov Prahy (pozri Vondrušková, 1983). K dispozícii máme početnosti v jednotlivých kategóriách.

Súbor dát: multinom-blood-groups.txt

	0	A	B	AB
K	138	147	84	31
P	209	184	81	26

Popis premenných:

city – mesto (K – Košice, P – Praha);

blood – krvná skupina AB0 systému (0, A, B, AB).

Biologické súvislosti: Krvné skupiny sú vrodene vlastnosti povrchu erytrocytov (proteíny, glykoproteíny alebo glykolipidy), detegovateľné pomocou aloprotilátok. Do dnešnej doby bolo rozlíšených minimálne 30 systémov krvných skupín, z ktorých väčšina je polymorfných (ľudia sa vzájomne líšia kombináciou alel podmienujúcich príslušné antigény). Polymorfizmus krvných skupín je podľa dnešných poznatkov udržiavaný prírodným výberom a predstavuje výsledok adaptácií minulých populácií na pôsobenie bakteriálnych patogénov. Napríklad relatívne nízka frekvencia skupiny 0 (AB0 systému) v mnohých

oblastiach Európy a Ázie môže byť dôsledkom devastujúcich epidémií (*Yersiniapestis*). Antigén na povrchu tohto mikroorganizmu je podobný H antigénu krvnej skupiny 0. Ľudia s krvnou skupinou 0 neprodukuje žiadne protilátky anti-H pravdepodobne tento patogén nerozpoznali, čo u nich mohlo viesť k horšiemu priebehu choroby a vyššej úmrtnosti (Mielke a kol., 2011). Frekvencie foriem v rámci daného systému (napr. ABO systému) sa naprieč geografickým územím mení *klinálne*, t.j. existujú geografické gradienty v zastúpení jednotlivých foriem (A, B, AB a 0).

Ciele:

(a) zistiť, či sa obyvatelia Prahy a Košíc líšia v zastúpení krvných skupín ABO systému.

10 Funkcie

V tabuľkách 10.1, 10.2, 10.3, 10.4, 10.5 a 10.6 sa nachádza tabuľkový prehľad použitých a naprogramovaných funkcií v \mathbb{R} a ich stručné definície.

Tabuľka 10.1: Prehľad základných funkcií – charakteristiky polohy a variability a matematické funkcie

funkcia	popis
<code>cor()</code>	korelačný koeficient r
<code>length()</code>	rozsah n
<code>mad()</code>	priemer absolútnych odchýlok MAD
<code>max()</code>	maximum x_{\max}
<code>mean()</code>	aritmetický priemer \bar{x}
<code>median()</code>	medián $\tilde{x}_{0.5}$
<code>min()</code>	minimum x_{\min}
<code>quantile()</code>	vybrané kvantily, napr. $\tilde{x}_{0.25}$, $\tilde{x}_{0.5}$ a $\tilde{x}_{0.75}$
<code>range()</code>	rozpätie D
<code>sd()</code>	smerodajná odchýlka s_x
<code>summary()</code>	päťčíselný súhrn $(x_{\min}, \tilde{x}_{0.25}, \tilde{x}_{0.5}, \tilde{x}_{0.75}, x_{\max})$
<code>var()</code>	rozptyl s_x^2
<code>abs()</code>	absolútna hodnota
<code>atan()</code>	arkus tangens
<code>atanh()</code>	hyperbolický arkus tangens
<code>ceiling()</code>	najbližšie vyššie celé číslo
<code>colMeans()</code>	aritmetický priemer čísel v matici po stĺpcoch
<code>colSum()</code>	suma čísel v matici po stĺpcoch
<code>cos()</code>	kosínus uhla v radiánoch
<code>cumsum()</code>	kumulatívna suma
<code>cut()</code>	rozdelenie spojitej premennej na intervaly
<code>density()</code>	hustota
<code>dim()</code>	rozмеры objektu
<code>exp()</code>	exponenciálna funkcia
<code>floor()</code>	celá časť čísla
<code>log()</code>	prírodný logaritmus
<code>na.omit()</code>	vyradenie chýbajúcich pozorovaní ozn. NA
<code>order()</code>	výpis poradia elementov vektora
<code>round()</code>	zaokrúhľovanie
<code>rowMeans()</code>	aritmetický priemer čísel v matici po riadkoch
<code>rowSum()</code>	suma čísel v matici po riadkoch
<code>scale()</code>	škálovanie dát
<code>sin()</code>	sínus uhla v radiánoch
<code>sort()</code>	zoradenie elementov vektora podľa veľkosti
<code>sqrt()</code>	odmocnina čísla
<code>sum()</code>	suma členov vektora
<code>tanh()</code>	hyperbolický tangens

Tabuľka 10.2: Prehľad funkcií súvisiacich s dátovým manažmentom a funkcia `library()`

funkcia	popis
<code>addmargins()</code>	pridanie okrajových početností do tabuľky početností
<code>apply()</code>	aplikácia funkcie na maticu
<code>array()</code>	vytvorenie objektu pole
<code>as.data.frame()</code>	zmena nejakého objektu na dátovú tabuľku
<code>as.factor()</code>	zmena nejakého objektu na kategoriálnu premennú
<code>as.matrix()</code>	zmena nejakého objektu na maticu
<code>as.numeric()</code>	zmena nejakého objektu na číselný vektor
<code>as.vector()</code>	zmena nejakého objektu na vektor
<code>attach()</code>	použitie názvov stĺpcov
<code>c()</code>	vytvorenie objektu vektor
<code>cbind()</code>	skladanie vektorov po stĺpcoch
<code>combn()</code>	jednoduchý náhodný výber s vrátením z knižnice <code>utils</code>
<code>data.frame()</code>	vytvorenie dátovej tabuľky
<code>dimnames()</code>	pomenovania dimenzií v objekte
<code>factor()</code>	vytvorenie kategoriálnej premennej
<code>ftable()</code>	vytvorenie kontingenčnej tabuľky
<code>choose()</code>	počet všetkých výberov s vrátením z knižnice <code>utils</code>
<code>levels()</code>	hladiny kategoriálnej premennej
<code>library()</code>	načítanie nainštalovanej knižnice
<code>list()</code>	vytvorenie objektu <code>list</code>
<code>margin.table()</code>	marginálne početnosti v tabuľke početností
<code>matrix()</code>	vytvorenie objektu matica
<code>na.omit()</code>	odstránenie chýbajúcich pozorovaní ozn. <code>NA</code>
<code>names()</code>	pomenovanie dimenzií v objekte alebo elementov objektu
<code>numeric()</code>	vytvorenie číselného vektora
<code>print()</code>	výpis objektu (použitie vo funkcii alebo cykle)
<code>prop.table()</code>	vytvorenie tabuľky pravdepodobností
<code>rbind()</code>	skladanie vektorov po riadkoch
<code>read.table()</code>	načítanie (import) dátovej tabuľky do \mathbb{R}
<code>rep()</code>	vytvorenie vektora opakovaním jeho elementov
<code>replicate()</code>	opakovanie nejakého príkazu alebo funkcie
<code>return()</code>	výpis objektu (použitie vo funkcii)
<code>sample()</code>	jednoduchý náhodný výber bez vrátenia alebo s vrátením
<code>seq()</code>	vytvorenie sekvencie čísel
<code>split()</code>	rozdelenie dát na skupiny
<code>t()</code>	transpozícia matice
<code>table()</code>	vytvorenie tabuľky početností
<code>tapply()</code>	aplikácia funkcie na pole
<code>write.table()</code>	export tabuľky z \mathbb{R}
<code>X[i]</code>	indexovanie vo vektore
<code>X[[i]]</code>	indexovanie v liste
<code>X[i,j]</code>	indexovanie v matici
<code>"retazec"</code>	textový reťazec
<code>==</code>	indexovanie
<code>!is.na()</code>	identifikácia chýbajúcich pozorovaní ako <code>FALSE</code> , ostatných ako <code>TRUE</code>

Tabuľka 10.3: Prehľad štatistických a numericko-matematických funkcií

funkcia	popis
cr()	koeficient reliability merania
grafy.dva.vybery()	tri grafy pre exploratórnu analýzu dát
grafy.jeden.vyber()	štyri grafy pre exploratórnu analýzu dát
chisq.stat	χ^2 test dobrej zhody
ISkor()	IS pre klasický Pearsonov korelačný koeficient ρ
ISkor.rozdiel()	IS pre rozdiel dvoch Pearsonových korelačných koeficientov $\rho_1 - \rho_2$
ISkor.uhl()	IS pre lineárno-uhlový Pearsonov korelačný koeficient ρ
ks.l.mc()	MC Lillieforsov test dobrej zhody
ks.mc()	MC Kolmogorov-Smirnovov test dobrej zhody
kvart.sikmost()	kvartilová šikmost'
lambda.multinom()	parameter necentrality λ^2 rozdelenia χ^2_{J-1, λ^2}
lin.uhl.r()	lineárno-uhlový Pearsonov korelačný koeficient r
LRp()	logaritmus funkcie vierohodnosti pre pravdepodobnosť p
min.rozsah.n.kor()	minimálny rozsah n pre rozdiel dvoch korelačných koeficientov $\rho_1 - \rho_2$
min.rozsah.n.p()	minimálny rozsah N pre rozdiel dvoch pravdepodobností $p_1 - p_2$
oktil.sikmost()	oktilová šikmost' b_{1O}
priem.uhol()	priemerný uhol
rho.hat()	odhad korelačného koeficientu $\hat{\rho}$ (iteračné riešenie rovníc)
rozptyl()	rozptyl s_x^2
SE()	štandardná chyba $s_{\bar{x}}$
sikmost()	šikmost' b_1
sin.cos.uhla()	sínus a kosínus uhla v stupňoch
smerodch()	smerodajná odchýlka s_x
spicatost()	špicatost' b_2
tem()	technická chyba merania
tem.rel()	relatívna technická chyba merania
test.pomeru.sanci()	Waldove testy o pomere šancí
test.relat.rizika()	Waldove testy o relatívnom riziku
test.rozdielu.prav()	Waldove testy o rozdieloch pravdepodobností
testy.o.kor.koef()	test pomerom vierohodnosti a χ^2 -test o korelačných koeficientoch
testy.o.rozptyloch()	test pomerom vierohodnosti a Bartlettov test o homogenite rozptylov
testy.o.stred.hodnotach()	F -test a test pomerom vierohodnosti o rovnosti stredných hodnôt
uhl.uhl.r()	uhlový Pearsonov korelačný koeficient r
urezanie()	γ -urezaný vektor
winsorizacia()	vektor winsorizovaný pomocou „vnútorných hradieb“
zakl.char()	vybrané základné charakteristiky
aov()	ANOVA model s fixnými efektami
bartlett.test()	viacvýberový test o homogenite rozptylov
binconf()	Waldov 95% empirický IS pre pravdepodobnosť z knižnice Hmisc
cor.test()	jednovýberový t -test nulovosti korelačného koeficientu ρ
ks.test()	Kolmogorov-Smirnovov test dobrej zhody
lillie.test	Lillieforsov test dobrej zhody z knižnice nortest
pairwise.t.test()	viacvýberový test o rovnosti stredných hodnôt
power.t.test()	sila jednovýberového Studentovho t -testu o strednej hodnote
prop.test()	χ^2 test o pravdepodobnosti alebo o vektore pravdepodobností
t.test()	Studentove t -testy
TukeyHSD()	viacvýberový Tukeyho HSD test
var.test()	χ^2 test o podiele rozptylov
optim()	numerické hľadanie maxima alebo minima funkcie
optimize()	numerické hľadanie maxima alebo minima funkcie
uniroot()	numerické hľadanie koreňov rovnice

Tabuľka 10.4: Prehľad funkcií kresliacich rôzne druhy grafov a funkcií s grafmi súvisiacich

funkcia	popis
abline()	priamka so zadaným interceptom a sklonom
arrows()	úsečka so šípkami na ich koncoch
axis()	dokreslenie osí x a y do obrázka
barplot()	stĺpcový diagram
box()	ohraničenie grafu
boxplot()	krabicový diagram
contour()	kontúrový graf/vkreslenie kontúr do existujúceho obrázka
curve()	krivka
errbar()	chybová úsečka z knižnice <code>Hmisc</code>
gray()	vytvorenie RGB-vektora z vektora hladín sivej z intervalu $(0, 1)$
grey()	vytvorenie RGB-vektora z vektora hladín sivej z intervalu $(0, 1)$
heat.colors()	teplé farby
histback()	dva histogramy dotýkajúce sa bázami z knižnice <code>Hmisc</code>
histogram()	histogram
identfy()	výpis pozície (x,y) v grafe na mieste kurzora
image()	sieť farebných štvoruholníkov
kde2d()	dvozmerný graf hustoty
legend()	výpis legendy grafu
lines()	nakreslenie krivky medzi bodmi (x,y)
locator()	výpis pozície (x,y) v grafe na mieste kurzora
matplot()	komplikovanejší bodový graf
mtext()	výpis textu na špecifikované miesto mimo grafu
par()	parametre obrázka
persp()	perspektívny 3D graf
pie()	kruhový diagram
plot()	bodový (rozptylový) graf
plot(ecdf())	empirická distribučná funkcia
points()	body v súradniciach (x,y)
polygon()	vyfarbený mnohoúholník medzi dvoma krivkami
qqline()	kvantilová priamka
qqnorm()	kvantilový diagram
qqPlot()	kvantilový diagram s Atkinsonovou obálkou z knižnice <code>car</code>
rainbow()	farby dúhy
rect()	vyfarbený štvoruholník (a jeho vnútro) definovaný svojimi vrcholmi
rug()	„koberec“ pod histogramom
scatterplot3d()	3D bodový graf z knižnice <code>scatterplot3d</code>
segments()	úsečka medzi bodmi (x_0,y_0) a (x_1,y_1)
sm.density()	hustota z knižnice <code>sm</code>
spine()	spinogram z knižnice <code>vcd</code>
terrain.colors()	topografické farby
text()	text v polohe (x,y)
title()	popis grafu
topo.colors()	topografické farby
windows()	otvorenie okna danej šírky a výšky v palcoch

Tabuľka 10.5: Prehľad funkcií súvisiacich s grafmi – popis obrázka a jeho parametre

argument	popis	argument	popis
xlab	popis osí x	col	farba
ylab	popis osí y	pch	typ bodu
sub	popis grafu	cex	veľkosť bodu
main	nadpis grafu	lty	typ čiary
axes	zobrazenie osí	lwd	šírka čiary
fig	súradnice plochy obrázka	mfcow	počet stĺpcov v sérii
new	pridanie obrázka do série	mfrow	počet riadkov v sérii
font	typ písma	family	písmová rodina
xlim	hranice grafu v smere osi x	ylim	hranice grafu v smere osi y
asp	pomer škály osí y a x	mar	okraje grafu

Tabuľka 10.6: Prehľad funkcií súvisiacich s rozdeleniami pravdepodobnosti

funkcia	popis	funkcia	popis
binomické rozdelenie		Poissonovo rozdelenie	
dbinom()	pravdepodobnostná funkcia	dpois()	pravdepodobnostná funkcia
pbinom()	distribučná funkcia	ppois()	distribučná funkcia
qbinom()	kvantil	qpois()	kvantil
rbinom()	pseudonáhodné čísla	rpois()	pseudonáhodné čísla
multinomické rozdelenie		gama rozdelenie	
dmultinom()	pravdepodobnostná funkcia	dgamma()	hustota
pmultinom()	distribučná funkcia	pgamma()	distribučná funkcia
qmultinom()	kvantil	qgamma()	kvantil
rmultinom()	pseudonáhodné čísla	rgamma()	pseudonáhodné čísla
normálne rozdelenie		Studentovo rozdelenie	
dnorm()	hustota	dt()	hustota
pnorm()	distribučná funkcia	pt()	distribučná funkcia
qnorm()	kvantil	qt()	kvantil
rnorm()	pseudonáhodné čísla	rt()	distribučná funkcia
χ^2 rozdelenie		Fisherovo rozdelenie	
dchisq()	hustota	df()	hustota
pchisq()	distribučná funkcia	pf()	distribučná funkcia
qchisq()	kvantil	qf()	kvantil
rchisq()	pseudonáhodné čísla	rf()	pseudonáhodné čísla
mnohorozmerné normálne rozdelenie z knižnice mvtnorm		mnohorozmerné normálne rozdelenie z knižnice MASS	
rmvnorm()	pseudonáhodné čísla	mvrnorm()	pseudonáhodné čísla

Literatúra

- Agresti, A., 2002: *Categorical Data Analysis*. Hoboken: John Wiley & Sons
- Agresti, A., Coull, B.A., 1998: Approximate Is Better than "Exact" for Interval Estimation of Binomial Proportions. *The American Statistician* 52(2): 119–126
- Alánová, N., 2008: *Sociální a morfologické vlastnosti matek a novorozenců a jejich souvislosti s poměrem pohlaví*. Bakalářská práce. Brno: Masarykova univerzita
- Almagor, M., Schwed, P., Yaffe, H., 1998: Male to female ratio in newborns of grand grand multiparous women. *Human Reproduction* 13(8): 2323–2324
- Alt, K.W., Benz, M., Müller, W., Berner, M.E., Schultz, M., Schmidt-Schultz, T.H., Knipper, C., Gebel, H.-G.K., Nissen, H.J., Vach, W., 2013: Earliest Evidence for Social Endogamy in the 9,000-Year-Old-Population of Basta, Jordan. *PLoS ONE* 8(6): e65649
- Anděl, J., 2011: *Základy matematické statistiky*. Praha: MatfyzPress
- Angel, J.L., 1982: A New Measure of Growth Efficiency: Skull Base Height. *American Journal of Physical Anthropology* 58: 297–305
- Ashley Montagu, M.F., 1944: Aleš Hrdlička, 1869–1943. *American Anthropologist* 46: 113–117
- Atkinson, A.C., 1981: Two Graphical Displays for Outlying and Influential Observations in Regression. *Biometrika* 68: 13–20
- Azzalini, A., 1996: *Statistical inference based on likelihood*. Boca Raton: Chapman Hall/CRC Press
- Bainbridge, D., Martin, J., Arango, M., Cheng, D., 2012: Perioperative and anaesthetic-related mortality in developed and developing countries: a systematic review and meta-analysis. *The Lancet* 380(9847): 1075–1081
- Bartlett, M. S. 1937: Properties of sufficiency and statistical tests. *Proceedings of the Royal Statistical Society, Series A* 160: 268–282
- Becker, R.A., Chambers, J.M., Wilks, A.R., 1988: *The New S Language*. Boca Raton: Chapman and Hall/CRC
- Benjamini, Y., Hochberg, Y., 1995: Controlling the false discovery rate: a practical and powerful approach to multiple testing. *Journal of the Royal Statistical Society Series B* 57: 289–300
- Benjamini, Y., Yekutieli, D., 2001: The control of the false discovery rate in multiple testing under dependency. *The Annals of Statistics* 29: 1165–1188
- Bickel, P.J., Doksum, K.A., 2006: *Mathematical Statistics: Basic Ideas and Selected Topics (Vol. 1)*. Upper Saddle River: Pearson
- Bland, M., 2009: *An introduction to medical statistics*. Oxford: Oxford University Press
- Bogaert, A.F., Blanchard, R., 1996: Physical development and sexual orientation in men: Height, weight and age of puberty differences. *Personality and individual differences* 21: 77–84
- Bogaert, A.F., Skorska, M., 2011: Sexual orientation, fraternal birth order, and the maternal immune hypothesis: a review. *Frontiers in Neuroendocrinology* 32(2): 247–254
- Bogin, B., 1999: *Patterns of Human Growth*. New York: Cambridge University Press
- Bonferroni, C.E., 1936: *Teoria statistica delle classi e calcolo delle probabilità*. Firenze: Libreria Internazionale Seeber
- Bouchalová, M., 1987: *Vývoj během dětství a jeho ovlivnění*. Praha: Avicenum
- Bowman, A.W., Azzalini, A., 1997: *Applied Smoothing Techniques for Data Analysis*. Oxford: Oxford University Press
- Brazzale, A.R., Davison, A.C., Reid, N., 2007: *Applied Asymptotics: Case Studies in Small-Sample Statistics*. New York: Cambridge University Press
- Brent, R.P., 1973: Chapter 4: An Algorithm with Guaranteed Convergence for Finding a Zero of a Function. *Algorithms for Minimization without Derivatives*. Englewood Cliffs, NJ: Prentice-Hall
- Broca, P., 1862: Sur les proportions relatives du bras, de l'avant bras et de la clavicule chez les nègres et les Européens. *Bulletin Société d'Anthropologie Paris* 3(2): 162–172
- Brůžek, J., 2008: Současná česká paleodemografie: falešné naděje přílišného optimismu a nový reálný cíl. *Archeologické rozhledy* 60: 329–344
- Budíková, M., Králová, M., Maroš, B., 2010: *Průvodce základními statistickými metodami*. Praha: Grada
- Buk, Z., Kordík, P., Brůžek, J., Schmitt, A., Šnorek, M., 2012: The age at death assessment in a multi-ethnic sample of pelvic bones using nature-inspired data mining methods. *Forensic Science International* 220(1–3): 294–294
- Býmová, I., 1990: *Dlaňové dermatoglyfy ve vztahu k barvě vlasů*. Magisterská diplomová práce. Brno: Masarykova univerzita
- Cardoso, H.F.V., 2008: Secular changes in body height and weight of portuguese boys over one century. *American Journal of Human Biology* 20: 270–277
- Casella, G., Berger, R.L., 2002: *Statistical Inference*. Pacific Grove: Duxbury Press
- Cox, D.R., 2006: *Principles of statistical inference*. Cambridge: Cambridge University Press
- Cox, D.R., Donnelly, C.A., 2011: *Principles of Applied Statistics*. New York: Cambridge University Press
- Cox, D.R., Hinkley, D.V., 1974: *Theoretical Statistics*. London: Chapman and Hall
- Cressie, N., Read, T.R.C., 1984: Multinomial goodness-of-fit tests. *Journal of the Royal Statistical Society, Series B* 46: 440–464
- Dadejová, V., Králík, M., Urbanová, P., 2011: Věkové a mezipohlavní rozdíly v rozměrech zubního oblouku dolní čelisti nedospělých jedinců: Brněnská sbírka sádrových ortodontických modelů chrupu. *Anthropologia Integra* 2(1): 13–29
- Dalgaard, P., 2008: *Introductory Statistics with R*. New York: Springer
- Dallal, G.E., Wilkinson, L., 1986: An analytic approximation to the distribution of Lilliefors' test for normality. *The American Statistician* 40: 294–296
- DasGupta, A., 2008: *Asymptotic Theory of Statistics and Probability*. New York: Springer
- Dodo, Y., 1974: Non-metrical cranial traits in the Hokkaido Ainu and the Northern Japanese of recent times. *Journal of Anthropological Society of Nippon* 82: 31–51
- Donner, A., Rosner, B., 1980: On Inference Concerning a Common Correlation Coefficient. *Journal of the Royal Statistical Society, Series C* 29(1): 69–76
- Dudoit, S., van der Laan, M.J., 2008: *Multiple Testing Procedures with Applications to Genomics*. New York: Springer
- Eveleth, P.B., Tanner, J.M., 1990: *Worldwide variation of human growth*. Cambridge: Cambridge University Press
- Fetter, V. a kol., 1967: *Antropologie*. Praha: Academia
- Fisher, R.A., 1935: *The Design of Experiments*. London: Macmillan

- Fisher, R.A., 1936, 1971: The use of multiple measurements in taxonomic problems. *Annals of Eugenics* 7: 179–188
- Flack, V.F., Flores, R.A., 1989: Using Simulated Envelopes in the Evaluation of Normal Probability Plots of Regression Residuals. *Technometrics* 31(2): 219–225
- Garn, S.M., Rohmann, C.G., 1963: On the Prevalence of Skewness in Incremental Data. *American Journal of Physical Anthropology* 21: 235–236
- Geissler, A., 1889: Beiträge ge zur Frage des Geschlechtsverhältnisses der Geborenen. *Z. Königl. Sächs. Statist. Bur.* 35: 1–24
- Gentle, J.E., 2007: *Matrix Algebra: Theory, Computations, and Applications in Statistics*. New York: Springer
- Gentle, J.E., 2009: *Computational Statistics*. New York: Springer
- Gerring, J., 2007: *Case Study Research. Principles and Practices*. Cambridge: Cambridge University Press
- Givens, G.H., Hoeting, J.A., 2005: *Computational Statistics*. Hoboken: Wiley & Sons
- Goto, R., Mascie-Taylor, C.G.N., 2007: Precision of Measurement as a Component of Human Variation. *Journal of Physiological Anthropology* 26: 253–256
- Greenwood, M., Yule, G.U., 1920: An inquiry into the nature of frequency distributions representative of multiple happening with particular reference to the occurrence of multiple attacks of disease or repeated accidents. *Journal of the Royal Statistical Society, Series A* 83: 255–279
- Hackshaw, A., 2009: *A concise guide to clinical trials*. Chichester: Wiley-Blackwell, BMJ Books
- Hackshaw, A., 2011: *How to write a grant application*. Chichester: Wiley-Blackwell, BMJ Books
- Halligan, S., 2002: Reproducibility, repeatability, correlation and measurement error. *The British Journal of Radiology* 75: 193–195
- Hauser G., De Stefano G. F. a kol., 1989: *Epigenetic Variants of the Human Skull*. Stuttgart: E. Schweizerbart'sche Verlagsbuchhandlung (Nägele u. Obermiller)
- Hochberg, Y., 1988: A sharper Bonferroni procedure for multiple tests of significance. *Biometrika* 75: 800–803
- Hollier, L.P., Keelan, J.A., Jamnadass, E.S.L., Maybery, M.T., Hickey, M., Whitehouse, A.J.O., 2015: Adult digit ratio (2D:4D) is not related to umbilical cord androgen or estrogen concentrations, their ratios or net bioactivity. *Early Human Development* 91(2): 111–117
- Holm, S., 1979: A simple sequentially rejective multiple test procedure. *Scandinavian Journal of Statistics* 6: 65–70
- Horníčková, L., 1992: *Barva očí brněnských vysokoškoláků*. Magisterská diplomová práce. Brno: Masarykova univerzita
- Horová, I., Zelinka, J., 2008: *Numerické metody*. Brno: Masarykova univerzita
- Hotelling, H., 1979: New light on the correlation coefficient and its transforms. *Journal of the Royal Statistical Society, Series B* 15: 193–232
- Hrdlička, A., 1920: *Anthropometry*. Philadelphia: Wistar Institute of Anatomy and Biology
- Hrdlička, A., 1939, 1952: *Pactical Anthropometry*. Philadelphia: Wistar Institute of Anatomy and Biology
- Hulanicka, B., 1973: *Anthroposcopic features as a measure of similarity*. *Materiały i prace antropologiczne (Wrocław)* 86: 115–155
- Hulley, S.B., Cummings, S.R., Browner, W.S., Grady, D.G., Newman, T.B., 2007: *Designing clinical research*. Philadelphia: Wolters Kluwer
- Chambers, J.M., 2008: *Software for Data Analysis: Programming with R*. New York: Springer
- Cheng, D.C., Bainbridge, D., Martin, J.E., Novick, R.J., 2005: Does Off-pump Coronary Artery Bypass Reduce Mortality, Morbidity, and Resource Utilization When Compared with Conventional Coronary Artery Bypass? A Meta-analysis of Randomized Trials. *Anesthesiology* 102(1): 188–203
- Cheng, H., Shang, X., He, Y., Zhang, T., Zhang, Y.P., Zhou, R., 2007: Insight into human sex ratio imbalance: the more boys born, the more infertile men. *Reproductive Biomedicine Online* 15(5): 487–494
- Chernoff, H., Lehmann, E.L., 1954: The use of maximum likelihood estimates in χ^2 tests for goodness of fit. *Annals of Mathematical Statistics* 25: 579–586
- Christensen, R., 1997: *Log-Linear Models and Logistic Regression*. New York: Springer
- Christensen, R., 2002: *Plane Answers to Complex Questions*. New York: Springer
- James, W.H., 2006: Possible constraints on adaptive variation in sex ratio at birth in humans and other primates. *Journal of Theoretical Biology* 238: 383–394
- James, W.H., 2008: The variations of human sex ratio at birth with time of conception within the cycle, coital rate around the time of conception, duration of time taken to achieve conception, and duration of gestation: A synthesis. *Journal of Theoretical Biology* 255: 199–204
- Jammalamadaka, S.R., Lund, U.J., 2006: The effect of wind direction on ozone levels: a case study. *Environ Ecol Stat* 13: 287–298
- Jit, I., Singh, S., 1966: The sexing of the adult clavicles. *Indian Journal of Medical Research* 54: 551–571
- Juntunen, K.S.T., Kvist, A.P., Kauppila, A.J.L., 1997: A shift from a male to a female majority in newborns with the increasing age of grand grand multiparous women. *Human Reproduction* 12: 2321–2323
- Jurda, M., 2008: *Tafonomické změny lidské lebky z pohledu geometrické morfometrie*. Magisterská diplomová práce. Brno: Masarykova univerzita
- Kabacoff, R.I., 2011: *R in Action: Data analysis and graphics with R*. Shelter Island: Manning Publications
- Katina, S., Bodoríková, S., Dornhoferová, 2011: Reliability of measurements in geometric and traditional morphometrics of human skull. *Česká antropologie* 61(2): 16–25
- Katz, D., Baptista, J., Azen, S.P., Pike, M.C., 1978: Obtaining confidence intervals for the risk ratio in cohort studies. *Biometrics* 34: 469–474
- Kaur, J., Choudhry, R., Raheja, S., Dhissa, N.C., 2012: Non metric traits of the skull and their role in anthropological studies. *Journal of Morphological Science* 29(4): 189–194
- Kinsey, A.C., Pomeroy, W.B., Martin, C.E., 1948: *Sexual Behavior in the Human Male*. Philadelphia and London: W. B. Saunders Company
- Knussmann, R. (ed.), 1988: *Anthropologie, Handbuch der vergleichenden Biologie des Menschen* (4. Auflage des Lehrbuchs der Anthropologie begründet von Rudolf Martin), Band I und II. Stuttgart: Gustav Fischer Verlag
- Kolmogorov, A.N., 1933: Sulla determinazione empirica di una legge di distribuzione. *Giornale dell' Istituto Italiano degli Attuari* 4: 83–91
- Komenda, S., 2000: *Vypočítatelná náhoda. Elementy počtu pravděpodobnosti a matematické statistiky*. Olomouc: Univerzita Palackého v Olomouci
- Králik, M., Urbanová, P., Wagenknechtová, M., 2014: Sex assessment using clavicle measurements: Inter- and intra-population comparisons. *Forensic Science International* 234: 181.e1–181.e15
- Kukla, L., 2008: Evropská dlouhodobá studie těhotenství a dětství – ELSPAC. *Vox Paediatricae* 8(5): 24–26
- Kumar, V. S., Jeyaseelan, L., Sebastian, T., Regi, A., Mathew, J., Jose, R., 2013: New birth weight reference standards customised to birth order and sex of babies from South India. *BMC Pregnancy and Childbirth* 13: 38–38
- Larsen, C.S., 1997: *Bioarchaeology: Interpreting behavior from the human skeleton*. Cambridge: Cambridge University Press

- Lehmann, E.L., 1999: *Elements of Large-Sample Theory*. New York: Springer
- Lehmann, E.L., Casella, G., 1998: *Theory of Point Estimation*. New York: Springer
- Leroux, B.G., Puterman, M.L., 1992: Maximum-penalized-likelihood estimation for independent and Markov-dependent mixture models. *Biometrics* 48: 545–558
- LeVay, S., 1991: A difference in hypothalamic structure between homosexual and heterosexual men. *Science* 253: 1034–1037
- Lieberman, D.E., 2011: *Complexity, Modularity, and Integration in the Human Head. The Evolution of the Human Head*. Cambridge, Mass: The Belknap Press of Harvard University Press
- Lindsey, J.K., Altham, P.M.E., 1998: Analysis of the human sex ratio by using overdispersion models. *Appl. Statist.* 47(1): 149–157
- Lorencová, A., Beneš, J. 1976: Body composition of workers in three industrial centres in Moravia (ČSSR). In: M. Dokládál (ed.) *Human growth and physical development*, Brno: J. E. Purkyně University Brno, 141–148
- Maccoby, E.E., Doering, C.H., Jacklin, C.N., Kraemer, H., 1979: Concentrations of sex hormones in umbilical-cord blood: their relation to sex and birth order of infants. *Child Development* 50(3): 632–642
- Macfarlane, J., Prewett, J., Rose, D., Gard, P., Cunningham, R., Saikku, P., Euden, S., Myint, S., 1997: Prospective casecontrol study of role of infection in patients who reconsult after initial antibiotic treatment for lower respiratory tract infection in primary care. *British Medical Journal* 315(7117): 1211–1214
- MacIntyre, C.R., Heywood, A.E., Koor, P., Ridda, I. Seale, H., Tan, T., Gao, Z., Katelaris, A.L., Siu, H.W.D., Lo, V., Lindley, R., Dwyer, D.E., 2013: Ischaemic heart disease, influenza and influenza vaccination: a prospective case control study. *Heart* 99(24): 1843–1848
- Mardia, K.V., 1976: Linear-circular correlation and rhythmometry. *Biometrika* 63: 403–405
- Mardia, K.V., Jupp, P.E., 2000: *Directional statistics*. New York: Wiley
- Marini, E., Racugno, W., Borgognini Tarli, S. M., 1999: Univariate estimates of sexual dimorphism: the effects of intrasexual variability. *American Journal of Physical Anthropology* 109: 501–508
- Martin, R., 1914, 1928: *Lehrbuch der Anthropologie* 1. a 2. Aufl. Band II. Kraniologie, Osteologie. Stuttgart: Gustav Fischer Verlag
- Martin, R., Saller, K., 1957–1966: *Lehrbuch der Anthropologie* 3. Aufl. Stuttgart: Gustav Fischer Verlag
- Mastrangelo, P., De Luca, S., Alemni, B., Botella, M.C., 2011: Sex assessment from the carpal bones: Discriminant function analysis in a 20th century Spanish sample. *Forensic Science International* 206: 216.e1–216.e10
- Matalová, A. (ed.), 2008: Gregor Mendel, *Pokusy s hybridy rostlin*. Brno: Jiří Krejčí, Nakl. K-public
- Matloff, N., 2011: *The Art of R Programming: A Tour of Statistical Software Design*. San Francisco: William Pollock
- Mays, S., Steele, J., Ford, M., 1999: Directional asymmetry in the human clavicle. *International Journal of Osteoarchaeology* 9: 18–28
- McPaul, M.J., Toto, R.D., 2011: *Clinical research from proposal to implementation*. Philadelphia: Wolters Kluwer
- Meloun, M., Militký, J., 2004: *Statistické zpracování experimentálních dat*. Praha: East Publishing
- Mielke, J.H., Konigsberg, L.W., Relethford, J.H., 2011: *Human Biological Variation* (2 ed.). New York – Oxford: Oxford University Press
- Mikešová, T., 2008: *Poporodní změny na kostě: kritická historická studie*. Magisterská diplomová práce. Brno: Masarykova univerzita
- Mood, A.M., Graybill, F.A., Boes, D.C., 1987: *Introduction to the theory of statistics*. London: McGraw-Hill
- Mouri, T., 1976: A Study of non-metrical cranial variants of the modern Japanese in the Kinki district. *Journal of Anthropological Society of Nippon* 84: 191–203
- Mueller, W.H., Martorell, R., 1988: Reliability and accuracy of measurement. In: Lohman, T.G., Roche, A.F., Martorell, R. (eds.) *Anthropometric Standardization Reference Manual*. Champaign, Illinois: Human Kinetic Books, 83–86
- Murrell, P., 2011: *R Graphics*. Boca Raton: Chapman Hall/CRC Press
- Nedoma, K., Freund, K., 1961: Somatosexuální nálezy u homosexuálních mužů. *Československá psychiatrie* 57: 100–103
- Newcombe, R.G., 1998: Two-sided confidence intervals for the single proportion: comparison of seven methods. *Statistics in Medicine* 17(8): 857–872
- Okajima, M., Iwayanagi, C., 1986: Absence of palmar digital triradius d observed in 2,681 Japanese families and clinical significance. *Japanese Journal of Human Genetics* 31(4): 331–336
- Parsons, F.G., 1916: On the proportions and characteristics of the modern English clavicle. *Journal of Anatomy* 51: 71–93
- Pařízková, J., 1973: *Body composition and lipid metabolism in different regimes of physical activity*. Praha: Avicenum
- Paul, S.R., 1989: Test for equality of several correlation coefficients. *The Canadian Journal of Statistics* 17(2): 217–227
- Pawitan, Y., 2001: *In All Likelihood: Statistical Modelling and Inference Using Likelihood*. Oxford: Oxford University Press
- Peacock, J.L., Peacock, P.J., 2011: *Oxford handbook of medical statistics*. Oxford: Oxford University Press
- Pearson, K., 1899: IV. *Mathematical contribution to the theory of evolution*. – V. *On the reconstruction of the stature of prehistoric races*. Philosophical Transactions of the Royal Society of London, Series A 192: 169–244
- Pearson, K., 1933: On a method of determining whether a sample of size n supposed to have been drawn from a parent population having a known probability integral has probably been drawn at random. *Biometrika* 25: 379–410
- Preedy, V.R. (ed), 2012: *Handbook of Anthropometry: Physical Measures of Human Form in Health and Disease*. New York: Springer
- R Development Core Team, 2013: *R: A Language and Environment for Statistical Computing*. Vienna: R Foundation for Statistical Computing
- Rasch, D., Pilz, J., Verdooren, R., Gebhardt, A., 2011: *Optimal Experimental Design with R*. Boca Raton: Chapman Hall/CRC Press
- Rizzo, M.L., 2007: *Statistical Computing with R*. Boca Raton: Chapman Hall/CRC Press
- Robert, C.P.R., Casella, G., 2010: *Introducing Monte Carlo Methods with R*. New York: Springer
- Rousseeuw, P.J., van Zomeren, B.C., 1990: Unmasking multivariate outliers and leverage points. *J. Amer. Statist. Assoc.* 85: 633–651
- Rouso, D., Panidis, D., Gkoutzioulis, F., Kourtis, A., Mavromatidis, G., Kalahanis, I., 2002: Effect of the interval between pregnancies on the health of mother and child. *European Journal of Obstetrics and Gynecology and Reproductive Biology* 105(1):4–6
- Russell Bernard, H., 2006: *Research Methods in Anthropology. Qualitative and Quantitative Approaches*. Fourth Edition. New York: Rowman and Littlefield Publishers
- Rücker, G., Schwarzer, G., Carpenter, J., Olkin, I., 2009: Why add anything to nothing? The arcsine difference as a measure of treatment effect in meta-analysis with zero cells. *Statistics in Medicine* 28(5): 721–738
- Seidman, D.S., Ever-Hadani, P., Stevenson, D.K., Slater, P.E., Harlap, S., Gale, R., 1988: Birth Order and Birth Weight Reexamined. *Obstetrics and Gynecology* 72(2): 158–162
- Shaffer, J.P., 1995: Multiple hypothesis testing. *Annual Review of Psychology* 46: 561–576
- Schaie, K.W., 2000: The impact of longitudinal studies on understanding development from young adulthood to old age. *Inter-*

- national Journal of Behavioral Development* 24: 257–266
- Scheffe, 1953: *The Analysis of Variance*. Hoboken: John Wiley Sons
- Schmidt, E., 1888: Catalog der im anatomischen Institut der Universität Leipzig aufgestellten craniologischen Sammlung des Herrn Dr. Emil Schmidt. *Archiv für Anthropologie* 17. Braunschweig: Vieweg und sohn
- Singh, D., Jit, I., 1996: Identification of sex from the volume of the clavicle. *Journal of the Anatomical Society of India* 45(2): 119–124
- Singh, S., Gangrade, K.C., 1968: The sexing of adult clavicles – demarking points for Varanasi zone. *Journal of the Anatomical Society of India* 17: 89–100
- Smirnov, N.V., 1933: Estimate of deviation between empirical distribution functions in two independent samples. *Bulletin Moscow University* 2: 3–16
- Sovinová, H., Sadílek, P., Csémy, L., 2012: Vývoj prevalence kuřáctví v dospělé populaci ČR. Názory a postoje občanů ČR k problematice kouření (období 1997–2011). Výzkumná zpráva. Státní zdravotní ústav.
- Spector, P., 2008: *Data Manipulation with R*. New York: Springer
- Stephens, M.A., 1974: EDF statistics for goodness of fit and some comparisons. *Journal of the American Statistical Association* 69: 730–737
- Stewart, T. D., 1970: Identification of the scars of parturition in the skeletal remains of females. In: Stewart, T.D. (ed.) *Personal identification in mass disasters. Report of a seminar held in Washington, D.C., 9–11 December 1968, by arrangement between the Support Services of the Department of the Army and the Smithsonian Institution*. Washington, D.C.: National Museum of Natural History, Smithsonian Institution, 127–135
- Suess, E.A., Trumbo, B.E., 2010: *Introduction to Probability Simulation and Gibbs Sampling with R*. New York: Springer
- Suchý, J., 1967: Nejčastěji používané metody zpracování antropologického materiálu. In: Fetter, V. a kol., 1967: *Antropologie*, 173–196. Praha: Academia
- Swaab, D.F., Gooren, L.J., Hofman, M.A., 1992: Gender and sexual orientation in relation to hypothalamic structures. *Hormone Research* 38(2): 51–61
- Swamy, G.K., Edwards, S., Gelfand, A., James, S.A., Miranda, M.L., 2012: Maternal age, birth order, and race: differential effects on birthweight. *Journal of Epidemiology and Community Health* 66(2): 136–142
- Szilvánssy, J., 1988: Altersdiagnose am Skelett. In: Knussmann, R. (ed.) *Anthropologie. Handbuch der vergleichenden Biologie des Menschen (4. Auflage des Lehrbuchs der Anthropologie begründet von Rudolf Martin)*, Band I und II. Jena, New York, Stuttgart: Gustav Fischer
- Šefčáková, A., Katina, S., 2008: Geometrical analysis of adult skulls from Předmostí. In: Velemínská, J., Brůzek, J. (eds.) *Early modern humans from Předmostí nr. Přešov: Old documentation and new reading*. Praha: Academia, 87–101
- Šefčáková, A., Katina, S., Mizera, I., Halouzka, R., Barta, P., Thurzo, M., 2011: A late upper palaeolithic skull from Moca (The Slovak Republic) in the context of central Europe. *Acta Musei Nationalis Pragae: Series B: Historia naturalis* 67(1–2): 3–22
- Šidák, Z., 1967: Rectangular Confidence Regions for the Means of Multivariate Normal Distributions. *Journal of the American Statistical Association* 62(318): 626–633
- Štouračová, B., 1992: *Variabilita ušního boltce u brněnských vysokoškoláků*. Magisterská diplomová práce. Brno: Masarykova univerzita
- Šťastná, A., 2010: Změny reprodukčních vzorců a individuální souvislosti rodičovství. *Demografie* 52(4): 77–88
- Titlbachová, S., 1967: Somatoskopie. In: Fetter, V. a kol., *Antropologie*. Praha: Academia
- Tukey, J.W., 1949: Comparing Individual Means in the Analysis of Variance. *Biometrics* 5(2): 99–114
- Tukey, J.W., 1953: The problem of multiple comparisons. Unpublished manuscript. In *The Collected Works of John W. Tukey VIII. Multiple Comparisons: 1948–1983*. New York: Chapman & Hall
- Tukey, J.W., 1962: The Future of Data Analysis. *The Annals of Mathematical Statistics* 31: 385–391
- Tukey, J.W., 1991: The philosophy of multiple comparisons. *Statist. Sci.* 6: 100–116
- Ugarte, M.D., Militino, A.F., Arnholt, A.T., 2008: *Probability and Statistics with R*. Boca Raton: Chapman Hall/CRC Press
- Ulijaszek, S.J., Kerr, D.A., 1999: Anthropometric measurement error and the assessment of nutritional status. *British Journal of Nutrition* 82: 165–177
- Ulijaszek, S.J., Lourie, J.A., 1994: Intra- and inter-observer error in anthropometric measurement. In: Ulijaszek, S.J., Mascie-Taylor, C.G.N. (eds.) *Anthropometry: the individual and the population*. Cambridge: Cambridge University Press
- Venables, W.N., Ripley, B.D., 2002: *Modern Applied Statistics with S*. New York: Springer
- Venables, W. N., Smith, D.M., the R Core Team, 2013: *An Introduction to R. Notes on R: A Programming Environment for Data Analysis and Graphics* Version 3.0.1 (2013-05-16). Vienna: R Foundation for Statistical Computing
- Verzani, J., 2005: *Using R for Introductory Statistics*. Boca Raton: Chapman & Hall/CRC Press
- von Bortkiewicz, L., 1898: Das Gesetz der kleinen Zahlen [The law of small numbers]. Leipzig: B.G. Teubner
- Vondrušková, L., 1983: *ABO/H/ systém*. Magisterská diplomová práce. Brno: Masarykova univerzita
- Waalder, H.T., 1984: Height, Weight and Mortality: The Norwegian Experience. *Acta Medica Scandinavica, Supplementum* 679: 1–56
- Walker, J., Almond, P., 2010: *Interpreting statistical findings*. Maidenhead: Open University Press
- Wasserman, L., 2006: *All of Nonparametric Statistics*. New York: Springer
- Weill, C.L., ed., 2009: *Natures Choice. What Science Reveals About the Biological Origins of Sexual Orientation*. New York: Taylor and Francis
- Welch, B.L., 1947: The generalization of Student's problem when several different population variances are involved. *Biometrika* 34(1–2): 28–35
- White, K.R., 1980: Socio-economic status and academic achievements. *Evaluation in Education* 4: 79–81
- Wilks, S.S., 1948: Order statistics. *Bulletin of the American Mathematical Society* 54(1): 6–50
- Wilson, E.B., 1927: Probable inference, the law of succession, and statistical inference. *Journal of the American Statistical Association* 22: 209–212
- Wood, W., Milner, R., Harpending, C., Weiss, M., 1992: The Osteological Paradox: Problems of Inferring Prehistoric Health from Skeletal Samples. *Current Anthropology* 33(4): 343–370
- Woolf, B., 1955: On estimating the relation between blood groups and disease. *Annals of Human Genetics* 19(4): 251–253
- Yekutieli, H., Benjamini, Y., 1999: Resampling-based false discovery rate controlling multiple test procedures for correlated test statistics. *Journal of Statistical Planning and Inference* 82: 171–196
- Zvára, K., 1999: Statistika v antropologii. In: Stloukal, M. a kol. 1999: *Antropologie. Příručka pro studium kostry*, 433–479. Praha: Národní muzeum
- Zvára, K., 2001: *Biostatistika*. Praha: Nakladatelství Karolinum
- Živný, M., 2010: *Antropologické zpracování lidských kosterních pozůstatků ze hřbitova u kostela sv. Jakuba v Brně: Výsledky paleodemografické a osteometrické analýzy*. Brno: Akademické nakladatelství CERM

Register

dáta

- databáza, 25
 - bezpečnosť, 26
 - databázový management, 26
 - databázový programátor, 26
 - databázový projekt, 26
 - kontrola kvality, 26
 - štatistický programátor, 26
 - uzamknutie, 27
 - zmrazenie, 27
 - zoznam formulárov, 26
- dokumentácia, 21
- hlavné atribúty, 18
- objektívnosť, 18
- platnosť, 18
- reliabilita, 18
- reprezentatívnosť, 18
- spôhlivosť, 18
- validita, 18
- chyba merania, 21
 - maskovanie, 25
- metódy zberu, 18
 - dotazník, 19
 - observačné, 18
 - rozhovor, 19
- odľahlé pozorovanie, 85
- otázky, 21
- presnosť merania, 21
- realizácie, 33, 80
 - abundančná matica, 24
 - dátová tabuľka, 24
 - incidenčná matica, 24
 - kontingenčná tabuľka, 50–52, 90
 - matica, 24
 - pole, 24
 - skalár, 24
 - tabuľka početností, 24
 - usporiadané, 80
 - vektor, 24
- stratifikácia, 25
- stratifikačné skupiny, 25
- škála, 19
- štatistické požiadavky, 19
 - jednoznačnosť, 19
 - nezávislosť, 19
 - úplnosť, 19
- triedenie
 - dĺžky triednych intervalov, 24
 - ekvidistantné intervaly, 24
 - hranice triednych intervalov, 24
 - jednostupňové, 24
 - počet triednych intervalov, 24
 - stredu triednych intervalov, 24
 - triedy, 24
 - viacstupňové, 24
- z-skóre, 86
- zaslepenie, 25
 - dvojité, 25
- znáhodnená alokácia, 25
 - alokačný pomer, 25
 - permutačný blokový princíp, 25
- znáhodnenie, 25

dátový súbor

- anova-head.txt, 39, 141, 234, 252, 253, 284
- anova-means-skull.txt, 283
- anova-newborns.txt, 36, 249, 285
- lin-uhl-fm.txt, 171, 277
- more-samples-correlations-skull.txt, 263, 286
- more-samples-probabilities-pubis .txt, 270

- more-samples-probabilities-pubis.txt, 39, 287
- more-samples-variances-clavicle.txt, 86, 104, 259, 285
- multinom-blood-groups.txt, 49, 51, 104, 268, 290
- multinom-earlobe.txt, 49, 51, 104, 290
- multinom-iris-color.txt, 49, 51, 104, 287
- multinom-palmar-lines.txt, 49, 51, 104, 271, 288
- one-sample-correlation-skull-mf.txt, 36, 43, 45, 72, 89, 104, 141, 169, 276
- one-sample-mean-skull-mf.txt, 36, 41, 60, 72, 86, 89, 97–99, 150–152, 273
- one-sample-probability-sexratio.txt, 73, 179, 181, 278
- one-sample-variance-skull-mf.txt, 163, 164, 275
- paired-means-clavicle.txt, 153, 154, 156, 158, 273
- paired-means-clavicle2.txt, 36, 41, 60, 72, 89, 104, 141, 275
- two-samples-correlations-trunk.txt, 39, 100, 104, 207, 281
- two-samples-means-birth.txt, 36, 97, 102, 197, 280
- two-samples-means-skull.txt, 39, 104, 199, 280
- two-samples-probabilities-sexratio.txt, 38, 73, 224, 282
- two-samples-variances-skull.txt, 202, 281
- uhl-uhl-fm.txt, 173, 277

efekt, 39

- korelačný koeficient, 165
- podiel rozptylov, 199
- pomer šancí, 209
- pomer rizík, 209
- pravdepodobnosť, 175
- relatívne riziko, 209
- rozdiel korelačných koeficientov, 204
- rozdiel rizík, 209
- rozdiel stredných hodnôt, 191
- rozptyl, 159
- stredná hodnota, 122, 144, 152

funkcia vierohodnosti, 62

- binomického rozdelenia, 63, 221
- Fisherova miera informácie, 64
 - očakávaná, 64
 - pozorovaná, 64
- jadro, 63
- kvadratická aproximácia, 64, 65, 67, 70
- logaritmus, 63
- maximalizácia, 69
- multinomického rozdelenia, 63
- normálneho rozdelenia, 67, 149, 162, 168, 195, 201, 202, 205, 206, 233, 256–258, 261, 262, 266, 269, 270
- Poissonovho rozdelenia, 64
- pomer vierohodnosti
 - jednoduchý, 120
 - zovšeobecnený, 120
- profilová, 68
 - zakrivenie, 68
- relatívna, 120
- skóre funkcia, 64, 66, 70
- štandardizovaná, 120
- Taylorov rozvoj, 70

graf

- bodový, 91
- empirická distribučná funkcia, 99
- exploratórna analýza dát, 33, 89
- histogram, 89, 96
 - Freedman-Diaconisova formula, 96
 - kumulatívnych početností, 99
 - súčtový, 99
 - Scottova formula, 96
 - Sturgesova formula, 96

- v absolútnej škále, 96
 - v relatívnej škále, 96
 - koláčový, 94
 - krabicový diagram, 99
 - so zárezom, 99
 - kruhový diagram, 94
 - kvantilový diagram, 101
 - Atkinsonova obálka, 101
 - odtiene
 - farby sivej, 95
 - farieb dúhy, 95
 - teplých farieb, 95
 - topografických farieb, 95
 - qq-diagram, 101
 - rozptylový, 91
 - spinogram, 90
 - stĺpcový diagram, 89
 - výsekový diagram, 94
 - veková pyramída, 89
- charakteristika polohy
- aritmetický priemer, 80
 - decil, 80, 106
 - dolný kvartil, 78, 80, 106
 - druhý kvartil, 80, 106
 - horný kvartil, 78, 80, 106
 - maximum, 80
 - medián, 77, 80, 106
 - minimum, 80
 - modus, 80
 - päťčíselný súhrn, 80
 - percentil, 78, 80, 106
 - poradie, 81
 - prvý kvartil, 80, 106
 - stredná hodnota, 77
 - stredná hodnota mediánu, 79
 - strednoporadie, 81
 - tretí kvartil, 80, 106
 - urezaný aritmetický priemer, 81
 - winsorizovaný aritmetický priemer, 82
- charakteristika variability
- decilové rozpätie, 84
 - koeficient šikmosti, 83
 - koeficient špicatosti, 83
 - koeficient variácie, 77, 82, 113
 - kvartilový koeficient šikmosti, 84
 - kvartilový koeficient variácie, 84
 - medzikvartilové rozpätie, 83
 - oktilový koeficient šikmosti, 85
 - percentilové rozpätie, 84
 - priemer absolútnych odchýlok, 83
 - rozpätie, 79, 83
 - rozptyl, 77, 82
 - rozptyl aritmetického priemeru, 83
 - rozptyl mediánu, 79
 - smerodajná odchýlka, 82
 - stredná chyba priemeru, 83
 - suma štvorcov, 83
 - štandardná chyba, 83
 - suma absolútnych odchýlok, 83
 - urezaný rozptyl, 84
 - vnútorné hradby, 84
 - vonkajšie hradby, 84
 - winsorizovaný rozptyl, 84
- chyba
- druhého druhu, 105
 - interindividuálna, 5, 152
 - intraindividuálna, 5, 152
 - kalibrácie meracieho prístroja, 21
 - koeficient reliability, 23
 - náhodná, 22
 - registrácie, 22
 - priemerná kvadratická, 113
 - prvého druhu, 105
 - relatívna technická chyba merania, 22
 - systematická
 - kombinovaná, 21
 - merania, 21
 - prístroja, 21
 - spôsobená externými faktormi, 21
 - technická chyba merania, 22
- interval
- dĺžka, 115
 - dvojstranný, 113
 - elipsa spoľahlivosti, 121
 - elipsoid spoľahlivosti, 121
 - empirický, 114
 - jednostranný, 113, 117
 - koeficient spoľahlivosti, 105, 113
 - konzervatívny, 118
 - liberálny, 118
 - obojsstranný, 117
 - pravdepodobnosť pokrytia
 - aktuálna, 118
 - nominálna, 118
 - skutočná, 118
 - spoľahlivosti, 113
 - skóre, 177
 - vierohodnostný, 121, 127, 128, 150, 162, 169, 178, 187, 202, 207, 222
 - Waldov, 125, 144, 160, 166, 175, 186, 190, 200, 204, 212, 213, 216, 217, 219, 220
 - šírka, 115
- knížnica
- Hmisc, 97
 - MASS, 45
 - PASWR, 132
 - car, 101
 - kolmim, 79
 - mvtnorm, 45
 - nortest, 140
 - scatterplot3d, 91
 - sm, 98
 - utils, 35
 - vcd, 90
- konvergenca
- podľa pravdepodobnosti, 109
 - skoro všade, 109
 - v distribúcii, 110
 - v kvadratickom strede, 109
- kritická hodnota, 107
- Fisherovho rozdelenia, 107
 - χ^2 rozdelenia, 107
 - normálneho rozdelenia, 107
 - Studentovho rozdelenia, 107
- kvantil, 106
- Fisherovho rozdelenia, 106
 - χ^2 rozdelenia, 106
 - normálneho rozdelenia, 106
 - Studentovho rozdelenia, 106
- metóda
- BFGS, 71
 - Brent-Dekkerova metóda, 130
 - Brentova, 130
 - dotyčníc, 69
 - Fisherova skóringová, 71
 - Nelder-Meadova, 71
 - Newton-Raphsonova, 69
 - Newtonova, 69
 - quasi Newtonova, 71
 - sečníc, 130
 - simplexov, 71
 - sukcesívnej parabolickej interpolácie, 70
 - zlátého rezu, 70
- model, 34
- aplikácia na dáta, 33
 - distribučná funkcia, 33
 - funkcia hustoty, 33
 - množina modelov, 34
 - na dáta, 33
 - neparametrický, 40
 - parametrický, 33, 40
 - pre štatistiku, 33

- pre chyby, 33
 - pre testováciu štatistiku, 33
 - rozdelenia pravdepodobnosti, 2, 15, 33, 39
 - štatistická inferencia, 34
 - štatistický, 2, 11–13, 15, 24, 27, 28, 33
- parameter, 39
- odhad
 - asymptoticky nevychýlený, 110
 - asymptoticky normálny, 111
 - intervalový, 113
 - konzistentný, 110
 - konzistentný a asymptoticky efektívny, 111
 - lepší, 110
 - maximálne vierohodný, 63, 64, 69
 - nevychýlený, 110
 - vlastnosti odhadu, 112
 - vychýlený, 110
- premenná, 1, 23
- mätúca, 11
 - nezávislá, 2
 - pozri znak, 23
 - závislá, 1, 2
- rozdelenie
- asymptotické, 116
 - diskrétné, 35
 - binomické, 47, 208
 - multinomické, 49, 54
 - negatívne binomické, 54, 56
 - Poissonovo, 52, 54, 56
 - súčinové multinomické, 50
 - ZIP, 135
 - funkcie parametra, 209
 - marginálne, 42, 49, 56
 - parametra
 - normálne, 121, 128, 166
 - pivotovej štatistiky, 114
 - podmienené, 54
 - poriadkovej štatistiky, 78
 - pravdepodobnosti, 2, 15, 33
 - spojité, 36
 - dvojjazmerné normálne, 42, 204
 - exponenciálne, 59
 - Fisherovo, 106, 107, 109
 - gama, 56
 - χ^2 , 106
 - normálne, 41, 75, 76, 84–86, 96, 100, 101, 119, 131, 138
 - rovnomerné, 59
 - štandardizované dvojjazmerné normálne, 44
 - štandardizované normálne, 41, 57, 107
 - Studentovo, 106–108
 - stupne voľnosti, 107
 - symetrické, 80, 99
 - štatistiky
 - normálne, 119
 - testovacej štatistiky
 - Fisherovo, 118, 199
 - χ^2 , 118, 136, 159
 - necentrálne Studentovo, 144, 191
 - normálne, 118, 119, 204, 215–220
 - Studentovo, 118, 144, 169, 191
 - zošikmené, 75, 86, 96
 - ľavostranne, 47, 80, 99
 - negatívne, 80
 - pozitívne, 80
 - pravostranne, 47, 80, 99
- štúdia
- účely, 1
 - analytická, 2
 - biologické súvislosti, 1
 - ciele, 1, 3
 - hlavné, 4
 - vedľajšie, 5
 - vedecká otázka, 5
 - deskriptívna, 2
 - dizajn, 1
 - experimentálna, 6
 - hypotézy, 1
 - interná, 3
 - klinická, 2
 - klinické vyšetrenia, 2
 - kontrola kvality, 5
 - kostrových pozostatkov, 14
 - metóda, 3
 - meta-analýza, 7
 - metodika, 3
 - observačná, 6
 - audit pacientov, 7
 - kohortová, 9
 - kvalitatívna, 7
 - plán, 11
 - prípadov a kontrol, 9
 - prípadová, 7
 - prierezová, 8
 - sekvenčná, 11
 - semilongitudinálna, 11
 - opis štatistickej analýzy, 2
 - opisná, 2
 - plán, 1
 - subjekty, 1
 - systematický prehľad, 7, 13
 - technika, 3
 - translačná, 7
 - trvanie, 2
 - validita, 3
 - externá, 3
 - konštrukčná, 3
 - štatistických záverov, 3
 - validizácia
 - externá, 5
 - interná, 5
 - zákroky, 2
- štatistika, 11
- abundancia, 11
 - frekvencia, 11
 - incidencia, 11
 - kumulatívna incidencia, 11
 - kumulatívna prevalencia, 11
 - pivot, 114
 - pivotová, 114
 - počet, 11
 - početnosť, 11
 - poriadková, 77
 - postačujúca, 60
 - prevalencia, 11
 - testovania, 61, 105
 - pomerom vierohodnosti, 120, 126, 150, 152, 162, 169, 178, 187, 194–196, 202, 206, 222, 233, 258, 262, 266, 269, 271
 - skóre, 120, 177, 187, 267, 270, 271
 - typy, 121
 - Waldova, 120, 122, 144, 159, 166, 169, 175, 185, 189, 191, 199, 204, 211, 212, 215–220, 266, 270, 271
- test
- štatistický, 105
 - dobrej zhody
 - χ^2 , 131
 - Kolmogorov-Smirnovov, 137
 - Lillieforsov, 139
 - dvojvýberový
 - alternatívny Z-test o logaritme pomeru šancí, 219
 - alternatívny Z-test o logaritme relatívneho rizika, 216
 - alternatívny Z-test o rozdiel pravdepodobností, 212
 - alternatívny Z-test o pomere šancí, 220
 - alternatívny Z-test o relatívnom riziku, 217
 - F-test o podiele rozptylov, 199
 - t-test o rozdiel stredných hodnôt, 191
 - Welchov t-test o rozdiel stredných hodnôt, 191
 - Z-test o logaritme pomeru šancí, 218

Z -test o logaritme relatívneho rizika, 215
 Z -test o pomere šancí, 220
 Z -test o relatívnom riziku, 217
 Z -test o rozdiel korelačných koeficientov, 204
 Z -test o rozdiel pravdepodobností, 211
 Z -test o rozdiel stredných hodnôt, 189
 hladina významnosti, 106, 115, 116
 pozorovaná, 117
 hypotéza
 alternatívna, 105
 jednostranná, 115–117
 nezamietanie, 116, 117
 nulová, 105
 obojsstranná, 115–118
 zamietanie, 116, 117
 jednovýberový
 χ^2 -test o rozptyle, 159
 Studentov t -test o strednej hodnote, 144
 Z -test o λ , 185
 Z -test o korelačnom koeficiente, 166
 Z -test o pravdepodobnosti, 175
 Z -test o strednej hodnote, 122
 konzervatívny, 118
 kritická hodnota, 116, 120
 liberálny, 118
 Neyman-Pearsonov prístup, 106
 oblasť
 kritická, 105
 nezamietania, 105, 115
 zamietania, 105
 obor
 kritický, 116, 124, 144, 160, 166, 175, 185, 189, 191,
 200, 204, 211, 212
 nezamietania, 105, 115, 116
 zamietania, 116
 p-hodnota, 117, 118, 144, 160, 166, 175, 186, 190, 192,
 200, 204, 211, 212, 216, 217, 219, 220
 párový
 Studentov t -test o strednej hodnote, 152
 sila, 105
 silofunkcia, 106, 124, 144, 160, 166, 175, 185, 189, 191,
 200, 204, 211, 212
 testovacie kritérium, 116
 výsledok
 hraničná štatistická signifikancia, 117
 štatisticky nesignifikantný, 117
 štatisticky signifikantný, 117
 viacvýberový
 Bartlettov test o homogenite rozptylov, 258
 F -test o rovnosti stredných hodnôt, 230
 χ^2 -test o homogenite korelačných koeficientov, 261
 χ^2 -test o homogenite pravdepodobností, 270
 χ^2 -test o homogenite vektorov pravdepodobností,
 271
 χ^2 -test v multinomickom rozdelení, 266
 nepravdepodobnostný, 16
 počet návštev, 28
 pomer vyšetrených ku zahrnutým, 28
 pravdepodobnostný, 16
 propagácia, 28
 protokol, 29
 rozsah, 33
 minimálny, 27, 124, 167, 176, 205
 selektívny, 17
 školenie subjektov, 28
 štatistické jednotky, 15
 štatistický súbor, 15
 typu snehovej gule, 17
 typu vhodnosti a príležitosti, 17
 typy, 15
 výberové jednotky, 15
 vedecká etika, 29
 vyšetrenie, 30
 základný súbor, 15
 zámerný, 17
 zápis subjektov do štúdie, 29
 znak, 23
 kardinálny, 23
 kvalitatívny, 24
 alternatívny, 24
 binárny, 24
 neusporiadaná kategorizácia, 24
 nominálny, 24
 ordinálny, 24
 usporiadaná kategorizácia, 24
 kvantitatívny, 23
 diskrétny, 23
 frekvencia, 24
 intervalový, 23
 spojitý, 23
 výskyt, 24
 metrický, 23
 pozri premenná, 23
 prognostický, 25
 realizácie, 24
 škála merania, 23

výber

alokačný čas, 28
 chyba
 registrácie, 17
 reprezentatívnosti, 17
 dobrovoľníci, 17
 informovaný súhlas, 28, 29
 infraštruktúra, 28
 kontrola, 29
 kritériá
 prijímacie, 29
 vylučovacie, 29
 nábor, 30
 náhodný, 16
 homogénny, 85
 jednoduchý, 16
 mechanický, 16
 oblastný, 16
 skupinový, 16
 stratifikovaný, 16
 systematický, 16
 usporiadaný, 77

Aplikovaná štatistická inferencia I

Biologická antropológia očami matematickej štatistiky

Dnešný antropológický výskum sa bez uplatnenia štatistického uvažovania nezaobíde. I keď sa väčšina biológov, lekárov ani antropológov štatistikmi nikdy nestanú, výsledky výskumov i možnosti ich publikácie na správnom usporiadaní a štatistickom spracovaní dát silno závisia. Kľúčovým pre obojstranne úspešnú spoluprácu preto je na strane týchto odborov porozumieť základom štatistických postupov, vedieť sa vyjadrovať aspoň základnou štatistickou terminológiou a vedieť štatistikovi vysvetliť svoj výskumný zámer; na strane štatistika potom pochopiť podstatu zamerania jednotlivých odborov, charakter ich metodológie a typické problémy, s ktorými sa po štatistickej stránke stretávajú. Jedným z cieľov tejto knihy je podporiť kladný prístup mladých ľudí k využívaniu štatistických prostriedkov v antropológii a ďalších odboroch a umožniť ich aplikáciu v prostredí programu \mathbb{R} , univerzálneho výpočtového prostredia, voľne dostupného všetkým. Táto kniha nie je „kuchárskou knihou“ (pretože matematická štatistika nie je knihou receptov alebo návodov), nie je ani „teoretickou matematickou štatistikou“ (pretože teória je vysvetlená prostredníctvom príkladov pochádzajúcich z reality praxe biologickej antropológie) a nie je ani „učebnicou prostredia \mathbb{R} “ (pretože program \mathbb{R} je v knihe použitý len ako nástroj, prostredníctvom ktorého sú riešené reálne situácie). Čím teda kniha je? Kniha je unikátnou kombináciou sily teoretického základu matematickej štatistiky implementovaného v prostredí \mathbb{R} s cieľom pochopiť a riešiť praktické situácie z biologickej antropológie (ako aj biológie a medicíny). Internetová stránka knihy: <http://www.math.muni.cz/pro-studenty/ucebni-text-el-podoba/352-aplikova-statisticka-inferencia.html>

Katina, Stanislav (*1976), bioštatistik; v súčasnosti pôsobí ako docent a vedúci Oddelenia aplikovanej matematiky na Ústave matematiky a štatistiky Masarykovej univerzity a tiež ako Honorary Research Fellow na School of Mathematics and Statistics (The University of Glasgow). Dlhodobou pôsobil v zahraničí na univerzitách v USA, Kanade, Nemecku, Rakúsku, Francúzsku a Veľkej Británii. Je členom výkonného výboru International Society for Clinical Biostatistics a členom dvoch subkomisií National Groups a Statistics in Regulatory Affairs v tejto spoločnosti. Vo vedeckej činnosti sa venuje biomedicínskym štatistickým analýzám v kardiológii, neurológii, imunológii a antropológii, štatistickej analýze tvaru a obrazu, časopriestorovému štatistickému modelovaniu elektroencefalografických signálov, elektrických signálov srdca a biogeografických javov, dizajnu klinických, medicínskych a antropológických štúdií, štatistickej vizualizácii a implementácii štatistických a numericko-matematických metód do jazyka \mathbb{R} . Kontakt: Oddelení aplikovanej matematiky, Ústav matematiky a štatistiky, Přírodovědecká fakulta, Masarykova univerzita, Kotlářská 267/2, 611 37, Brno, Česká republika, e-mail: katina@math.muni.cz, tel.: 00420-549-49-7265. Internetová stránka: <http://www.muni.cz/sci/people/Stanislaw.Katina>

Králík, Miroslav (*1973), antropológ; v súčasnosti pôsobí ako docent Ústavu antropológie Přírodovědecké fakulty Masarykovej univerzity. Zaoberá sa teoretickými aspektmi sexuálneho dimorfizmu, jeho variabilitou, prenatálnou a postnatálnou ontogenezou, významom sexuálneho dimorfizmu z hľadiska ľudského konania a sexuality, a tiež praktickými aplikáciami sexuálneho dimorfizmu vo forennej oblasti a archeológii. Po metodologickej stránke sa venuje aplikácii a rozvoju moderných morfometrických prístupov v antropológii. Kontakt: Laboratoř morfologie a forenzní antropologie, Ústav antropologie, Přírodovědecká fakulta, Masarykova univerzita, Kotlářská 267/2, 611 37, Brno, Česká republika, e-mail: mirekkralik@seznam.cz, tel.: 00420-549-49-4966. Internetová stránka: <http://www.muni.cz/sci/people/Miroslav.Kralik>

Hupková, Adela (*1985, rod. Koprlová), antropológka so zameraním na kostrovú a dentálnu antropológiu; v súčasnosti pôsobí ako asistentka Ústavu antropológie Přírodovědecké fakulty Masarykovej univerzity. Zaoberá sa ontogenezou človeka, vplyvom vývinového stresu na rozvoj bilaterálne symetrických znakov, indikátormi stresu na zuboch a kostrových pozostatkoch človeka. Po metodologickej stránke sa venuje aplikácii histologických analýz mikroštruktúry tvrdých zubných tkanív v antropológii a bioarcheológii. Kontakt: Laboratoř morfologie a forenzní antropologie, Ústav antropologie, Přírodovědecká fakulta, Masarykova univerzita, Kotlářská 267/2, 611 37, Brno, Česká republika, e-mail: hupkova@sci.muni.cz, tel.: 00420-549-49-4073. Internetová stránka: <http://www.muni.cz/sci/people/Adela.Hupkova>

