



VILIJANDAS BAGDONAVIČIUS
JULIUS JONAS KRUOPIS
RŪTA LEVULIENĖ

MATEMATINĖS STATISTIKOS UŽDAVINYNAS



440

**VILIJANDAS BAGDONAVIČIUS
JULIUS JONAS KRUOPIS
RŪTA LEVULIENĖ**

**MATEMATINĖS
STATISTIKOS
UŽDAVINYNAS
SU SPRENDIMAIS**

VILNIAUS UNIVERSITETO LEIDYKLA
2019

Apsvarstė ir rekomendavo išleisti Vilniaus universiteto Matematikos ir informatikos fakulteto taryba (2019 m. gegužės 31 d., protokolas Nr. (1.5) 110000-TPN-24)

Recenzentai:

prof. habil. dr. Algimantas Bikėlis (Vytauto Didžiojo universitetas)

prof. dr. Kęstutis Dučinskas (Klaipėdos universitetas)

Leidinio bibliografinė informacija pateikiama Lietuvos nacionalinės Martyno Mažvydo bibliotekos Nacionalinės bibliografijos duomenų banke (NBDB)

ISBN 978-609-07-0247-5

© Vilijandas Bagdonavičius, 2019
© Julius Jonas Kruopis, 2019
© Rūta Levulienė, 2019
© Vilniaus universitetas, 2019

Turinys

Pratarmė	6
Trumppiniai ir žymenys	7
I. Parametrinė statistika	9
I.1. Empirinės charakteristikos	9
I.1.1. Statistinis modelis	9
I.1.2. Empirinė pasiskirstymo funkcija ir tankis	11
I.1.3. Pozicinės statistikos	11
I.1.4. Empiriniai momentai ir jų funkcijos	15
I.1.5. Sprendimai, nurodymai, atsakymai	20
I.2. Parametru įvertinai	42
I.2.1. Įvertinai ir jų klasifikacija	42
I.2.2. Pakankamosios statistikos. NMD įvertinai	43
I.2.3. Rao ir Kramerio nelygybė. Efektyvieji įvertinai	50
I.2.4. Įvertinių radimo metodai	54
I.2.5. Intervaliniai įvertinai	58
I.2.6. Įverčių radimo pavyzdžiai	62
I.2.7. Sprendimai, nurodymai, atsakymai	65
I.3. Parametrinių hipotezių tikrinimas	115
I.3.1. Statistiniai kriterijai	115
I.3.2. Neimano ir Pirsono lema	117
I.3.3. Skirstiniai, priklausantys nuo vieno parametru	118
I.3.4. Skirstiniai, priklausantys nuo keleto parametru	121
I.3.5. Hipotezių tikrinimas, kai imtys didelės	124
I.3.6. Hipotezių tikrinimo pavyzdžiai	126
I.3.7. Sprendimai, nurodymai, atsakymai	130
II. Tiesiniai modeliai	161
II.1. Gauso ir Markovo tiesinis modelis	161
II.1.1. Mažiausiuju kvadratų metodas	161
II.1.2. Normaliojo skirstinio atvejis	163
II.1.3. Atsakymai, nurodymai, sprendimai	166
II.2. Dispersinė analizė	175
II.2.1. Vienfaktorių dispersinė analizė	175
II.2.2. Dvifaktorių dispersinė analizė	179
II.2.3. Daugiafaktorių dispersinė analizė	184

II.2.4. Nepilni dispersinės analizės planai	186
II.2.5. Atsakymai, sprendimai, nurodymai	189
II.3. Regresinė analizė	207
II.3.1. Prognozavimo uždaviniai	207
II.3.2. Tiesinė vieno kintamojo regresija	209
II.3.3. Tiesinė keleto kintamųjų regresija	212
II.3.4. Kovariacinė analizė	215
II.3.5. Faktoriniai eksperimentai 2^k	219
II.3.6. Apibendrintieji tiesiniai modeliai	220
II.3.7. Sprendimai, atsakymai, nurodymai	224
III. Neparametrinė statistika	243
III.1. Chi kvadrato kriterijus	243
III.1.1. Paprastoji hipotezė	243
III.1.2. Sudėtinės hipotezės	244
III.1.3. Sprendimai, atsakymai, nurodymai	248
III.2. Glodūs Neimano ir Bartono kriterijai	256
III.2.1. Paprastoji suderinamumo hipotezė	256
III.2.2. Sudėtinės suderinamumo hipotezės	257
III.2.3. Sprendimai, atsakymai, nurodymai	258
III.3. Kriterijai, grindžiami empiriniais procesais	261
III.3.1. Pratimai	261
III.3.2. Sprendimai, atsakymai, nurodymai	263
III.4. Ranginiai kriterijai	265
III.4.1. Nepriklausomumo hipotezių tikrinimas	265
III.4.2. Homogeniškumo hipotezių tikrinimas	266
III.4.3. Sprendimai, atsakymai, nurodymai	267
III.5. Kiti neparametriniai kriterijai	269
III.5.1. Pratimai	269
III.5.2. Sprendimai, atsakymai, nurodymai	270
1 priedas. Pagalbinės lentelės	272
2 priedas. Matematinės statistikos lentelės	277
Literatūra	285

Pratarmė

Matematinės statistikos metodų įsisavinimas yra neįsivaizduojamas, jeigu nebandoma jų pritaikyti sprendžiant įvairaus tipo uždavinius.

Kiekvienoje matematinės statistikos knygoje, monografijoje ar vadovelyje pateikiama daug įvairių pratimų. Priklausomai nuo knygos paskirties, didesnis dėmesys skiriamas statistinių metodų taikymui realiems duomenims analizuoti arba teoriniams uždaviniams. Klasikinio tipo vadoveliuose įprastai pateikiami įvairaus sudėtingumo ir tipo uždaviniai, didelis dėmesys skiriamas teoriniams pratimams, kuriuos sprendžiant įsigilinama, kaip konstruojami metodai, sukuriamos jų taikymo rekomendacijos. Tik supratus, kaip gaunami matematinės statistikos rezultatai, galima kvalifikuotai interpretuoti konkrečių statistinių duomenų analizės rezultatus ir, susidūrus su nestandartine situacija, sukurti naują arba pakoreguoti esamą sprendimo metodą.

Daugelyje matematinės statistikos knygų pateikiami teorinio pobūdžio uždaviniai papildo ir išplečia dėstomą medžiagą. Neretai juose pateikiami naujausi matematinės statistikos rezultatai, kuriuos galima rasti mokslinėse publikacijose. Tokie uždaviniai daugumai studentų yra sunkiai įveikiami. Iškyla poreikis matematinės statistikos uždavinyno, kuriamo būtų pateikti teorinių uždavinių sprendimai arba gana detalūs jų sprendimo nurodymai. Be to, tokiam uždavinyne turėtų būti ir praktinių uždavinių, skirtų realių statistinių duomenų analizei ir gautų analizės rezultatų interpretavimui. Iki šiol neturime tokio uždavinyno lietuvių kalba. Šis uždavinynas ir skirtas šiai spragai užpildyti. Iš užsienio kalbomis išleistų tokio pobūdžio uždavinyň paminėsime [6], [9], [10].

Kad suprastų pateikiamų uždavinių sprendimus, skaitytojas turėtų būti išklausęs universitetinės apimties tikimybų teorijos kursą ir įsisavinęs atitinkamų matematinės statistikos skyrių medžiagą, pavyzdžiui, iš vadovėlio [2], [3], [4]. Uždavinius pateikiame iš minėto vadovėlio, papildydami juos uždaviniais iš kitų matematinės statistikos knygų ir uždavinyň. Sprendžiant pratimus pateikiamas nuorodos į taikomas formules, teoremas ar skyrelius iš minėto vadovėlio. Sąvokas ar apibrėžimus galima pasitikslinti minėtame vadovelyje pasinaudojus dalykine rodykle.

Uždavinynas skirtas universitetų statistikos ir matematikos studijų krypčių studen-tams, studijuojantiems matematinės statistikos kursą, taip pat ir kitų mokslinės ar praktinės sričių specialistams, taikantiems matematinės statistikos metodus.

Autoriai

Trumpiniai ir žymenys

A. d. – atsitiktinis dydis;

n. a. d. – nepriklausomi atsitiktiniai dydžiai;

a. v. – atsitiktinis vektorius;

n. a. v. – nepriklausomi atsitiktiniai vektoriai;

TG – tolygiai galingiausias (kriterijus);

TGN – tolygiai galingiausias nepaslinktasis (kriterijus);

DT – didžiausiojo tikėtinumo (funkcija, metodas, ivertinys);

ASE – asymptotinis santykinis efektyvumas (ivertinių, kriterijų);

NMD ivertinys – nepaslinktasis minimalios dispersijos ivertinys

X, Y, Z, \dots – atsitiktiniai dydžiai;

$\mathbf{X}, \mathbf{Y}, \mathbf{Z}, \dots$ – atsitiktiniai vektoriai;

\mathbf{X}^T – transponuotas vektorius, t. y. vektorius – eilutė;

α_k – pradinis k -osios eilės momentas;

μ_k – centrinis k -osios eilės momentas;

γ_1 – asimetrijos koeficientas;

γ_2 – eksceso koeficientas;

$x(P)$ – P -asis kvantilis;

x_P – P -oji kritinė reikšmė;

p_v – P reikšmė;

$\Sigma = [\sigma_{ij}]_{k \times k}$ – kovariacijų matrica;

$\rho = [\rho_{ij}]_{k \times k}$ – koreliacijos koeficientų matrica;

$\mathbf{P}\{A\}$ – įvykio A tikimybė;

$\mathbf{P}\{A|B\}$ – įvykio A sąlyginė tikimybė;

$\mathbf{P}_\theta\{A\}$, $\mathbf{P}\{A|\theta\}$ – tikimybė, priklausanti nuo parametru θ ;

$F_\theta(x)$, $F(x; \theta)$, $F(x|\theta)$ – pasiskirstymo funkcija, priklausanti nuo parametru θ (analogiškai tankio funkcijai);

$\mathbf{E}X$ – a. d. X vidurkis;

$\mathbf{V}X$ – a. d. X dispersija;

$\mathbf{E}_\theta(X)$, $\mathbf{E}(X|\theta)$, $\mathbf{V}_\theta(X)$, $\mathbf{V}(X|\theta)$ – a. d. X vidurkis ar dispersija, priklausantys nuo parametru θ ;

$\mathbf{E}(\mathbf{X})$ – a. v. \mathbf{X} vidurkių vektorius;

$\mathbf{V}(\mathbf{X})$ – a. v. \mathbf{X} kovariacijų matrica;

$\mathbf{Cov}(X, Y)$ – a. d. X ir Y kovariacija;

$\mathbf{Cov}(\mathbf{X}, \mathbf{Y})$ – a. v. \mathbf{X} ir \mathbf{Y} kovariacijų matrica;

$B(n, p)$ – binominis skirstinys su parametrais n ir p ;

$B^-(n, p)$ – neigiamasis binominis skirstinys su parametrais n ir p ;

$\mathcal{P}(\lambda)$ – Puasono skirstinys su parametru λ ;

$H(N, M, n)$ – hipergeometrinis skirstinys su parametrais N, M ir n ;

$N(0, 1)$ – standartinis normalusis skirstinys;

$N(\mu, \sigma^2)$ – normalusis skirstinys su parametrais μ ir σ^2 ;

$LN(\mu, \sigma)$ – lognormalusis skirstinys su parametrais μ ir σ ;

$K(\mu, \sigma)$ – Koši skirstinys su parametrais μ ir σ ;

- $\mathcal{E}(\lambda)$ – eksponentinis skirstinys su parametru λ ;
 $\mathcal{E}(\alpha, \lambda)$ – paslinktasis eksponentinis skirstinys su parametrais α ir λ ;
 $G(\lambda, \eta)$ – gama skirstinys su parametrais λ ir η ;
 $W(\theta, \nu)$ – Veibulo skirstinys su parametrais θ ir ν ;
 $Pa(\alpha, \theta)$ – Pareto skirstinys su parametrais α ir θ ;
 $Be(\gamma, \eta)$ – beta skirstinys su parametrais γ ir η ;
 $U(\alpha, \beta)$ – tolygusis skirstinys intervale (α, β) ;
 $\chi^2(n)$ – chi kvadrato skirstinys su n laisvės laipsnių;
 $\chi^2(n; \delta)$ – necentrinis chi kvadrato skirstinys su n laisvės laipsnių ir necentriškumo parametru δ ;
 $S(n)$ – Stjudento skirstinys su n laisvės laipsnių;
 $S(n; \delta)$ – necentrinis Stjudento skirstinys su n laisvės laipsnių ir necentriškumo parametru δ ;
 $F(m, n)$ – Fišerio skirstinys su m ir n laisvės laipsnių;
 $F(m, n; \delta)$ – necentrinis Fišerio skirstinys su m ir n laisvės laipsnių ir necentriškumo parametru δ ;
 z_α – standartinio normaliojo skirstinio α kritinė reikšmė;
 $t_\alpha(n)$ – Stjudento skirstinio su n laisvės laipsnių α kritinė reikšmė;
 $\chi^2_\alpha(n)$ – chi kvadrato skirstinio su n laisvės laipsnių α kritinė reikšmė;
 $F_\alpha(m, n)$ – Fišerio skirstinio su m ir n laisvės laipsnių α kritinė reikšmė;
 $\mathcal{P}_k(n, \boldsymbol{\pi})$ – k -matis polinominis skirstinys su parametrais n ir $\boldsymbol{\pi} = (\pi_1, \dots, \pi_k)^T$,
 $\pi_1 + \dots + \pi_k = 1$;
 $H_k(N, \mathbf{M}, n)$ – k -matis hipergeometrinis skirstinys su parametrais N , $\mathbf{M} = (M_1, \dots, M_k)^T$ ir n ;
 $N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ – k -matis normalusis skirstinys su vidurkių vektoriumi $\boldsymbol{\mu}$ ir kovariacijų matrica $\boldsymbol{\Sigma}$;
 $X \sim N(\mu, \sigma^2)$ – a. d. X , pasiskirstęs pagal normalujį dėsnį su parametrais μ ir σ^2 (analogiškai kitų skirstinių atveju);
 $X_n \xrightarrow{P} X$ – konvergavimas pagal tikimybę ($n \rightarrow \infty$);
 $X_n \xrightarrow{b.t.} X$ – konvergavimas su tikimybe 1 arba beveik tikrai ($n \rightarrow \infty$);
 $X_n \xrightarrow{k.v.v.} X$ – konvergavimas pagal kvadratinį vidurkį ($n \rightarrow \infty$);
 $X_n \xrightarrow{d} X, F_n(x) \xrightarrow{d} F(x)$ – konvergavimas pagal pasiskirstymą (silpnasis; $n \rightarrow \infty$);
 $X_n \xrightarrow{d} X \sim N(\mu, \sigma^2)$ – a. d. X_n asimptotiškai ($n \rightarrow \infty$) turi normalujį skirstinį su parametrais μ ir σ^2 ;
 $X_n \stackrel{d}{=} Y_n$ – a. d. X_n ir Y_n skirstiniai vienodi;
 $\|\mathbf{x}\|$ – kai $\mathbf{x} = (x_1, \dots, x_k)^T$ yra vektorius, reiškia atstuma $(\mathbf{x}^T \mathbf{x})^{1/2} = (\sum_i x_i^2)^{1/2}$;
 $\|\mathbf{A}\|$ – kai $\mathbf{A} = [a_{ij}]$ yra matrica, reiškia $(\sum_i \sum_j a_{ij}^2)^{1/2}$;
 $\mathbf{A} > \mathbf{B}$ ($\mathbf{A} \geq \mathbf{B}$) – kai \mathbf{A} ir \mathbf{B} yra vienodos dimensijos kvadratinės matricos, reiškia, kad matrica $\mathbf{A} - \mathbf{B}$ yra teigiamai (neneigiamai) apibrėžta.

I. Parametrinė statistika

I.1. Empirinės charakteristikos

I.1.1. Statistinis modelis

I.1.1. Yra dvi nepriklausomos paprastosios a.d. $X \sim B(1, p)$ imtys, kurių didumai yra n_1 ir n_2 . Tegu vieneto pasiodymų skaičiai šiose imtyse yra X_1 ir X_2 . Sudarykite jungtinės imties $\mathbf{X} = (X_1, X_2)^T$ statistinį modelį. Raskite statistikos

$$T = \frac{X_1}{n_1} - \frac{X_2}{n_2}$$

vidurkį ir dispersiją.

I.1.2. Objektų, turinčių savybę A , dalys k populiacijose atitinkamai yra π_1, \dots, π_k .

a) Atsitiktinai parenkama populiacija ir iš jos atsitiktinai imama grąžinant didumo n imtis.

b) Atsitiktinai parenkama populiacija ir iš jos atsitiktinai imamas grąžinant vienas elementas. Procedūra kartojama n kartų.

Sudarykite šiuo eksperimentu statistinius modelius. Raskite statistikos X/n vidurkį ir dispersiją, kai X yra skaičius imties objektų, turinčių savybę A .

I.1.3. (**I.1.2** pratimo tēsinys). Iš kiekvienos populiacijos atsitiktinai imama grąžinant didumo n imtis. Sudarykite šio eksperimento statistinį modelį. Raskite statistikos X/n vidurkį ir dispersiją, kai X yra jungtinės nk didumo imties objektų, turinčių savybę A , skaičius.

I.1.4. Iš populiacijos, kurioje požymį A turinčių objektų dalis lygi π , atsitiktinai imama grąžinant didumo n_1 imtis. Iš tos imties atsitiktinai imama grąžinant didumo n_2 imtis. Sudarykite šio eksperimento statistinį modelį.

I.1.5. (**I.1.4** pratimo tēsinys). Tarę, kad eksperimento metu užregistruojami tik skaičiai X_1 ir X_2 pirmosios ir antrosios imties objektų, turinčių savybę A , sudarykite imties $(X_1, X_2)^T$ statistinį modelį. Raskite statistikos $X_1/n_1 - X_2/n_2$ vidurkį ir dispersiją.

I.1.6. Išspręskite **I.1.5** pratimą, kai imtys imamos atsitiktinai ir negražinant (populiaciją sudaro N elementų, $n_2 < n_1 < N$).

I.1.7. Atrankinei kontrolei pateko N dydžio gaminių partija, kurioje yra nežinomas skaičius M defektinių gaminių. Atsitiktinai imama negražinant n gaminių ir nustatomas defektinių skaičius X iš jų. Sudarykite imties X statistinį modelį.

I.1.8. (**I.1.7** pratimo tēsinys). Tegu partija pripažįstama gera, kai $X \leq c$. Kaip priklauso partijos priėmimo tikimybė nuo šios partijos defektinių gaminiių skaičiaus M ?

I.1.9. Aibę sudaro N objektų, kurie apibūdinami tam tikru požymiu y , t. y. aibė $O_N = \{y_1, \dots, y_N\}$ sudaryta iš požymio y reikšmių. Atsitiktinai imame negražinant $n \leq N$ objektų. Tegu a. v. $\mathbf{X} = (X_1, \dots, X_n)^T$ koordinatė X_i lygi i -ojo parinkto objekto požymio y reikšmei. a) Irodykite, kad a. v. \mathbf{X} koordinatės yra priklausomi a. d. ir imtis nėra paprastoji; sudarykite imties \mathbf{X} statistinį modelį. b) Raskite a. d. $Y = X_1 + \dots + X_n$ vidurkį ir dispersiją. c) Raskite a. d. Y tikimybinę skirstinį, kai $y_i, i = 1, \dots, N$, įgyja tik dvi reikšmes: 0 arba 1.

I.1.10. (**I.1.9** pratimo tēsinys). Išspręskite **I.1.9** pratimą tuo atveju, kai objektai imami atsitiktinai grąžinant.

I.1.11. Tegu $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra dvi paprastosios imtys, gautos stebint nepriklausomus a. d. $X \sim \mathcal{P}(\lambda_1)$ ir $Y \sim \mathcal{P}(\lambda_2)$. Sudarykite jungtinės didumo $m+n$ imties statistinį modelį. Kaip pasikeistų šis modelis, jeigu būtų žinoma, kad $\lambda_1 = \lambda_2$?

I.1.12. Tegu $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra dvi paprastosios imtys, gautos stebint nepriklausomus a. d. $X \sim N(\mu_1, \sigma_1^2)$ ir $Y \sim N(\mu_2, \sigma_2^2)$. Sudarykite jungtinės didumo $m+n$ imties statistinį modelį, jeigu žinoma, kad: a) $\mu_1 = \mu_2$; b) $\sigma_1 = \sigma_2$; c) jokios informacijos apie parametrus nėra.

I.1.13. Tegu $(X_i, Y_i)^T, i = 1, \dots, n$, yra paprastoji atsitiktinė a. v. $(X, Y)^T$, turinčio dvimatį normalųjų skirstinį, imtis. Sudarykite imties statistinį modelį. Kaip pasikeistų statistinis modelis, jeigu būtų žinoma, kad marginalieji atsitiktinių dydžių X ir Y skirstiniai vienodi?

I.1.14. Imties $\mathbf{X} = (X_1, \dots, X_n)^T$ elementai $X_i \sim N(\mu, \sigma^2), i = 1, \dots, n$. Koreliacijos koeficientas $\rho(X_i, X_j) = \rho$, kai $|i - j| = 1$, ir $\rho(X_i, X_j) = 0$, kai $|i - j| > 1$. Sudarykite imties \mathbf{X} statistinį modelį.

I.1.15. Tegu $\mathbf{X}_i = (X_{i1}, \dots, X_{in_i})^T, i = 1, \dots, m$, yra paprastosios atsitiktinės imtys, gautos stebint absoliučiai tolydžius n. a. d. X_1, \dots, X_m . Sudarykite jungtinės imties $\mathbf{X} = (\mathbf{X}_1^T, \dots, \mathbf{X}_m^T)^T$ statistinį modelį, kai žinoma, kad: a) a. d. X_1, \dots, X_m skirstiniai gali skirtis tik poslinkio parametru; b) gali skirtis tik mastelio parametru; c) gali skirtis poslinkio ir mastelio parametrais; d) jokios papildomos informacijos nėra.

I.1.16. Imties $\mathbf{X} = (X_1, \dots, X_n)^T$ nariai yra nepriklausomi absoliučiai tolydūs atsitiktiniai dydžiai. Sudarykite imties \mathbf{X} statistinį modelį. Kaip pasikeistų statistinis modelis, jeigu imtis būtų paprastoji?

I.1.17. Paprastoji atsitiktinė imtis $\mathbf{X}^{(i)} = (X_{1i}, \dots, X_{ki})^T, i = 1, \dots, n$, gauta stebint a. v. $\mathbf{X} = (X_1, \dots, X_k)^T$. Sudarykite imties statistinį modelį, jeigu žinoma, kad a. d. X_1, \dots, X_k marginalieji skirstiniai yra vienodi.

I.1.18. Taškas tolygiai juda tiese greičiu v . Laiko momentais t_1, \dots, t_n užregistruojamas taško nueitas kelias X_1, \dots, X_n ; laiko momentu $t = 0$ taškas buvo taške x_0 . Tarkime, kad matavimo rezultatai tarpusavyje nepriklausomi, matavimo paklaidos neturi sisteminės dedamosios, o atsitiktinė dedamoji pasiskirčiusi pagal normalųjų dėsnį $N(0, \sigma^2)$. Sudarykite imties $\mathbf{X} = (X_1, \dots, X_n)^T$ statistinį modelį.

I.1.19. (**I.1.18** pratimo tēsinys). Sudarykite statistinį modelį tuo atveju, kai žinoma, kad $x_0 = 0$.

I.1.20. Sveriant tą patį kūną n kartų, gauti svérimo rezultatai X_1, \dots, X_n . Tegu jie tarpusavyje nepriklausomi. Pirmųjų k svérimų sisteminė paklaida 0, o likusiųjų – μ . Atsitiktinės visų svérimų paklaidų dedamosios turi normaliuosius skirstinius $N(0, \sigma^2)$. Sudarykite imties $\mathbf{X} = (X_1, \dots, X_n)^T$ statistinį modelį.

I.1.2. Empirinė pasiskirstymo funkcija ir tankis

I.1.21. Tegu $\hat{F}_n(x)$ yra empirinė pasiskirstymo funkcija, gauta iš paprastosios didumo $n = 100$ imties a. d. $X \sim N(1, 4)$. Raskite aproksimaciją tikimybės, kad $\hat{F}_n(0)$ absolютiniu didumu skirsis nuo teorinės pasiskirstymo funkcijos taške $x = 0$ ne daugiau kaip $0,1; 0,05$.

I.1.22. Paprastoji didumo n imtis gauta stebint absolūciai tolydžių a. d. su pasiskirstymo funkcija $F(x)$. Raskite aproksimaciją tikimybės, kad empirinės pasiskirstymo funkcijos $\hat{F}_n(x)$ maksimalus nuokrypis nuo teorinės pasiskirstymo funkcijos neviršys ε . Raskite apytikslę šios tikimybės reikšmę, kai $n = 50; 100$ ir $\varepsilon = 0,1; 0,05$.

I.1.23. Paprastoji imtis gauta stebint a. d. $X \sim \mathcal{P}(3)$. Koks apytiksliai turi būti imties didumas n , kad, vertinant tikimybę $\mathbf{P}\{X = 2\}$ santykiniu dažniu, absolūtinė paklaida neviršytų $0,05$ su tikimybe, ne mažesne už $0,95$?

I.1.24. Lentelėje pateikiama $n = 100$ atsitiktinai atrinktų gaminių tam tikro parametru pamatuotos reikšmės (didumo n paprastosios imties realizacija).

24	41	30	37	25	32	28	35	28	51
36	26	43	25	27	39	21	45	39	25
29	43	66	25	24	56	29	31	41	41
36	57	36	48	25	36	48	24	48	22
40	7	31	24	32	53	33	46	22	33
25	37	34	32	41	36	19	32	25	19
19	37	20	21	48	44	35	19	44	34
29	48	38	43	48	35	42	37	35	36
58	45	34	40	37	21	41	11	41	27
50	24	37	39	33	45	39	43	21	34

a) Sugrupuokite stebinius ilgio $h = 10$ intervalais pradėdami nuo 0.

b) Nubraižykite empirinės pasiskirstymo funkcijos realizacijos grafiką ir histogramą.

I.1.25. (I.1.24 pratimo tēsinys). Palyginkite empirinės pasiskirstymo funkcijos realizacijos grafiką ir histogramą su normaliojo skirstinio pasiskirstymo funkcija ir tankiu (vietoje nežinomų parametru imkime jų empirinius analogus).

I.1.3. Pozicinės statistikos

I.1.26. Paprastoji didumo $n = 50$ imtis gauta stebint a. d., kurio tankis $f(x|\mu) = 2e^{-2(x-\mu)}$, $x > \mu$. Raskite tikimybę, kad $X_{(1)} - \mu \leq 0,05$.

I.1.27. Variacinė eilutė $X_{(1)}, \dots, X_{(n)}$ gauta stebint paslinktą eksponentinę a. d. $X \sim \mathcal{E}(1/\sigma, \mu)$, kurio tankio funkcija

$$f(x|\mu, \sigma) = \frac{1}{\sigma} \exp\left\{-\frac{x-\mu}{\sigma}\right\}, \quad x > \mu.$$

a) Raskite statistikos

$$T = \frac{n(X_{(1)} - \mu)}{W}, \quad (W = \frac{1}{n-1} \sum_{i=2}^n (X_{(i)} - X_{(1)}))$$

tikimybinį tankį. b) Irodykite, kad $X_{(1)}$ skirstinys yra $\mathcal{E}(n/\sigma, \mu)$; a. d. $2(\sum_{i=1}^n X_i - nX_{(1)})/\sigma$ turi χ^2 skirstinį $\chi^2(2n-2)$. c) Tarkime, kad paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $\mathcal{E}(\lambda)$. Irodykite, kad a. d. $Y_1 = nX_{(1)}, Y_2 = (n-1)(X_{(2)} - X_{(1)}), \dots, Y_n = X_{(n)} - X_{(n-1)}$ yra nepriklausomi ir turi tą patį eksponentinį skirstinį $\mathcal{E}(\lambda)$.

I.1.28. Variacinė eilutė $X_{(1)}, \dots, X_{(n)}$ gauta stebint tolydujį a. d. X , kurio pasiskirstymo funkcija yra $F(x)$. Irodykite, kad a. d.

$$Y_i = \left(\frac{F(X_{(i)})}{F(X_{(i+1)})} \right)^i, i = 1, 2, \dots, n-1,$$

yra nepriklausomi ir vienodai pasiskirstę pagal $U(0, 1)$.

I.1.29. Tegu $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra dvi paprastosios nepriklausomos atsitiktinės imtys, gautos stebint tolygujį a. d. $U(0, 1)$. Raskite tų imčių maksimalių reikšmių santykio $X_{(m)}/Y_{(n)}$ tikimybinį skirstinį.

I.1.30. Imtis, kurios didumas $n = 2k+1$, gauta stebint a. d. $X \sim U(0, 1)$. Irodykite, kad empirinės medianos dispersija lygi $1/(4(2k+3))$.

I.1.31. Variacinė eilutė $X_{(1)}, \dots, X_{(n)}$ gauta stebint tolydujį a. d., kurio pasiskirstymo funkcija yra $F(x)$. Raskite a. v. $(F(X_{(k_1)}), F(X_{(k_2)}))^T$ kovariacijų matricą.

I.1.32. Variacinė eilutė $X_{(1)}, \dots, X_{(n)}$ gauta stebint tolydujį a. d., kurio pasiskirstymo funkcija yra $F(x)$. Irodykite, kad imties pločio $W_n = X_{(n)} - X_{(1)}$ vidurkis yra

$$\mathbf{E}W_n = \int_{-\infty}^{\infty} (1 - F^n(x) - (1 - F(x))^n) dx,$$

jeigu pasiskirstymo funkcija $F(x)$ tenkina sąlygą $x[1 - F^n(x) - (1 - F(x))^n] \rightarrow 0$, kai $x \rightarrow \pm\infty$.

I.1.33. Raskite kraštinių pozicinių statistikų pirmuosius momentus, kai stebimo a. d. skirstinys yra eksponentinis.

I.1.34. Yra k nepriklausomų paprastujų didumo n imčių, gautų stebint a. d. $X_i \sim U(0, 1)$. Tegu i -osios imties maksimali reikšmė yra $X_{(n)}^{(i)}$ ir $V = X_{(n)}^{(1)} \dots X_{(n)}^{(k)}$. Raskite a. d. V tikimybių pasiskirstymo dėsnį.

I.1.35. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra a. d. $X \sim G(\lambda, \eta)$ paprastoji atsitiktinė imtis. Irodykite, kad $\sum_{i=1}^n X_i$ ir $\sum_{i=1}^n [\ln X_i - \ln X_{(1)}]$ yra nepriklausomi.

I.1.36. Sakykime, $\mathbf{X} = (X_1, \dots, X_n)^T$ yra a. d. $X \sim U(a, b)$, $-\infty < a < b < \infty$, paprastoji atsitiktinė imtis. Irodykite, kad $Y_i = (X_{(i)} - X_{(1)})/(X_{(n)} - X_{(1)})$, $i = 2, \dots, n-1$, yra nepriklausomi nuo $X_{(1)}$ ir $X_{(n)}$.

I.1.37. Tegu X_1, \dots, X_{k+1} yra n. a. d., turintys gama skirstinius $X_i \sim G(\lambda, \eta_i)$, $i = 1, \dots, k+1$. Irodykite, kad a. v. $(Z_1, \dots, Z_k)^T$, kai $Z_i = X_i/(X_1 + \dots + X_{k+1})$, $i = 1, 2, \dots, k$, turi k -matį Dirichlė skirstinį $D(\eta_1, \dots, \eta_k; \eta_{k+1})$. Jeigu $k = 1$, tai $Z_1 \sim Be(\eta_1, \eta_2)$.

I.1.38. Tegu X_1, \dots, X_n yra paprastoji imtis a. d. $X \sim U(0, \theta), \theta > 0$. Irodykite, kad $X_{(n)}$ tankio funkcija yra nx^{n-1}/θ^n , kai $0 < x < \theta$.

I.1.39. Tegu X_1, \dots, X_n yra paprastoji imtis a. d. $X \sim U(\mu - \theta/2, \mu + \theta/2), \theta > 0$. Irodykite, kad imties pločio $X_{(n)} - X_{(1)}$ tankio funkcija

$$(n(n-1)/\theta)(x/\theta)^{n-2}(1-x/\theta), \quad 0 < x < \theta.$$

I.1.40. (**I.1.39** pratimo tēsinys). Irodykite, kad a. d. $Z = ((X_{(1)} + X_{(n)})/2 - \mu)/(X_{(n)} - X_{(1)})$ tankio funkcija $f(x) = (n-1)/(1+2|x|)^n, -\infty < x < \infty$.

I.1.41. Tegu X_1, X_2, \dots, X_n yra paprastoji imtis a. d. $X \sim U(0, 1)$. Irodykite, kad a. d. $Y = (X_1 \cdot \dots \cdot X_n)^{1/n}$ tankio funkcija yra

$$f(y) = \frac{n^n y^{n-1}}{(n-1)!} (-\ln y)^{n-1}, \quad 0 < y < 1.$$

I.1.42. Tegu $X_{(k)}$ yra k -oji pozicinė statistika iš didumo m imties, gautos stebint a. d. X su absoliučiai tolydžia pasiskirstymo funkcija $F(x)$. Tarkime, kad gauta kita nepriklausoma didumo n imtis su ta pačia pasiskirstymo funkcija $F(x)$. Pažymėkime Z skaičių tokį antrosios imties elementą, kurie neviršija $X_{(k)}$. Irodykite, kad a. d. Z skirstinys nusakytas tikimybėmis

$$\mathbf{P}\{Z = z\} = \frac{C_m^k C_n^z}{C_{m+n}^{k+z}} \frac{k}{k+z}, \quad z = 0, 1, \dots, n.$$

I.1.43. (**I.1.42** pratimo tēsinys). Irodykite, kad a. d. Z r -asis faktorialinis momentas

$$\mathbf{E}(Z^{[r]}) = \frac{m!n!(k+r-1)!}{(k-1)!(m+r)!(n-r)!}, \quad 1 \leq r \leq n.$$

I.1.44. Tegu Y_1, \dots, Y_n yra paprastoji imtis a. d. $Y \sim U(0, 1)$. Irodykite, kad jei $k, n \rightarrow \infty, k/n \rightarrow p, 0 < p < 1$, tai

$$\sqrt{n}(Y_{(k)} - p) \xrightarrow{d} Y \sim N(0, p(1-p)).$$

I.1.45. Tegu X_1, \dots, X_n yra paprastoji imtis a. d. X su tolydžia pasiskirstymo funkcija $F(x)$. Irodykite, kad jei $F(x)$ tolydžiai diferencijuojama taško $x(p), 0 < p < 1, 0 < p < 1$ aplinkoje ir tankis $f(x(p)) > 0, k/n \rightarrow p, n \rightarrow \infty$, tai

$$\sqrt{n}(\hat{x}(p) - x(p)) \xrightarrow{d} Y \sim N(0, p(1-p)/f^2(x(p))).$$

I.1.46. Tegu X_1, \dots, X_n yra paprastoji imtis a. d. X su tolydžia pasiskirstymo funkcija $F(x)$. Irodykite, kad jei $F(x)$ tolydžiai diferencijuojama taškų $x(p_1), x(p_2), 0 < p_1 < p_2 < 1$ aplinkose ir tankio reikšmės $f(x(p_1)) > 0, f(x(p_2)) > 0$, tai $n \rightarrow \infty$

$$\sqrt{n}(\hat{x}(p_2) - \hat{x}(p_1) - (x(p_2) - x(p_1))) \xrightarrow{d} Y \sim N(0, \sigma^2(p_1, p_2)),$$

$$\sigma^2(p_1, p_2) = \frac{p_1(1-p_1)}{f^2(x(p_1))} - 2 \frac{p_1(1-p_2)}{f(x(p_1))f(x(p_2))} + \frac{p_2(1-p_2)}{f^2(x(p_2))}.$$

I.1.47. (I.1.46 pratimo tēsinys). Jeigu $p_1 = 1/4$, o $p_2 = 3/4$, tai $z = x(3/4) - x(1/4)$ vadinamas interkvartiliiniu pločiu. Raskite statistikos $\hat{z} = \hat{x}(3/4) - \hat{x}(1/4)$ asimptotinį skirstinį.

I.1.48. Tarkime, kad paprastojo imtis X_1, \dots, X_n gauta stebint a.d. $X \sim K(\mu, \sigma)$. Šio skirstinio vidurkis neegzistuoja, o parametras μ yra mediana $x(1/2) = \mu$. Kvartiliai $x(1/4) = \mu - \sigma$, $x(3/4) = \mu + \sigma$, ir $(x(3/4) - x(1/4))/2 = \sigma$. Raskite statistikų $\hat{\mu} = \hat{x}(1/2)$ ir $\hat{\sigma} = (\hat{x}(3/4) - \hat{x}(1/4))/2$ asimptotinius skirstinius.

I.1.49. (I.1.48 pratimo tēsinys). Tegu $0 < p < 1/2$. a) parinkite konstantą $c(p)$ taip, kad $(x(1-p) - x(p))/c(p) = \sigma$; b) raskite tokią parametru p reikšmę, kad statistikos $\hat{\sigma} = (\hat{x}(1-p) - \hat{x}(p))/c(p)$ asimptotinio skirstinio dispersija būtų minimali.

I.1.50. Tarkime, kad paprastojo imtis X_1, \dots, X_n gauta stebint a.d. $X \sim N(\mu, \sigma^2)$. Šio skirstinio mediana sutampa su vidurkiu $x(1/2) = \mu$. Kvartiliai $x(1/4) = \mu - z_{1/4}\sigma$, $x(3/4) = \mu + z_{1/4}\sigma$, $z_{1/4}$ yra standartinio normaliojo skirstinio kritinė reikšmė $z_{1/4} = \Phi^{-1}(3/4)$, ir $(x(3/4) - x(1/4))/(2z_{1/4}) = \sigma$. Raskite statistikų $\hat{\mu} = \hat{x}(1/2)$ ir $\hat{\sigma} = (\hat{x}(3/4) - \hat{x}(1/4))/(2z_{1/4})$ asimptotinius skirstinius.

I.1.51. (I.1.50 pratimo tēsinys). Tegu $0 < p < 1/2$. a) parinkite konstantą $c(p)$ taip, kad $(x(1-p) - x(p))/c(p) = \sigma$; b) raskite tokią parametru p reikšmę, kad statistikos $\hat{\sigma} = (\hat{x}(1-p) - \hat{x}(p))/c(p)$ asimptotinio skirstinio dispersija būtų minimali.

I.1.52. Tarkime, kad paprastojo imtis X_1, \dots, X_n gauta stebint a.d. X , turintį Laplaso skirstinį, kurio tankis

$$f(x|\mu, \sigma) = \frac{1}{2\sigma} e^{-|x-\mu|/\sigma}, \quad \sigma > 0, \quad x, \mu \in \mathbf{R}.$$

Šio skirstinio mediana sutampa su vidurkiu $x(1/2) = \mu$. Kvartiliai $x(1/4) = \mu - \sigma \ln 2$, $x(3/4) = \mu + \sigma \ln 2$, ir $(x(3/4) - x(1/4))/(2 \ln 2) = \sigma$. Raskite statistikų $\hat{\mu} = \hat{x}(1/2)$ ir $\hat{\sigma} = (\hat{x}(3/4) - \hat{x}(1/4))/(2 \ln 2)$ asimptotinius skirstinius.

I.1.53. (I.1.52 pratimo tēsinys). Tegu $0 < p < 1/2$. a) parinkite konstantą $c(p)$ taip, kad $(x(1-p) - x(p))/c(p) = \sigma$; b) raskite tokią parametru p reikšmę, kad statistikos $\hat{\sigma} = (\hat{x}(1-p) - \hat{x}(p))/c(p)$ asimptotinio skirstinio dispersija būtų minimali.

I.1.54. Empirinė mediana $\hat{x}(1/2)$ gauta iš paprastosios didumo n imties a.d. X su tolydžia pasiskirstymo funkcija $F(x)$. Įrodykite, kad asimptotiškai ($n \rightarrow \infty$)

$$2\sqrt{n}(F(\hat{x}(1/2)) - 1/2) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.55. Įrodykite, kad eksponentinio skirstinio $\mathcal{E}(\lambda)$ empirinė mediana $\hat{x}(1/2)$, gauta iš didumo $2n+1$ paprastosios imties, turi tokį asimptotinį ($n \rightarrow \infty$) skirstinį

$$\lambda \sqrt{2n+1}(\hat{x}(1/2) - \frac{\ln 2}{\lambda}) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.56. Variacinė eilutė $X_{(1)} \leq \dots \leq X_{(n)}$ gauta stebint tolydūjį a.d. su pasiskirstymo funkcija $F(x)$. Tegu $Y_{(i)} = F(X_{(i)})$, $i = 1, \dots, n$ ir $Z_i = Y_{(i)} - Y_{(i-1)}$, $i = 1, \dots, n+1$, $Y_{(0)} = 0$, $Y_{(n+1)} = 1$. Įrodykite, kad fiksuoto skaičiaus k skirtinį a.d. Z_i suma S_k asimptotiškai ($n \rightarrow \infty$) turi gama skirstinį $G(1, k)$.

I.1.57. (I.1.56 pratimo tēsinys). Raskite asimptotinius skirstinius statistikų $X_{(k)}$ ir $X_{(n-k+1)}$, kai stebėtas a.d. $X \sim U(a, b)$.

I.1.58. (I.1.56 pratimo tēsinys). Raskite asimptotinius skirstinius statistikų $X_{(k)}$ ir $X_{(n-k+1)}$, kai stebėtas a.d. $X \sim \mathcal{E}(\lambda)$.

I.1.4. Empiriniai momentai ir jų funkcijos

I.1.59. Pagal didumo n_1, n_2, \dots, n_k paprastasias nepriklausomas imtis gauti empiriniai vidurkiai \bar{X}_i ir nepaslinktos empirinės dispersijos s_i^2 , $i = 1, 2, \dots, k$. Raskite jungtinės didumo $n = n_1 + \dots + n_k$ imties empirinį vidurkį \bar{X} ir nepaslinktają empirinę dispersiją s^2 .

I.1.60. Ekspertų grupė vertino kino kadru, nufilmuotų dviejų tipų kino juostomis, kokybę. Gauti šie rezultatai:

I tipo kino juosta				II tipo kino juosta			
i	n_i	X_i	s_i^2	i	n_i	X_i	s_i^2
1	20	25	6	1	10	21	6
2	10	23	5	2	10	18	25
3	10	21	4	3	10	17	5
4	10	18	4	4	9	17	5
5	10	22	9				

Čia n_i yra i -osios imties didumas, \bar{X}_i – empirinis vidurkis, s_i^2 – nepaslinktasis dispersijos ivertis. Raskite I ir II tipo kino juostų jungtinių imčių empirinius vidurkius ir nepaslinktasių empirines dispersijas.

I.1.61. Pagal didumo n imtį gauta empirinis vidurkis \bar{X} ir nepaslinktoji empirinė dispersija s^2 . Kaip perskaičiuoti šias empirines charakteristikas, jeigu imtis papildyta dar vienu nepriklausomu stebėjimu?

I.1.62. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis ir $\bar{X} = (X_1 + \dots + X_n)/n$ – aritmetinis vidurkis. Irodykite, kad a) jeigu $X_i \sim N(\mu, \sigma^2)$, tai $\bar{X} \sim N(\mu, \sigma^2/n)$; b) jeigu $X_i \sim K(\mu, \sigma)$, tai $\bar{X} \sim K(\mu, \sigma)$; c) jeigu $X_i \sim G(\lambda, \eta)$, tai $n\bar{X} \sim G(\lambda, n\eta)$; d) jeigu $X_i \sim B(k, p)$, tai $n\bar{X} \sim B(nk, p)$; d) jeigu $X_i \sim \mathcal{P}(\lambda)$, tai $n\bar{X} \sim \mathcal{P}(n\lambda)$.

I.1.63. Tegu \bar{X} , s_1^2 ir \bar{Y} , s_2^2 yra empiriniai vidurkiai ir nepaslinktosios empirinės dispersijos dviejų nepriklausomų didumo m ir n imčių, gautų stebint a. d. $X \sim N(\mu_1, \sigma^2)$ ir $Y \sim N(\mu_2, \sigma^2)$. Irodykite, kad

$$t = (\bar{X} - \bar{Y} - (\mu_1 - \mu_2)) / \sqrt{\frac{(m-1)s_1^2 + (n-1)s_2^2}{m+n-2} \frac{m+n}{mn}} \sim S(m+n-2).$$

I.1.64. Yra k nepriklausomų a. d. $X \sim N(\mu, \sigma^2)$ imčių, kurių didumai – n_1, \dots, n_k . Tegu \bar{X}_i ir s_i^2 yra i -osios imties empirinis vidurkis ir nepaslinktoji empirinė dispersija. Irodykite, kad funkcijos

$$U = \sum_{i=1}^k (n_i - 1) \frac{s_i^2}{\sigma_i^2}, \quad V = \sum_{i=1}^k n_i \frac{(\bar{X}_i - \bar{X})^2}{\sigma_i^2},$$

$$W = n \frac{(\bar{X} - \mu)^2}{\sigma^2}, \quad (\bar{X} = \frac{\sum_i n_i \bar{X}_i}{n}, \quad n = \sum_i n_i)$$

yra n. a. d., turintys χ^2 skirstinius.

I.1.65. (I.1.64 pratimo tėsinys). Irodykite, kad

$$\frac{W(n-k)}{U} \sim F(1, n-k), \quad \frac{V(n-k)}{U(k-1)} \sim F(k-1, n-k).$$

I.1.66. Tarkime, kad $(X_{1i}, X_{2i})^T, i = 1, 2, \dots, n$ yra paprastojo imtis, gauta stebint dvimatių normaliųjų a. v. $(X_1, X_2)^T \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, $\boldsymbol{\Sigma} = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = \sigma_1^2$, $\sigma_{22} = \sigma_2^2$, $\sigma_{12} = \rho\sigma_1\sigma_2$. Tegu \bar{X}_1 ir \bar{X}_2 yra empirinai vidurkiai, o s_1^2 ir s_2^2 – nepaslinktosios empirinės dispersijos ir r – empirinis koreliacijos koeficientas. Irodykite, kad

$$\sqrt{n}(\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)) / \sqrt{s_1^2 + s_2^2 + rs_1s_2} \sim S(n-1).$$

I.1.67. Paprastosios imtys $\mathbf{X} = (X_1, \dots, X_n)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ gautos stebint n. a. d. X ir Y su vienodomis dispersijomis σ^2 . Raskite statistikos $\bar{Z} - \bar{X}$ vidurkį ir dispersiją, kai $\bar{Z} = (m\bar{Y} + n\bar{X})/(m+n)$.

I.1.68. Tegu $X \sim N(\mu, \sigma^2)$ ir $F(x) = \mathbf{P}\{X \leq x | \mu, \sigma\}$. Irodykite, kad a. d. X ir $F(X)$ koreliacijos koeficientas yra $\sqrt{3/\pi}$.

I.1.69. Tegu Y_1, \dots, Y_n yra n. a. d. ir $Y_i \sim N(\alpha + \beta(x_i - \bar{x}), \sigma^2)$, $i = 1, 2, \dots, n$; čia $\alpha, \beta, x_1, \dots, x_n, \bar{x} = \sum x_i/n$ – konstantos. Tegu

$$SS_E = \min_{\alpha, \beta} SS(\alpha, \beta) = \min_{\alpha, \beta} \sum_{i=1}^n (Y_i - \alpha - \beta(x_i - \bar{x}))^2 = \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}(x_i - \bar{x}))^2.$$

Irodykite, kad a) $\hat{\alpha}$ ir $\hat{\beta}$ yra nepriklausomi ir turi normaliuosius skirstinius su vidurkiais α ir β ir dispersijomis σ^2/n ir $\sigma^2 / \sum_i (x_i - \bar{x})^2$; b) SS_E nepriklauso nuo $\hat{\alpha}$ ir $\hat{\beta}$, o $SS_E/\sigma^2 \sim \chi^2(n-2)$.

I.1.70. Tegu X_1, \dots, X_n yra paprastojo imtis, gauta stebint a. d. $X \sim N(\mu, \sigma^2)$. Pažymėkime

$$Y_j = X_{j+1} - \frac{1}{1+\sqrt{n}}X_1 - \frac{n}{n+\sqrt{n}}\bar{X}, \quad j = 1, 2, \dots, n-1.$$

Irodykite, kad a. d. Y_1, \dots, Y_{n-1} yra nepriklausomi ir $Y_i \sim N(0, \sigma^2)$.

I.1.71. Tegu X_1, \dots, X_n yra paprastojo imtis, gauta stebint a. d. $X \sim N(\mu, \sigma^2)$, ir tegu d empirinis aritmetinis nuokrypis nuo μ

$$d = \frac{1}{n} \sum_{i=1}^n |X_i - \mu|.$$

Irodykite, kad

$$\mathbf{E}d = \sqrt{2/\pi}\sigma, \quad \mathbf{V}d = (\sigma^2/n)(1 - 2/\pi).$$

I.1.72. Paprastojo imtis X_1, \dots, X_n gauta stebint a. d. X , kurio ketvirtas momentas baigtinis $\mathbf{E}(X^4) < \infty$. Raskite empirinio vidurkio \bar{X} vidurkį, dispersiją, asimetrijos ir eksceso koeficientus.

I.1.73. Paprastojo didumo n imtis gauta stebint a. d. X su baigtinge dispersija $\mathbf{E}X = \mu$, $\mathbf{V}X = \sigma^2 < \infty$. Irodykite, kad $n \rightarrow \infty$

$$\sqrt{n} \frac{\bar{X} - \mu}{\sigma} \xrightarrow{d} Z \sim N(0, 1), \quad \sqrt{n} \frac{\bar{X} - \mu}{\sqrt{m_2}} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.74. Paprastojo didumo n imtis gauta stebint a. d. $X \sim \mathcal{P}(\lambda)$. Irodykite, kad $n \rightarrow \infty$

$$S = \sqrt{n} \frac{\bar{X} - \lambda}{\sqrt{\lambda}} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.75. (I.1.74 pratimo tėsinys). Įrodykite, kad $n \rightarrow \infty$

$$Z = \sqrt{n}(2\sqrt{\bar{X}} - 2\sqrt{\lambda}) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.76. (I.1.74 pratimo tėsinys). Įrodykite, kad $n \rightarrow \infty$

$$U = 3\sqrt{n}((\bar{X} + 1/(2n))^{2/3} - \lambda^{2/3})/(2\lambda^{1/6}) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.77. Paprastoji didumo n imtis gauta stebint Bernulio a.d. $X \sim B(1, p)$. Įrodykite, kad $n \rightarrow \infty$

$$\sqrt{n} \frac{\bar{X} - p}{\sqrt{p(1-p)}} \xrightarrow{d} Z \sim N(0, 1), \quad \sqrt{n} \frac{\bar{X} - p}{\sqrt{\bar{X}(1-\bar{X})}} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.78. (I.1.77 pratimo tėsinys). Įrodykite, kad $n \rightarrow \infty$

$$\sqrt{n}(\arcsin(2\bar{X} - 1) - \arcsin(2p - 1)) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.79. Paprastoji didumo n imtis gauta stebint a.d. $X \sim U(0, \theta)$, $\theta > 0$. Įrodykite, kad

$$\mathbf{E}_\theta(2\bar{X}) = \theta, \quad \mathbf{V}_\theta(2\bar{X}) = \frac{\theta^2}{3n} = O\left(\frac{1}{n}\right), \quad \sqrt{3n} \frac{2\bar{X} - \theta}{\theta} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.80. (I.1.79 pratimo tėsinys). Įrodykite, kad

$$\mathbf{E}_\theta\left(\frac{n+1}{n}X_{(n)}\right) = \theta, \quad \mathbf{V}_\theta\left(\frac{n+1}{n}X_{(n)}\right) = \frac{\theta^2}{n(n+2)} = O\left(\frac{1}{n^2}\right).$$

I.1.81. (I.1.79 pratimo tėsinys). Įrodykite, kad

$$\sqrt{3n}(\ln(2\bar{X}) - \ln\theta) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.82. Paprastoji didumo n imtis gauta stebint geometrinj a.d., kurio skirstinys nusakytas tikimybėmis

$$\mathbf{P}_p\{X = k\} = pq^{k-1}, \quad q = 1 - p, \quad k = 1, 2, \dots$$

Įrodykite, kad $n \rightarrow \infty$

$$\sqrt{n}(p\bar{X} - 1)/\sqrt{q} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.83. (I.1.82 pratimo tėsinys). Įrodykite, kad $n \rightarrow \infty$

$$\sqrt{n}\{\ln[\bar{X}(1 + \sqrt{1 - 1/\bar{X}}) - 1/2] - \ln[(1 + \sqrt{q})/p - 1/2]\} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.84. Paprastoji didumo n imtis gauta stebint a.d. X , kurio antras momentas baigtinis $\mathbf{V}X = \sigma^2 < \infty$. Patikrinkite, kad empirinės dispersijos vidurkis $\mathbf{E}_\sigma m_2 \neq \sigma^2$. Nepaslinktoji empirinė dispersija $s^2 = nm_2/(n-1)$ ir $\mathbf{E}_\sigma s^2 = \sigma^2$.

I.1.85. (I.1.84 pratimo tėsinys). Tarkime, kad yra baigtinis ir ketvirtas momentas $\mu_4 = \mathbf{E}(X - \mathbf{E}X)^4 < \infty$. Raskite empirinės dispersijos m_2 dispersija $\mathbf{V}m_2$.

I.1.86. Paprastojo imtis X_1, \dots, X_n gauta stebint a. d. X , turintį baigtinį momentą $\alpha_{2k} = \mathbf{E}X^{2k}$. Irodykite, kad $n \rightarrow \infty$

$$a_k \xrightarrow{b.t.} \alpha_k, \quad \sqrt{n}(a_k - \alpha_k) \xrightarrow{d} Y \sim N(0, \alpha_{2k} - \alpha_k^2).$$

I.1.87. Paprastojo imtis X_1, \dots, X_n gauta stebint a. d. X , turintį baigtinį momentą $\alpha_{2k} = \mathbf{E}X^{2k}$. Irodykite, kad $n \rightarrow \infty$

$$\sqrt{n}(\mathbf{a} - \boldsymbol{\alpha}) \xrightarrow{d} \mathbf{Y} \sim N_k(\mathbf{0}, \boldsymbol{\Sigma}),$$

čia $\mathbf{a} = (a_1, a_2, \dots, a_k)^T$, $a_j = \sum_i X_i^j / n$, $j = 1, \dots, k$; $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_k)^T$; $\boldsymbol{\Sigma} = [\sigma_{ij}]_{k \times k}$, $\sigma_{ij} = \alpha_{i+j} - \alpha_i \alpha_j$, $i, j = 1, \dots, k$.

I.1.88. Irodykite, kad $n \rightarrow \infty$ a) $m_2 \xrightarrow{P} \sigma^2$, $s^2 \xrightarrow{P} \sigma^2$.

b) $\frac{m_2 - \sigma^2}{\sqrt{V m_2}} \xrightarrow{d} Z \sim N(0, 1)$, $\sqrt{n} \frac{m_2 - \sigma^2}{\sqrt{\mu_4 - \sigma^4}} \xrightarrow{d} Z \sim N(0, 1)$,

$$\sqrt{n} \frac{s^2 - \sigma^2}{\sqrt{\mu_4 - \sigma^4}} \xrightarrow{d} Z \sim N(0, 1).$$

c) normaliojo skirstinio atveju

$$nm_2/\sigma^2 \sim \chi^2(n-1), \quad (n-1)s^2/\sigma^2 \sim \chi^2(n-1).$$

I.1.89. Pagal dvi didumo n_1 ir n_2 nepriklausomas paprastąsias imtis, gautas stebint a. d. X ir Y su vidurkiais $\mu_1 = \mathbf{E}X$ ir $\mu_2 = \mathbf{E}Y$, turinčiais baigtines dispersijas, gauti empiriniai vidurkiai ir empirinės dispersijos \bar{X} , s_1^2 ir \bar{Y} , s_2^2 . Irodykite, kad $n_1, n_2 \rightarrow \infty$

$$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{s_1^2/n_1 + s_2^2/n_2}} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.90. Didumo n paprastojo imtis gauta stebint a. d. X su baigtiniu trečiuoju momentu $\mathbf{E}|X|^3 < \infty$. Raskite a. d. \bar{X} ir s^2 kovariaciją.

I.1.91. Paprastojo didumo n imtis gauta stebint a. d. X su baigtiniu ketvirtu momentu $\mu_4 = \mathbf{E}(X - \mathbf{E}X)^4 < \infty$, $\sigma^2 = V X$. Patikrinkite, kad $\mathbf{E}m_3 \neq \mu_3$, $\mathbf{E}m_4 \neq \mu_4$. Kaip reikia pataisyti šias empirines charakteristikas, kad gautųjų statistikų vidurkiai sutaptų su μ_3 ir μ_4 .

I.1.92. Paprastojo imtis X_1, \dots, X_n gauta stebint a. d. X , turintį baigtinį momentą $\alpha_{2k} = \mathbf{E}X^{2k}$. Irodykite, kad $n \rightarrow \infty$

$$m_k \xrightarrow{b.t.} \mu_k, \quad \sqrt{n}(m_k - \mu_k) \xrightarrow{d} Y \sim N(0, B_k^2),$$

čia $B_k^2 = \mu_{2k} - \mu_k^2 - 2k\mu_{k-1}\mu_{k+1} + k^2\mu_{k-1}^2\sigma^2$, o kai stebėtas normalusis a. d., tai $B_k^2 = \sigma^{2k}[(2k-1)!! - ((k-1)!!)^2]$, kai k lyginis, ir $B_k^2 = \sigma^{2k}[(2k-1)!! - 2k(k-2)!!(k-1)!! + k^2(k-2)!!]$, kai k nelyginis.

I.1.93. (I.1.92 pratimo tēsinys). Tarkime, egzistuoja momentas $\mathbf{E}(X^{2k+2l}) < \infty$. Irodykite, kad $n \rightarrow \infty$

$$\sqrt{n}(m_k - \mu_k, m_l - \mu_l) \xrightarrow{d} (Y, Z) \sim N_2(\mathbf{0}, \boldsymbol{\Sigma}),$$

čia $\Sigma = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = B_k^2$, $\sigma_{22} = B_l^2$, $\sigma_{12} = B_{kl}$, $B_{kl} = \mu_{k+l} - k\mu_{l+1}\mu_{k-1} - l\mu_{l-1}\mu_{k+1} - \mu_k\mu_l + kl\mu_k - 1\mu_{l-1}\sigma^2$.

I.1.94. Tegu paprastoji imtis X_1, \dots, X_n gauta stebint a.d. $X \sim \mathcal{P}(\lambda), \lambda > 0$. Nagrinėkime statistiką $H(\bar{X}) = 1/\bar{X}^3$. Irodykite, kad $n \rightarrow \infty$

$$\sqrt{n}(1/\bar{X}^3 - 1/\lambda^3) \xrightarrow{d} Z \sim N(0, 9/\lambda^7).$$

Pažymėsime, kad funkcijos $H(\bar{X})$ dispersija neegzistuoja, nes vardiklis su teigiamą tikiomybę igyja reikšmę 0: $\mathbf{P}\{\bar{X} = 0\} = e^{-n\lambda} > 0$.

I.1.95. Tarkime, $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji didumo n imtis. Irodykite, kad

a) jeigu egzistuoja $\mu_4 = \mathbf{E}(X_i - \mathbf{E}X_i)^4$, tai

$$\mathbf{E}s = \sigma + O(1/n), \quad \mathbf{V}s = \frac{\mu_4 - \sigma^4}{4n\sigma^2} + O(1/n^{3/2}),$$

o kai skirstinys normalusis

$$\mathbf{E}s = \sigma M_{n-1}, \quad \mathbf{V}s = \sigma^2(1 - M_{n-1}^2), \quad M_n = \sqrt{\frac{2}{n} \frac{\Gamma((n+1)/2)}{\Gamma(n/2)}};$$

b) jeigu egzistuoja $\mu_6 = \mathbf{E}(X_i - \mathbf{E}X_i)^6$, tai

$$\begin{aligned} \mathbf{E}g_1 &= \gamma_1 + O(1/n), \quad \mathbf{V}g_1 = \frac{4\mu_6\sigma^4 - 12\mu_5\mu_3\sigma^2 + 9\mu_4\mu_3^2 + 35\mu_3^2\sigma^4}{4n\sigma^{10}} \\ &\quad + \frac{9\sigma^4 - 6\mu_4}{n\sigma^4} + O(1/n^{3/2}), \end{aligned}$$

o kai skirstinys normalusis

$$\mathbf{E}g_1 = 0, \quad \mathbf{V}g_1 = \frac{6(n-1)}{(n+1)(n+3)};$$

c) jeigu egzistuoja $\mu_8 = \mathbf{E}(X_i - \mathbf{E}X_i)^8$, tai

$$\begin{aligned} \mathbf{E}g_2 &= \gamma_2 + O(1/n), \quad \mathbf{V}g_2 = \frac{\mu_8\sigma^4 - 4\mu_6\mu_4\sigma^2 + 4\mu_4^3 + 16\mu_4\mu_3^2\sigma^2}{n\sigma^{12}} \\ &\quad + \frac{16\mu_3^2\sigma^2 - \mu_4^2 - 8\mu_5\mu_3}{n\sigma^8} + O(1/n^{3/2}), \end{aligned}$$

o kai skirstinys normalusis

$$\mathbf{E}g_2 = -\frac{6}{n+1}, \quad \mathbf{V}g_2 = \frac{24n(n-2)(n-3)}{(n+1)^2(n+3)(n+5)}.$$

Visais atvejais statistikų asimptotiniai skirstiniai yra normalieji su pateiktomis asimptotinėmis dispersijomis.

I.1.96. Tegu $(X_i, Y_i)^T, i = 1, 2, \dots, n$, yra didumo n paprastoji imtis, gauta stebint a.v. $(X, Y)^T$. Irodykite, kad

a) jeigu egzistuoja $\mu_{22} = \mathbf{E}[(X - \mathbf{E}X)^2(Y - \mathbf{E}Y)^2]$, tai

$$\mathbf{E}m_{11} = \frac{n-1}{n}\mu_{11}, \quad \mathbf{V}m_{11} = \frac{\mu_{22} - \mu_{11}^2}{n} + O(1/n^2);$$

b) jeigu egzistuoja $\mu_{66} = \mathbf{E}[(X - \mathbf{E}X)^6(Y - \mathbf{E}Y)^6]$, tai

$$\mathbf{Cov}(m_{20}, m_{11}) = \frac{\mu_{31} - \mu_{20}\mu_{11}}{n} + O(1/n^2), \quad \mathbf{Cov}(m_{20}, m_{02}) = \frac{\mu_{22} - \mu_{20}\mu_{02}}{n} + O(1/n^2);$$

o kai skirstinys normalusis

$$\mathbf{Cov}(m_{20}, m_{11}) = \frac{2\rho\sigma_1^3\sigma_2}{n} + O(1/n^2), \quad \mathbf{Cov}(m_{20}, m_{02}) = \frac{2\rho^2\sigma_1^2\sigma_2^2}{n} + O(1/n^2).$$

I.1.97. (1.96 pratimo tēsinys). Irodykite, kad jei egzistuoja

$$\mu_{66} = \mathbf{E}[(X - \mathbf{E}X)^6(Y - \mathbf{E}Y)^6],$$

tai $\mathbf{E}r = \rho + O(1/n)$,

$$\mathbf{V}r = \frac{\rho^2}{4n} \left(\frac{\mu_{40}}{\mu_{20}^2} + \frac{\mu_{04}}{\mu_{02}^2} + \frac{2\mu_{22}}{\mu_{20}\mu_{02}} + \frac{4\mu_{22}}{\mu_{11}^2} - \frac{4\mu_{31}}{\mu_{11}\mu_{20}} - \frac{4\mu_{13}}{\mu_{11}\mu_{02}} \right) + O(1/n^{3/2}) =$$

$$b_r^2/n + O(1/n^{3/2}), \quad \sqrt{n}(r - \rho) \xrightarrow{d} Y \sim N(0, b_r^2),$$

o kai skirstinys normalusis, tai $b_r^2 = (1 - \rho^2)^2$.

I.1.98. Tegu r yra empirinis koreliacijos koeficientas, gautas iš didumo n paprastosios dvimaco normaliojo vektoriaus imties. Irodykite, kad $n \rightarrow \infty$ (Fišerio transformacija)

$$\sqrt{n} \left(\frac{1}{2} \ln \frac{1+r}{1-r} - \frac{1}{2} \ln \frac{1+\rho}{1-\rho} \right) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.5. Sprendimai, nurodymai, atsakymai

I.1.1 skyrelis

I.1.1. A. d. X_1 ir X_2 yra nepriklausomi binominiai a. d. Imties $(X_1, X_2)^T$ skirstinys yra diskretusis, nusakomas tikimybėmis $\mathbf{P}_p\{X_1 = m_1, X_2 = m_2\} = C_{n_1}^{m_1} C_{n_2}^{m_2} p^{m_1+m_2} (1-p)^{(n_1+n_2-m_1-m_2)}$, $m_1 = 0, 1, \dots, n_1$, $m_2 = 0, 1, \dots, n_2$, $0 < p < 1$; $\mathbf{E}_p T = \mathbf{E}_p(X_1/n_1) - \mathbf{E}_p(X_2/n_2) = p - p = 0$, $\mathbf{V}_p T = \mathbf{V}_p X_1/n_1^2 + \mathbf{V}_p X_2/n_2^2 = p(1-p)(n_1 + n_2)/(n_1 n_2)$.

I.1.2. a) Tegu X_i yra a. d., kuris įgyja reikšmę 1, jeigu i -uoju émimu paimtas objektas, turintis savybę A , ir reikšmę 0 – priešingu atveju. Tada imties $\mathbf{X} = (X_1, \dots, X_n)^T$ tikimybinis modelis nusakomas tikimybėmis

$$\mathbf{P}\{X_i = j_i, i = 1, \dots, n\} = \frac{1}{k} \sum_{r=1}^k (\pi_r)^{\sum_i j_i} \times (1 - \pi_r)^{n - \sum_i j_i}, \quad j_i = 0, 1,$$

$$0 < \pi_j < 1, \quad j = 1, \dots, k.$$

Tarkime, kad B_j yra atsitiktinis įvykis, kuris reiškia, kad parinkta j -oji populiacija, $\mathbf{P}\{B_j\} = 1/k, j = 1, \dots, k$. Jeigu įvyko B_j , tai sąlyginis X skirstinys yra binominis ($X|B_j \sim B(n, \pi_j)$; $\mathbf{E}(X|B_j) = n\pi_j$, $\mathbf{E}(X^2|B_j) = n\pi_j(1 - \pi_j) + n^2\pi_j^2$). Tada $\mathbf{E}(X/n) = \frac{1}{k} \sum_{r=1}^k \pi_r = \bar{\pi}$, $\mathbf{V}(X/n) = \mathbf{E}(X/n)^2 - (\mathbf{E}(X/n))^2 = \frac{1}{kn} \sum_{r=1}^k \pi_r(1 - \pi_r) + \frac{1}{k} \sum_{r=1}^k \pi_r^2 - (\frac{1}{k} \sum_{r=1}^k \pi_r)^2$.

b) Eksperimentą galima traktuoti kaip Bernulio eksperimentus, kuriuose įvykis A pasirodo su tikimybe $\bar{\pi}$. Imties $\mathbf{X} = (X_1, \dots, X_n)^T$ tikimybinis modelis nusakomas tikimybėmis $\mathbf{P}\{X_1 = j_1, \dots, X_n = j_n\} = (\bar{\pi})^{\sum_i j_i} (1 - \bar{\pi})^{n - \sum_i j_i}, j_i = 0, 1$. A. d. X turi binominį skirstinį $X \sim B(n, \bar{\pi})$; $\mathbf{E}(X/n) = \bar{\pi}$, $\mathbf{V}(X/n) = \bar{\pi}(1 - \bar{\pi})/n$.

I.1.3. Jungtinės imties $\mathbf{X} = (\mathbf{X}_1^T, \dots, \mathbf{X}_n^T)^T$ tikimybinis modelis nusakomas tikimybėmis $\mathbf{P}\{\mathbf{X}_1 = \mathbf{x}_1, \dots, \mathbf{X}_n = \mathbf{x}_n\} = \mathbf{P}\{\mathbf{X}_1 = \mathbf{x}_1\} \dots \mathbf{P}\{\mathbf{X}_n = \mathbf{x}_n\}$; $\mathbf{P}\{\mathbf{X}_i = \mathbf{x}_i\} = \mathbf{P}\{X_{i1} = j_1, \dots, X_{in} = j_n\} = \pi_i^{\sum_i j_i} (1 - \pi_i)^{n - \sum_i j_i}, j_1, \dots, j_n = 0, 1$. Atsitiktinis dydis X yra suma $X = X_1 + \dots + X_k$, kai X_1, \dots, X_k yra nepriklausomi a. d. ir $X_j \sim B(n, \pi_j)$; $\mathbf{E}(X/n) = \sum_{r=1}^k \pi_r$, $\mathbf{V}(X/n) = \frac{1}{n} \sum_{r=1}^k \pi_r(1 - \pi_r)$.

I.1.4. Jungtinės imties $\mathbf{X} = (X_{11}, \dots, X_{1n_1}, X_{21}, \dots, X_{2n_2})^T$ tikimybinis skirstinys nusakomas tikimybėmis $\mathbf{P}_\pi\{X_{1i} = j_i, X_{2l} = k_l; i = 1, \dots, n_1, l = 1, \dots, n_2\} = \pi^{\sum_i j_i} (1 - \pi)^{n_1 - \sum_i j_i} (\sum_i j_i/n_1)^{\sum_l k_l}, (1 - \sum_i j_i/n_1)^{n_2 - \sum_l k_l}, j_i, k_l = 0, 1, 0 < \pi < 1$.

I.1.5. A. d. $X_1 \sim B(n_1, \pi)$, o a. d. X_2 sąlyginis skirstinys, kai $X_1 = m_1$ fiksotas, yra binominis $B(n_2, m_1/n_1)$. Taigi a. v. $(X_1, X_2)^T$ skirstinys nusakomas tikimybėmis

$$\mathbf{P}_\pi\{X_1 = m_1, X_2 = m_2\} = C_{n_1}^{m_1} \pi^{m_1} (1 - \pi)^{n_1 - m_1} C_{n_2}^{m_2} (m_1/n_1)^{m_2} (1 - m_1/n_1)^{n_2 - m_2},$$

$$m_1 = 0, \dots, n_1, m_2 = 0, \dots, n_2, 0 < \pi < 1.$$

Randame

$$\mathbf{E}_\pi X_1 = n_1 \pi, \quad \mathbf{E}_\pi X_2 = \mathbf{E}_\pi\{\mathbf{E}(X_2|X_1)\} = \mathbf{E}_\pi(n_2 X_1/n_1) = n_2 \pi, \quad \mathbf{E}_\pi(\frac{X_1}{n_1} - \frac{X_2}{n_2}) = 0;$$

$$\mathbf{V}_\pi(X_1/n_1 - X_2/n_2) = \mathbf{E}_\pi(X_1/n_1)^2 - 2\mathbf{E}_\pi(X_1 X_2/(n_1 n_2)) + \mathbf{E}_\pi(X_2/n_2)^2;$$

$$\mathbf{E}_\pi X_1^2 = \mathbf{V}_\pi X_1 + (\mathbf{E}_\pi X_1)^2 = n_1 \pi (1 - \pi) + n_1^2 \pi^2;$$

$$\mathbf{E}_\pi(X_1 X_2) = \mathbf{E}_\pi\{X_1 \mathbf{E}(X_2|X_1)\} = \mathbf{E}_\pi(n_2 X_1^2/n_1) = n_2 \pi (1 - \pi) + n_1 n_2 \pi^2;$$

$$\mathbf{E}_\pi X_2^2 = \mathbf{E}_\pi(n_2 \frac{X_1}{n_1} (1 - \frac{X_1}{n_1}) + n_2^2 (\frac{X_1}{n_1})^2) = n_2 \pi + \frac{n_2(n_2 - 1)}{n_1} \pi (1 - \pi) + n_2(n_2 - 1) \pi^2.$$

Iraše į dispersijos išraišką ir sutraukę panašiuosius narius, gausime

$$\mathbf{V}_\pi(X_1/n_1 - X_2/n_2) = \frac{(n_1 - 1)\pi(1 - \pi)}{n_1 n_2}.$$

I.1.6. Populiacijos objektų, turinčių savybę A , skaičius yra $M = N\pi$ ir $\pi = M/N$. Tada a. d. X_1 skirstinys yra hipergeometrinis $X_1 \sim H(N, M, n_1)$, o a. d. X_2 sąlyginis skirstinys, esant sąlygai, kad a. d. X_1 įgijo reikšmę m , taip pat hipergeometrinis ($X_2|X_1 = m \sim H(n_1, m, n_2)$).

Randame

$$\mathbf{E}_\pi X_1 = n_1 \pi, \quad \mathbf{E}_\pi X_2 = \mathbf{E}_\pi\{\mathbf{E}(X_2|X_1)\} = \mathbf{E}_\pi(n_2 X_1/n_1) = n_2 \pi, \quad \mathbf{E}_\pi(\frac{X_1}{n_1} - \frac{X_2}{n_2}) = 0;$$

$$\begin{aligned}\mathbf{V}_\pi(X_1/n_1 - X_2/n_2) &= \mathbf{E}_\pi(X_1/n_1)^2 - 2\mathbf{E}_\pi(X_1X_2/(n_1n_2)) + \mathbf{E}_\pi(X_2/n_2)^2; \\ \mathbf{E}_\pi X_1^2 &= \mathbf{V}_\pi X_1 + (\mathbf{E}_\pi X_1)^2 = n_1\pi(1-\pi)\frac{N-n_1}{N-1} + n_1^2\pi^2; \\ \mathbf{E}_\pi(X_1X_2) &= \mathbf{E}_\pi\{X_1\mathbf{E}(X_2|X_1)\} = \mathbf{E}_\pi(n_2X_1^2/n_1) = n_2\pi(1-\pi)\frac{N-n_1}{N-1} + n_1n_2\pi^2; \\ \mathbf{E}_\pi X_2^2 &= \mathbf{E}_\pi(n_2\frac{X_1}{n_1}(1-\frac{X_1}{n_1}) + n_2^2(\frac{X_1}{n_1})^2) = n_2\pi + \frac{n_2(n_2-1)}{n_1}\frac{N-n_1}{N-1}\pi(1-\pi) + n_2(n_2-1)\pi^2.\end{aligned}$$

Įrašę į dispersijos išraišką ir sutraukę panašiuosius narius, gausime

$$\mathbf{V}_\pi(X_1/n_1 - X_2/n_2) = \frac{(n_1-1)N}{n_1n_2(N-1)}\frac{M}{N}(1-\frac{M}{N}), \quad \pi = \frac{M}{N}.$$

I.1.7. A. d. X skirtinys yra hipergeometrinis $X \sim H(N, M, n)$.

I.1.8. Partijos priėmimo tikimybė

$$\mathbf{P}\{X \leq c|M\} = \sum_{m=0}^c h(m|N, M, n) = H(c|N, M, n),$$

čia $h(m|N, M, n) = C_M^m C_{N-M}^{n-m} / C_N^n$.

I.1.9. a) Atsitiktinio vektoriaus $\mathbf{X} = (X_1, \dots, X_n)^T$ koordinatės priklausomos: koordinatė X_i negali įgyti reikšmės y_j , jei kuri nors kita koordinatė jau įgijo šią reikšmę. A. v. \mathbf{X} galimos reikšmės yra visi galimi skirtinių rinkiniai $(y_{i_1}, y_{i_2}, \dots, y_{i_n})^T$ iš aibės $\{y_1, \dots, y_N\}$ (visi indeksai i_1, i_2, \dots, i_n skirtini); jų įgijimo tikimybės visos vienodos ir lygos $1/C_N^n$.

b)

$$\begin{aligned}\mathbf{E}Y &= \sum_{i=1}^n \mathbf{E}X_i = \frac{n}{N} \sum_{i=1}^N y_i = n\bar{y}; \\ \mathbf{E}Y^2 &= \mathbf{E}(\sum_{i=1}^n X_i^2 + \sum_{i \neq j} X_i X_j) = \frac{n}{N} \sum_{j=1}^N y_j^2 + \frac{n(n-1)}{N(N-1)} \sum_{i \neq j} y_i y_j = \\ &\quad \frac{n}{N} \sum_{j=1}^N y_j^2 + \frac{n(n-1)}{N(N-1)} [(\sum_{i=1}^N y_i)^2 - \sum_{i=1}^N y_i^2].\end{aligned}$$

Gauname

$$\mathbf{V}Y = \mathbf{E}Y^2 - (\mathbf{E}Y)^2 = \frac{n(N-n)}{N(N-1)} \sum_{i=1}^N y_i^2 - \frac{n(N-n)}{N^2(N-1)} (\sum_{i=1}^N y_i)^2.$$

Jeigu pažymėsime $s_y^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2$ aibės reikšmių dispersija, tai $\mathbf{V}Y = ns_y^2(N-n)/(N-1)$.

c) Tarkime, vienetų skaičius aibėje O_N lygus M . Tada $Y \sim H(N, M, n)$.

I.1.10. a) Atsitiktinio vektoriaus $\mathbf{X} = (X_1, \dots, X_n)^T$ koordinatės yra nepriklausomos; a. v. \mathbf{X} reikšmės yra visi galimi rinkiniai $(y_{i_1}, y_{i_2}, \dots, y_{i_n})^T$, kurių kiekviena koordinatė nepriklausomai nuo kitų gali įgti reikšmes y_1, \dots, y_N su tikimybėmis $1/N$, t. y. kiekvieno

rinkinio tikimybė yra $1/N^n$; b) $\mathbf{E}Y = n\bar{y}$, $\mathbf{V}Y = ns_y^2$; c) Jeigu vienetų skaičius aibėje yra M , tai $Y \sim B(n, p)$, $p = M/N$.

I.1.11. Jungtinės imties $(X^T, Y^T)^T$ tikimybinis skirstinys nusakomas tikimybėmis $\mathbf{P}\{X_1 = k_1, \dots, X_m = k_m, Y_1 = l_1, \dots, Y_n = l_n\} = \lambda_1^{k_1+\dots+k_m} e^{-m\lambda_1} \lambda_2^{l_1+\dots+l_n} e^{-n\lambda_2} / (k_1! \dots k_m! l_1! \dots l_n!)$, $0 < \lambda_1, \lambda_2 < \infty$, $k_j, l_i = 0, 1, \dots$. Jeigu $\lambda_1 = \lambda_2 = \lambda$, tai ši tikimybė yra $\lambda^{k_1+\dots+k_m+l_1+\dots+l_n} e^{-(m+n)\lambda} / (k_1! \dots k_m! l_1! \dots l_n!)$.

I.1.12. c) Jungtinės imties $(X_1, \dots, X_m, Y_1, \dots, Y_n)^T$ tikimybinio tankio funkcija yra $\prod_{i=1}^m \varphi(x_i | \mu_1, \sigma_1) \prod_{j=1}^n \varphi(y_j | \mu_2, \sigma_2)$, $-\infty < \mu_1, \mu_2 < \infty$, $0 < \sigma_1, \sigma_2 < \infty$; čia $\varphi(z | \mu, \sigma)$ – normaliojo skirstinio $N(\mu, \sigma^2)$ tankio funkcija. Atveju a) reikia išrašyti $\mu_1 = \mu_2 = \mu$, o atveju b) $\sigma_1 = \sigma_2 = \sigma$.

I.1.13. Imties tankio funkcija yra $\prod_{i=1}^n \varphi(x_i, y_i | \boldsymbol{\mu}, \boldsymbol{\Sigma})$, $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, $-\infty < \mu_1, \mu_2 < \infty$, $\boldsymbol{\Sigma} = [\sigma_{ij}]_{2 \times 2}$, $0 < \sigma_{11}, \sigma_{22} < \infty$, $\sigma_{12} = \sigma_{21} = \rho \sqrt{\sigma_{11}\sigma_{22}}$, $-1 < \rho < 1$; o $\varphi(x, y | \boldsymbol{\mu}, \boldsymbol{\Sigma})$ – dvimačio normaliojo skirstinio $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ tankio funkcija. Jeigu a. d. X ir Y marginalieji skirstiniai vienodi, tai reikia išrašyti $\mu_1 = \mu_2 = \mu$, $\sigma_{11} = \sigma_{22} = \sigma^2$.

I.1.14. Atsitiktinio vektoriaus \mathbf{X} skirstinys yra n -matis normalusis $N_n(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kurio vidurkių vektorius $\boldsymbol{\mu} = (\mu, \dots, \mu)^T$, $-\infty < \mu < \infty$; kovariacinės matricos $\boldsymbol{\Sigma} = [\sigma_{ij}]_{n \times n}$ elementai ant pagrindinės istrižainės yra σ^2 , $0 < \sigma < \infty$; elementai ant istrižainių, gretimų pagrindinei, yra $\rho\sigma^2$, $-1 < \rho < 1$, o visi kiti elementai lygūs 0.

I.1.15. Jungtinės imties \mathbf{X} pasiskirstymo funkcija F priklauso absoliučiai tolydžių $(n_1 + \dots + n_m)$ -mačių pasiskirstymo funkcijų aibei \mathcal{F} : a) \mathcal{F} yra aibė pasiskirstymo funkcijų $\prod_{j=1}^m \prod_{i=1}^{n_j} F(x_{ij} - \mu_j)$, $-\infty < \mu_1, \dots, \mu_m < \infty$; b) \mathcal{F} yra aibė pasiskirstymo funkcijų $\prod_{j=1}^m \prod_{i=1}^{n_j} F(x_{ij}/\sigma_j)$, $0 < \sigma_1, \dots, \sigma_m < \infty$; c) \mathcal{F} yra aibė pasiskirstymo funkcijų $\prod_{j=1}^m \prod_{i=1}^{n_j} F((x_{ij} - \mu_j)/\sigma_j)$, $-\infty < \mu_1, \dots, \mu_m < \infty$, $0 < \sigma_1, \dots, \sigma_m < \infty$; d) \mathcal{F} yra aibė pasiskirstymo funkcijų $\prod_{j=1}^m \prod_{i=1}^{n_j} F_j(x_{ij})$; čia F, F_j – vienmatės absoliučiai tolydžios pasiskirstymo funkcijos.

I.1.16. Imties \mathbf{X} pasiskirstymo funkcija F priklauso absoliučiai tolydžių n -mačių pasiskirstymo funkcijų aibei \mathcal{F} pavidalo $\prod_{i=1}^n F_i(x_i)$; čia F_1, \dots, F_n – vienmatės absoliučiai tolydžios pasiskirstymo funkcijos. Jeigu imties paprastoji, tai pasiskirstymo funkcijos F_1, \dots, F_n vienodos.

I.1.17. Imties nario $\mathbf{X}^{(i)}$ pasiskirstymo funkcija F priklauso absoliučiai tolydžių n -mačių pasiskirstymo funkcijų aibei $\mathcal{F} = \{F(x_1, \dots, x_n) : F(x, \infty, \dots, \infty) = F(\infty, x, \dots, \infty) = \dots = F(\infty, \infty, \dots, x), -\infty < x < \infty\}$.

I.1.18. Atsitiktinio vektoriaus $\mathbf{X} = (X_1, \dots, X_n)^T$ tikimybinio tankio funkcija yra $(\sqrt{2\pi}\sigma)^{-n} \exp\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_{t_i} - x_0 - vt_i)^2\}$, $-\infty < x_0, x_{t_1}, \dots, x_{t_n} < \infty, v > 0$.

I.1.19. Iš I.1.18 pratimo tankio formulė reikia išrašyti $x_0 = 0$.

I.1.20. A. v. $\mathbf{X} = (X_1, \dots, X_n)^T$ tikimybinio tankio funkcija yra

$$(\sqrt{2\pi}\sigma)^{-n} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^k x_i^2\right\} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=k+1}^n (x_i - \mu)^2\right\},$$

kai $-\infty < x_1, \dots, x_n < \infty$, $-\infty < \mu < \infty$, $\sigma > 0$.

I.1.2 skyrelis

I.1.21. Pažymėkime $p = \mathbf{P}\{X \leq 0\} = \Phi(-0, 5)$. Remiantis [2], 2.1.3 teorema

$$\sqrt{n} \frac{\hat{F}_n(0) - p}{\sqrt{p(1-p)}} \xrightarrow{d} Z \sim N(0, 1).$$

Randame

$$\begin{aligned} \mathbf{P}_p\{|\hat{F}_n(0) - p| \leq \varepsilon\} &= \mathbf{P}_p\{-\varepsilon \sqrt{n/(p(1-p))} \leq \sqrt{n} \frac{\hat{F}_n(0) - p}{\sqrt{p(1-p)}} \leq \varepsilon \sqrt{n/(p(1-p))}\} \\ &\approx 2\Phi(\varepsilon \sqrt{n/(p(1-p))}) - 1. \end{aligned}$$

Kai $n = 100$, $\varepsilon = 0, 1; 0, 05$, gauname apytiksles tikimybių reikšmes 0,9696; 0,7210.

I.1.22. Pažymėkime $D_n = \sup_x |\hat{F}_n(x) - F(x)|$. Tada remiantis Kolmogorovo teorema ([2], 2.1.4 teorema)

$$\mathbf{P}_F\{D_n \leq \varepsilon\} = \mathbf{P}\{\sqrt{n}D_n \leq \sqrt{n}\varepsilon\} \approx K(\varepsilon\sqrt{n}).$$

Kai $\varepsilon = 0, 1; 0, 05$, o $n = 50$, tai $\varepsilon\sqrt{n} = 0, 7071; 0, 35355$. Gauname apytiksles tikimybių reikšmes $K(0, 7071) = 0, 3006$; $K(0, 35355) = 0, 0004$. Kai $\varepsilon = 0, 1; 0, 05$, o $n = 100$, tai $\varepsilon\sqrt{n} = 1; 0, 5$. Gauname apytiksles tikimybių reikšmes $K(1) = 0, 7300$; $K(0, 5) = 0, 0361$.

I.1.23. Tegu $p = \mathbf{P}\{X = 2\} = 3^2 e^{-3}/2 \approx 0, 224$, o $\hat{p}_n = S_n/n$, kai S_n yra imties elementų, įgijusių reikšmę 2, skaičius. Kadangi $S_n \sim B(n, p)$, tai remiantis CRT

$$\sqrt{n}(\hat{p}_n - p) \xrightarrow{d} Z \sim N(0, p(1-p)).$$

Gauname nelygybę n atžvilgiu

$$\begin{aligned} \mathbf{P}_p\{|\hat{p}_n - p| \leq 0, 05\} &= \mathbf{P}_p\{-0, 05 \sqrt{n/(p(1-p))} \leq \sqrt{n} \frac{\hat{p}_n - p}{\sqrt{p(1-p)}} \leq 0, 05 \sqrt{n/(p(1-p))}\} \\ &\approx 2\Phi(0, 05 \sqrt{n/(p(1-p))}) - 1 \geq 0, 95. \end{aligned}$$

Iš čia

$$0, 05 \sqrt{p(1-p)/n} \geq z_{0,025} \Leftrightarrow n \geq z_{0,025}^2 p(1-p)/0, 05^2 = 267, 095.$$

Taigi imties didumas $n \geq 268$.

I.1.24. a) Sugrupavę duomenis ilgio $h = 10$ intervalais gauname grupuotosios imties realizaciją

X'_i	5	15	25	35	45	55	65
n_i	1	6	26	37	24	5	1

Šioje lentelėje X'_i yra i -ojo intervalo vidurys, o n_i – stebinių, patekusiuų į i -ąjį intervalą, skaičius.

b) Empirinės pasiskirstymo realizacijos $F_n(x)$ grafikas gaunamas braižant funkciją, kuri kinta didumo n_i/n šuoliukais taškuose X'_i .

Histogramos $f_n(x)$ grafikas gaunamas bražiant stačiakampius stulpelius, kurių aukštis i -ame intervale $n_i/(nh) = n_i/(10n)$.

Apie grupavimo intervalų ilgio parinkimą ir branduolinius tankio įvertinius žr. [2], 2.6.2 ir 2.6.3 skyrelius.

I.1.25. Nežinomų parametru įvertinių realizacijos yra $\hat{\mu} = \bar{X} = 34,75$; $\hat{\sigma} = s = 10,56$.

Vizualus palyginimas su normaliojo skirstinio pasiskirstymo funkcija dažnai atlieka mas bražiant empirinės pasiskirstymo funkcijos grafike funkciją $\Phi((x - \bar{X})/s)$.

Analogiškai, vizualiai lyginant su normaliojo skirstinio tankiu dažnai histogramos grafike pavaizduojama funkcija $\varphi((x - \bar{X})/s)/s$.

Pateiktieji palyginimai nėra vaizdūs. Jeigu paprastojo imtis X_1, X_2, \dots, X_n gauta stebint normaliųjį a. d. $X \sim N(\mu, \sigma^2)$, tai a. d. $Y_i = \Phi((X_i - \mu)/\sigma) \sim U(0, 1)$ turi tolygųjį intervalėje $[0; 1]$ skirstinį. Todėl taškai $(Y_{(i)}; i/n)$, $i = 1, 2, \dots, n$, bus išsidėstę apie vienetinio kvadrato įstrižainę.

A. d. $\hat{Y}_i = \Phi(\hat{Z}_i)$, $\hat{Z}_i = (X_i - \bar{X})/s$ nėra tolygiai pasiskirstę intervalėje $[0; 1]$; be to, jie yra priklausomi. Tačiau esant pakankamai dideliam imties didumui n , taškai $(\hat{Y}_{(i)}; i/n)$ irgi bus išsidėstę apie vienetinio kvadrato įstrižainę.

Šį principą galima panaudoti ir vizualiai lyginant histogramą su teoriniu tankiu. Sudalinkime intervalą $[0; 1]$ į, pavyzdžiui, 10 vienodo ilgio intervalų. Sugrupuokime a. d. $\hat{Y}_1, \hat{Y}_2, \dots, \hat{Y}_n$ į intervalus $[0; 0, 1]; (0, 1; 0, 2]; \dots; (0, 9; 1, 0]$. Tarkime, stebėjimų, patekusiu į šiuos intervalus, skaičiai yra m_1, m_2, \dots, m_{10} . Pagal šiuos duomenis bražoma histograma, t. y. aukščio $m_i/(0, 1n) = m_i/10$ stulpelius i -ame intervale. Šią histogramą vizualiai lyginame su skirstinio $U(0, 1)$ tankiu $f(x) \equiv 1$, kai $x \in [0; 1]$, ir $f(x) \equiv 0$, kai $x < 0$ arba $x > 1$.

Šis palyginimas turi tam tikrų privalumų lyginant su pradinių duomenų grupavimu į vienodo ilgio intervalus. Tada į kraštinius intervalus patenka mažiau stebinių ir palyninimas šiuose intervaluose yra mažiau tikslus negu centriniuose intervaluose. Be to, lyginimas su tiesine funkcija yra vaizdesnis negu su kreivalinijine funkcija $\varphi((x - \bar{X})/s)/s$.

Apie formalius suderinamumo kriterijus, kai tikrinama prielaida, kad turima paprasčiosios imties realizacija nepriestarauja prielaidai, kad stebimas a. d., turintis konkretų skirstinį ar priklausantis parametrinei skirstinių šeimai, žr. 3 skyriuje.

I.1.3 skyrelis

I.1.26. Statistikos $X_{(1)}$ tankio funkcija

$$f_1(x) = 2ne^{-2n(x-\mu)}, \quad x > \mu.$$

Randame

$$\mathbf{P}_\mu\{X_{(1)} - \mu \leq 0, 05\} = \int_\mu^{\mu+0,05} f_1(x)dx = 1 - e^{-2n0,05} = 1 - e^{-5} = 0, 9933.$$

I.1.27. a) Atlikime transformaciją

$$\left\{ \begin{array}{l} Z_1 = X_{(1)} - \mu, \\ Z_2 = X_{(2)} - X_{(1)}, \\ \dots, \\ Z_n = X_{(n)} - X_{(n-1)}. \end{array} \right.$$

Atvirkštinė transformacija

$$\begin{cases} X_{(1)} = Z_1 + \mu, \\ X_{(2)} = Z_2 + Z_1 + \mu, \\ \dots, \\ X_{(n)} = Z_n + \dots + Z_1 + \mu. \end{cases}$$

Pakeitimo jakobianas J lygus 1. Variacinės eilutės $(X_{(1)}, \dots, X_{(n)})^T$ tankio funkcija

$$f(x_1, \dots, x_n) = \frac{n!}{\sigma^n} e^{-(x_1 - \mu)/\sigma} \cdot \dots \cdot e^{-(x_n - \mu)/\sigma}, \quad \mu < x_1 < \dots < x_n < \infty.$$

Atlikę kintamųjų keitimą, gauname a. v. $(Z_1, \dots, Z_n)^T$ tankio funkciją

$$g(z_1, \dots, z_n) = (n/\sigma) e^{-(n/\sigma)z_1} ((n-1)/\sigma) e^{-(n-1)/\sigma)z_2} \cdot \dots \cdot (1/\sigma) e^{-(1/\sigma)z_n},$$

kai $0 < z_1, \dots, z_n < \infty$. Matome, kad a. d. Z_1, \dots, Z_n nepriklausomi; $Z_i \sim \mathcal{E}((n-i+1)/\sigma), i = 1, \dots, n$. Gauname $2nZ_1/\sigma = 2n(X_{(1)} - \mu)/\sigma \sim \chi^2(2)$, o suma

$$\sum_{i=2}^n (X_{(i)} - X_{(1)}) = (n-1)Z_2 + (n-2)Z_3 + \dots + Z_n \sim G(1/\sigma, n-1),$$

nes a. d. $(n-i+1)Z_i \sim G(1/\sigma, 1)$. Tada $(2/\sigma) \sum_{i=2}^n (X_{(i)} - X_{(1)}) \sim \chi^2(2(n-1))$.

Gauname

$$T = \frac{n(X_{(1)} - \mu)}{W} = \frac{(2/\sigma)n(X_{(1)} - \mu)/2}{(2/\sigma) \sum_{i=2}^n (X_{(i)} - X_{(1)})/(2(n-1))} \sim F(2, 2(n-1)).$$

b) Remiantis p. a) a. d. $X_{(1)} - \mu \sim \mathcal{E}(n/\sigma)$, taigi $X_{(1)} \sim \mathcal{E}(n/\sigma, \mu)$.

c) Imdami p. a) $\mu = 0$ ir $\sigma = 1/\lambda$, gausime, kad a. d. Y_1, \dots, Y_n yra nepriklausomi ir $Y_i \sim \mathcal{E}(\lambda), i = 1, \dots, n$.

I.1.28. A. v. $(Y_{(1)}, \dots, Y_{(n)})^T = (F(X_{(1)}), \dots, F(X_{(n)}))^T$ yra variacinė eilutė, gauta stebint a. d. $Y \sim U(0, 1)$; jo tankis lygus $n!$, kai $0 < y_1 < \dots < y_n < 1$. Atlikime transformaciją

$$\begin{cases} Z_1 = Y_{(1)}/Y_{(2)}, \\ Z_2 = (Y_{(2)}/Y_{(3)})^2, \\ \dots, \\ Z_{n-1} = (Y_{(n-1)}/Y_{(n)})^{n-1}, \\ Z_n = Y_{(n)}. \end{cases}$$

Atvirkštinė transformacija

$$\begin{cases} Y_{(1)} = Z_n Z_{n-1}^{1/(n-1)} \cdot \dots \cdot Z_2^{1/2} Z_1 \\ Y_{(2)} = Z_n Z_{n-1}^{1/(n-1)} \cdot \dots \cdot Z_2^{1/2} \\ \dots, \\ Y_{(n-1)} = Z_n Z_{n-1}^{1/(n-1)}, \\ Y_{(n)} = Z_n. \end{cases}$$

Pakeitimo jakobianas $J = z_n^{n-1}/(n-1)!$. Atlikę kintamųjų keitimą gauname, kad a. v. $(Z_1, \dots, Z_{n-1}, Z_n)^T$ tankio funkcija yra nz_n^{n-1} . Suintegravę pagal z_n , gauname a. v.

$(Z_1, \dots, Z_{n-1})^T$ tanki, kuris lygus 1, kai $0 < z_1, \dots, z_{n-1} < 1$. Taigi a. d. Z_1, \dots, Z_{n-1} yra nepriklausomi ir kiekvienas iš jų turi tolygųjį skirstinį $U(0, 1)$.

I.1.29. Atsitiktinio vektoriaus $(X_{(m)}, Y_{(n)})^T$ tankio funkcija $f(x, y) = mnx^{m-1}y^{n-1}$ vienetiniame kvadrate $0 < x, y < 1$. Randame

$$\mathbf{P}\{X_{(m)}/Y_{(n)} \leq z\} = \int_0^1 ny^{n-1} \int_0^{zy} mx^{m-1} dx dy = \frac{n}{m+n} z^m, \quad 0 < z < 1;$$

$$\mathbf{P}\{X_{(m)}/Y_{(n)} \leq z\} = 1 - \int_0^1 mx^{m-1} \int_0^{x/z} ny^{n-1} dy dx = 1 - \frac{m}{m+n} \frac{1}{z^n}, \quad 1 < z < \infty.$$

Diferencijuodami randame tankio funkciją

$$g(z) = \frac{mn}{m+n} z^{m-1}, \quad \text{kai } 0 < z < 1,$$

$$g(z) = \frac{mn}{m+n} \frac{1}{z^{n+1}}, \quad \text{kai } 1 < z < \infty.$$

I.1.30. Empirinės medianos X_{k+1} skirstinys (žr. [2], 2.3 skyrelį) yra $Be(k+1, k+1)$. Tada (žr. 1 priedo 1.P.2 lentelę)

$$\mathbf{V}X_{(k+1)} = \frac{k+1}{2(k+1)} \frac{k+1}{2(k+1)} \frac{1}{2(k+1)+1} = \frac{1}{4(2k+3)}.$$

I.1.31. Tegu $1 \leq k_1 < k_2 \leq n$. A. d. $F(X_{(k_1)})$ ir $F(X_{(k_2)})$ yra pozicinės statistikos $Y_{(k_1)}$ ir $Y_{(k_2)}$, gautos stebint a. d. $Y \sim U(0, 1)$. Žinome, kad $Y_{(k_1)} \sim Be(k_1, n - k_1 + 1)$, $Y_{(k_2)} \sim Be(k_2, n - k_2 + 1)$. Taigi $\mathbf{V}(Y_{(k_1)}) = p_1(1 - p_1)/(n + 2)$, $\mathbf{V}(Y_{(k_2)}) = p_2(1 - p_2)/(n + 2)$; čia $p_1 = k_1/(n + 1)$, $p_2 = k_2/(n + 1)$.

Atsitiktinio vektoriaus $(Y_{(k_1)}, Y_{(k_2)})^T$ tankio funkcija (žr. [2], 2.3 skyrelį)

$$\frac{n!}{(k_1 - 1)!(k_2 - k_1 - 1)!(n - k_2)!} y_1^{k_1 - 1} (y_2 - y_1)^{k_2 - k_1 - 1} (1 - y_2)^{n - k_2}, \quad 0 < y_1 < y_2 < 1.$$

Turime

$$\mathbf{Cov}(Y_{(k_1)}, Y_{(k_2)}) = \mathbf{E}(Y_{(k_1)}Y_{(k_2)}) - \mathbf{E}Y_{(k_1)}\mathbf{E}Y_{(k_2)}, \quad \mathbf{E}Y_{(k_1)} = \frac{p_1}{n+2}, \quad \mathbf{E}Y_{(k_2)} = \frac{p_2}{n+2}.$$

Randame

$$\mathbf{E}(Y_{(k_1)}Y_{(k_2)}) = \mathbf{E}(Y_{(k_1)} - Y_{(k_1)}(1 - Y_{(k_2)})) = \frac{p_1(k_2 + 1)}{(n + 2)},$$

$$\mathbf{Cov}(Y_{(k_1)}, Y_{(k_2)}) = p_1 \frac{k_2 + 1}{n + 2} - p_1 \frac{k_2}{n + 1} = p_1 \frac{n - k_2 + 1}{(n + 1)(n + 2)} = \frac{p_1(1 - p_2)}{n + 2}.$$

I.1.32. Remiantis [2], 2.3 skyreliu, a. d.

$$\mathbf{E}(W_n) = n \int_{-\infty}^{\infty} x[(F(x))^n - (1 - F(x))^n]f(x)dx =$$

$$-\int_{-\infty}^{\infty} xd[1 - (F(x))^n - (1 - F(x))^n] = \int_{-\infty}^{\infty} [1 - (F(x))^n - (1 - F(x))^n]dx.$$

I.1.33. Remiantis [2], 2.3 skyreliu, a. d. $X_{(1)}$ tankio funkcija

$$n(1 - F(x))^{n-1}f(x) = n\lambda e^{-n\lambda x}; \quad \mathbf{E}_{\lambda}(X_{(1)}) = 1/(n\lambda).$$

A. d. $X_{(n)}$ tankio funkcija

$$n(F(x))^{n-1}f(x) = n\lambda(1 - e^{-\lambda x})^{n-1}e^{-\lambda x} = n\lambda \sum_{j=0}^{n-1} C_{n-1}^j (-1)^j e^{-\lambda(j+1)x},$$

$$\mathbf{E}_{\lambda}(X_{(n)}) = n \sum_{j=0}^{n-1} C_{n-1}^j (-1)^j / (\lambda(j+1)^2).$$

I.1.34. Randame $-\ln X_{(n)}^{(j)} \sim \mathcal{E}(n)$, $j = 1, \dots, k$. Tada

$$-\ln V = -\ln X_{(n)}^{(1)} - \dots - \ln X_{(n)}^{(k)} \sim G(n, k).$$

I.1.35. Atsitiktinio vektoriaus $(X_{(1)}, \dots, X_{(n)})^T$ tankis yra

$$n!(\lambda^n / (\Gamma(\eta))^n) x_1^{\eta-1} \dots x_n^{\eta-1} \exp\{-\lambda(x_1 + \dots + x_n)\}$$

srityje $0 < x_1 < x_2 < \dots < x_n < \infty$. Atliekame transformaciją

$$\begin{cases} s = x_1 + \dots + x_n, \\ y_2 = \ln x_2 - \ln x_1, \\ \dots, \\ y_n = \ln x_n - \ln x_1. \end{cases}$$

Atvirkštinė transformacija

$$\begin{cases} x_1 = s / (1 + e^{y_2} + \dots + e^{y_n}) \\ x_2 = se^{y_2} / (1 + e^{y_2} + \dots + e^{y_n}) \\ \dots, \\ x_n = se^{y_n} / (1 + e^{y_2} + \dots + e^{y_n}). \end{cases}$$

Pakeitimo jakobianas

$$J = \left[\frac{\mathcal{D}(s, y_2, \dots, y_n)}{\mathcal{D}(x_1, x_2, \dots, x_n)} \right]^{-1} = \frac{x_1 x_2 \dots x_n}{s} = \frac{s^{n-1} e^{1+y_2+\dots+y_n}}{(1 + e^{y_2} + \dots + e^{y_n})^n}.$$

Irašę į tankio formulę matome, kad jis lygus funkcijos, priklausančios tik nuo s , ir funkcijos, priklausančios nuo y_2, \dots, y_n , sandaugai. Taigi a. d. $X_1 + \dots + X_n$ ir a. v. $(\ln X_{(2)} - \ln X_{(1)}, \dots, \ln X_{(n)} - \ln X_{(1)})^T$ yra nepriklausomi.

I.1.36. Atsitiktinio vektoriaus $(X_{(1)}, \dots, X_{(n)})^T$ tankio funkcija yra $f(x_1, \dots, x_n) = n!/(b-a)^n$ srityje $a < x_1 < \dots < x_n < b$. Atliekame transformaciją

$$\begin{cases} y_1 = x_1 \\ y_2 = (x_2 - x_1) / (x_n - x_1) \\ \dots, \\ y_{n-1} = (x_{n-1} - x_1) / (x_n - x_1), \\ y_n = x_n. \end{cases}$$

Atvirkštinė transformacija

$$\begin{cases} x_1 = y_1 \\ x_2 = y_2(y_n - y_1) + y_1 \\ \dots \\ x_{n-1} = y_{n-1}(y_n - y_1) + y_1, \\ x_n = y_n. \end{cases}$$

Pakeitimo jakobianas $J = (y_n - y_1)^{n-2}$.

Atlikę keitimą gauname a. v. $(Y_1, Y_n, Y_2, \dots, Y_{n-1})^T$ tankio funkciją

$$\frac{n(n-1)(y_n - y_1)^{n-2}}{(b-a)^{n-2}}(n-2)!, \quad a < y_1 < y_n < b, \quad 0 < y_2, \dots, y_{n-2} < 1.$$

Tankis yra sandauga a. v. $(Y_1, Y_n)^T$ tankio ir a. v. $(Y_2, \dots, Y_{n-1})^T$ tankio $(n-2)!$. Tai tankis variacinės eilutės, gautos pagal paprastąjį a. d. $Y \sim U(0, 1)$ imtį, kurios didumas $n-2$.

I.1.37. A. v. $(X_1, \dots, X_{k+1})^T$ tankio funkcija

$$f(x_1, \dots, x_{k+1}) = \frac{\lambda^{\eta_1 + \dots + \eta_{k+1}}}{\Gamma(\eta_1)\Gamma(\eta_2)\dots\Gamma(\eta_{k+1})} x_1^{\eta_1-1} \cdot \dots \cdot x_{k+1}^{\eta_{k+1}-1} e^{-\lambda(x_1 + \dots + x_{k+1})}.$$

Atliekame transformaciją

$$\begin{cases} z_1 = x_1/(x_1 + \dots + x_{k+1}) \\ z_2 = x_2/(x_1 + \dots + x_{k+1}) \\ \dots \\ z_k = x_k/(x_1 + \dots + x_{k+1}), \\ s = x_1 + \dots + x_{k+1}. \end{cases}$$

Atvirkštinė transformacija

$$\begin{cases} x_1 = sz_1 \\ x_2 = sz_2 \\ \dots \\ x_k = sz_k, \\ x_{k+1} = s(1 - z_1 - \dots - z_k). \end{cases}$$

Pakeitimo jakobianas $J = s^k$. Atlikę keitimą gauname tankį

$$\frac{\lambda^{\eta_1 + \dots + \eta_{k+1}}}{\Gamma(\eta_1)\Gamma(\eta_2)\dots\Gamma(\eta_{k+1})} (sz_1)^{\eta_1-1} \cdot \dots \cdot (sz_k)^{\eta_k-1} (s(1 - z_1 - \dots - z_k))^{\eta_{k+1}-1} e^{-\lambda s} s^k.$$

Suintegravę pagal s , gauname a. v. $(Z_1, \dots, Z_k)^T$ tankį

$$g(z_1, \dots, z_k) = \frac{\Gamma(\eta_1 + \dots + \eta_{k+1})}{\Gamma(\eta_1)\Gamma(\eta_2)\dots\Gamma(\eta_{k+1})} z_1^{\eta_1-1} \cdot \dots \cdot z_k^{\eta_k-1} (1 - z_1 - \dots - z_k)^{\eta_{k+1}-1},$$

kai $z_i > 0, z_1 + \dots + z_k < 1$. O tai yra Dirichlė skirstinio $D(\eta_1, \dots, \eta_k; \eta_{k+1})$ tankio funkcija. Kai $k = 1$, gauname beta skirstinį $Be(\eta_1, \eta_2)$.

I.1.38. Statistikos $X_{(n)}$ tankio funkcija yra $nF^{n-1}(x)f(x)$, $0 < x < \theta$; kai F ir f yra a. d. X pasiskirstymo funkcija ir tankis. Kadangi $F(x) = x/\theta$, $f(x) = 1/\theta$, tai gauname, kad $X_{(n)}$ tankis yra nx^{n-1}/θ^n , kai $0 < x < \theta$.

I.1.39. Tegu $Y_i = (X_i - \mu + \theta/2)/\theta$. Tada Y_1, \dots, Y_n yra paprastoji imtis a. d $Y \sim U(0, 1)$. Imties plotis $X_{(n)} - X_{(1)} = (Y_{(n)} - Y_{(1)})\theta$. Rasime a. d. $Y_{(n)} - Y_{(1)}$ pasiskirstymo funkciją

$$G(z) = 1 - \mathbf{P}\{Y_{(n)} - Y_{(1)} > z\} = 1 - \int_0^{1-z} \int_{x+z}^1 n(n-1)(y-x)^{n-2} dy dx =$$

$$1 - \int_0^{1-z} n(n-1)x^{n-1} \int_{(x+z)/x}^{1/x} (t-1)^{n-2} dt dx = nz^{n-1} - (n-1)z^n.$$

Diferencijuodami gauname tankio funkciją

$$g(z) = G'(z) = n(n-1)z^{n-2}(1-z), \quad 0 < z < 1.$$

Taigi imties plotis $Y_{(n)} - Y_{(1)} \sim Be(n-1, 2)$. A. d. $X_{(n)} - X_{(1)}$ tankio funkcija yra $g(z/\theta)/\theta$, $0 < z < \theta$.

I.1.40. Tegu $Y_i = (X_i - \mu + \theta/2)/\theta \sim U(0, 1)$, $i = 1, \dots, n$. Tada $Z = ((Y_{(1)} + Y_{(n)})/2 - 1/2)/(Y_{(n)} - Y_{(1)})$, $0 < Y_{(1)} < Y_{(n)} < 1$. Atlikime transformaciją

$$U = Y_{(n)} - Y_{(1)}, \quad Z = ((Y_{(1)} + Y_{(n)}) - 1)/(2(Y_{(n)} - Y_{(1)})).$$

Atvirkštinė transformacija

$$Y_{(1)} = (U(2Z-1) + 1)/2, \quad Y_{(n)} = (U(2Z+1) + 1)/2.$$

Pakeitimo jakobianas $|J| = U$. Gauname a. v. $(U, Z)^T$ tankio funkciją $g(u, z) = n(n-1)u^{n-1}$. Reikia nustatyti argumentų u, z kitimo sritį. Gauname

$$0 < (u(2z-1) + 1)/2 < (u(2z+1) + 1)/2 < 1,$$

$$-1 < u(2z-1) < u(2z+1) < 1, \quad (1-1/u) < 2z < (1/u-1).$$

Jeigu $z > 0$, tai $0 < u < 1/(1+2z)$; jeigu $z < 0$, tai $0 < u < 1/(1-2z)$. Taigi visais atvejais $0 < u < 1/(1+2|z|)$, $-\infty < z < \infty$.

A. d. Z tankio funkciją gauname integruodami $g(u, z)$ pagal u

$$f(z) = \int_0^{1/(1+2|z|)} n(n-1)u^{n-1} du = (n-1)(1/(1+2|z|))^n, \quad -\infty < z < \infty.$$

I.1.41. Nagrinėkime logaritma

$$-n \ln Y = Z = -\ln X_1 - \dots - \ln X_n \sim G(1, n),$$

nes a. d. $-\ln X_i \sim \mathcal{E}(1)$. Pereidami prie a. d $Y = e^{-Z/n}$, gauname jo tankį

$$g(y) = \frac{n^n}{\Gamma(n)} y^{n-1} (-\ln y)^{n-1}, \quad 0 < y < 1.$$

I.1.42. Fiksukime statistiką $X_{(k)} = y$. Tada antrosios imties elementų išsidėstymą galime interpretuoti kaip Bernulio eksperimentus: įgijimas reikšmės, ne didesnės už y su tikimybe y , ir reikšmės, didesnės už y su tikimybe $1 - y$. Taigi a. d. Z sąlyginis skirstinys yra binominis ($Z|X_{(k)} = y$) $\sim B(n, y)$,

$$\mathbf{P}\{Z = z|X_{(k)} = y\} = C_n^z y^z (1 - y)^{n-z}, \quad z = 0, 1, \dots, n.$$

Norint gauti besąlyginį Z skirstinį, reikia suvidurkinti pagal a. d. $X_{(k)}$ skirstinį $X_{(k)} \sim Be(k, m - k + 1)$.

$$\begin{aligned} \mathbf{P}\{Z = z\} &= C_n^z \frac{m!}{(k-1)!(m-k)!} \int_0^1 y^{k+z-1} (1-y)^{m+n-k-z} dy = \\ &\frac{C_n^z C_m^k}{C_{m+n}^{k+z}} \frac{k}{k+z}, \quad z = 0, 1, \dots, n. \end{aligned}$$

I.1.43. Binominio a. d. $X \sim B(n, p)$ r -asis faktorialinis momentas $\mathbf{E}X^{[r]} = \mathbf{E}(X(X-1)\dots(X-r+1)) = n^{[r]}p^r$, $r \leq n$. Taigi a. d. Z sąlyginio skirstinio r -asis faktorialinis momentas $\mathbf{E}(Z^{[r]}|X_{(k)}) = n^{[r]}X_{(k)}^r$. Suvidurkinę pagal $X_{(k)}$ skirstinį, gausime

$$\mathbf{E}Z^{[r]} = n^{[r]} \frac{m!}{(k-1)!(m-k)!} \int_0^1 y^{k+r-1} (1-y)^{m-k} dy = \frac{m!n!(k+r-1)!}{(k-1)!(m+r)!(n-r)!}.$$

I.1.44. Galima pasiūlyti keletą būdų įrodyti šį faktą.

1. Įrodyti, kad a. d. $\sqrt{n}(Y_{(k)} - p)/\sqrt{np(1-p)}$ tankio funkcija konverguoja į standartinio normaliojo skirstinio tankį $\varphi(x)$. Šis būdas panaudotas [2], 2.4.2 teoremoje.

2. Pasinaudosime sakyšiu $\mathbf{P}\{Y_{(k)} < z\} = \mathbf{P}\{Z_n \geq k\}$; čia $Z_n \sim B(n, z)$. Imdami $z = p + x/\sqrt{n}$, gauname $\mathbf{P}\{Y_{(k)} < z\} = \mathbf{P}\{\sqrt{n}(Y_{(k)} - p) < x\} = \mathbf{P}\{Z_n \geq k\}$, kai $Z_n \sim B(n, p + x/\sqrt{n})$. Taikydami CRT, gauname

$$\begin{aligned} \mathbf{P}\{Z_n \geq k\} &\approx 1 - \Phi\left(\frac{k - np - x\sqrt{n}}{\sqrt{n(p+x/\sqrt{n})(1-p-x/\sqrt{n})}}\right) = \\ &1 - \Phi\left(\frac{(k - np)/\sqrt{np(1-p)} - x/\sqrt{p(1-p)}}{\sqrt{1+x/\sqrt{np}}\sqrt{1-x/\sqrt{n(1-p)}}}\right) \rightarrow \Phi(x/\sqrt{p(1-p)}), \end{aligned}$$

nes $(k - np)/\sqrt{n} \rightarrow 0$, $x/\sqrt{n} \rightarrow 0$.

I.1.45. Kadangi $Y_i = F(X_i) \sim U(0, 1)$, tai a. d. $Y \sim U(0, 1)$ eilės p kvantilio $y(p)$ empirinis analogas yra $\hat{y}(p) = Y_{(k)}$, kai $k = [np]$, jei np sveikasis skaičius, ir $k = [np] + 1$ kitu atveju; bet kuriuo atveju $k/n \rightarrow 0$, kai $n \rightarrow \infty$. Remiantis I.1.44 pratimu

$$\sqrt{n}(\hat{y}(p) - p) \xrightarrow{d} Z \sim N(0, p(1-p)).$$

Kadangi $\hat{x}(p) = F^{-1}(\hat{y}(p))$, $x(p) = F^{-1}(y(p))$, tai remiantis delta metodu

$$\sqrt{n}(\hat{x}(p) - x(p)) \xrightarrow{d} U \sim N(0, \sigma^2(p)),$$

čia

$$\sigma^2(p) = [(F^{-1})'(p)]^2 p(1-p) = p(1-p)/f^2(x(p)).$$

I.1.46. Tvirtinimas yra išvada iš a. v. $(\hat{x}(p_1), \hat{x}(p_2))^T$ asimptotikos, pateiktos [2], 2.4.3 teoremoje.

I.1.47. Pakanka **I.1.46** pratime išrašyti $p_1 = 1/4, p_2 = 3/4$; jeigu tankis simetriškas, tai $f(x(1/4)) = f(x(3/4))$.

I.1.48. Kadangi $f^2(\mu|\mu, \sigma) = 1/(\pi^2 \sigma^2)$, tai a. d. $\hat{x}(1/2)$ asimptotinė dispersija yra $\pi^2 \sigma^2/(4n)$; $f^2(\mu + \sigma|\mu, \sigma) = 1/(4\pi^2 \sigma^2)$, tai a. d. $\hat{\sigma}$ asimptotinė dispersija yra $\pi^2 \sigma^2/(4n)$.

I.1.49. a) Prilyginę pasiskirstymo funkciją tikimybei p

$$F(x) = \frac{1}{\pi} \operatorname{arctg} \frac{x - \mu}{\sigma} + \frac{1}{2} = p$$

gauname p kvantilių

$$x(p) = \mu + \sigma \operatorname{tg}(\pi(p - 1/2)) = \mu - \sigma \operatorname{tg}(\pi(1/2 - p)),$$

$$x(1-p) - x(p) = 2\sigma \operatorname{tg}(\pi(1/2 - p)), \quad c(p) = 2 \operatorname{tg}(\pi(1/2 - p)).$$

Remiantis **I.1.46** pratimu statistikos $\hat{\sigma}$ asimptotinė dispersija

$$\sigma^2(p) = \frac{1}{c^2(p)} \frac{2p(1-2p)}{f^2(x(p))} \frac{\sigma^2}{n} = \frac{\pi^2 2p(1-2p)}{\sin^2(\pi(1-2p))} \frac{\sigma^2}{n}.$$

Pažymėję $z = \pi(1-2p)$, gausime

$$\sigma^2(p) = \frac{z(\pi-z)}{\sin^2 z} \frac{\sigma^2}{n} = h(z) \frac{\sigma^2}{n}.$$

Kai $z = \pi/2$ (t. y. $p = 1/4$), tai $h'(z)$ lygi nuliui ir keičia ženklą iš neigiamo į teigiamą. Asimptotinė dispersija minimali, kai $p = 1/4$; $\sigma^2(1/4) = \pi^2 \sigma^2/(4n)$.

I.1.50. Kadangi $f^2(\mu|\mu, \sigma) = 1/(2\pi\sigma^2)$, tai a. d. $\hat{x}(1/2)$ asimptotinė dispersija yra $\pi\sigma^2/(2n)$; $1/f^2(\mu+z_{1/4}\sigma|\mu, \sigma) = 2\pi e^{z_{1/4}^2/4} \sigma^2$, tai, remiantis **I.1.44** pratimu, a. d. $\hat{\sigma}$ asimptotinė dispersija yra $\pi e^{z_{1/4}^2/4} \sigma^2/(8nz_{1/4}^2) \approx 1,3605\sigma^2/n$.

I.1.51. a) Kadangi $x(p) = \mu - \sigma z_p$, $x(1-p) = \mu + \sigma z_p$, tai $c(p) = 2z_p$. b) Remiantis **I.1.46** pratimu statistikos $\hat{\sigma}$ asimptotinė dispersija

$$V(\hat{\sigma}) = \pi p(1-2p) e^{z_p^2} \sigma^2 / (nz_p^2).$$

Skaitiniai metodais minimizuodami šią funkciją p atžvilgiu, gauname, kad minimumas pasiekiamas, kai $p = 0,0692$. Tada asimptotinė dispersija yra $0,7666\sigma^2/n$. Vietoje kvartilių imdami kvantilius $x(0,0692)$ ir $x(0,9308)$ asimptotinę dispersiją sumažiname nuo $1,3605\sigma^2/n$ iki $0,7666\sigma^2/n$.

Pažymėsime, kad a. d. $s = \sqrt{s^2}$, kai s^2 yra nepaslinktoji empirinė dispersija, asimptotinė dispersija (žr. **I.1.95** pratimą) yra $0,5\sigma^2/n$.

I.1.52. Kadangi $f^2(\mu|\mu, \sigma) = 1/(4\sigma^2)$, tai a. d. $\hat{x}(1/2)$ asimptotinė dispersija yra σ^2/n ; $1/f^2(\mu+\sigma \ln 2|\mu, \sigma) = 16\sigma^2$, tai, remiantis **I.1.46** pratimu, a. d. $\hat{\sigma}$ asimptotinė dispersija yra $\sigma^2/(n \ln^2 2) \approx 2,0814\sigma^2/n$.

- I.1.53.** a) Randame $x(p) = \mu + \sigma \ln(2p)$, $x(1-p) = \mu - \sigma \ln(2p)$ ir $c(p) = -2 \ln(2p)$.
 b) Remiantis **I.1.46** pratimu statistikos $\hat{\sigma}$ asymptotinė dispersija

$$\sigma^2(p) = \frac{1-2p}{2p \ln^2(2p)} \frac{\sigma^2}{n}.$$

Skaitiniai metodais minimizuodami šią funkciją p atžvilgiu, gauname, kad minimumas pasiekiamas, kai $p \approx 0,1015$. Tada asymptotinė dispersija yra $1,5441\sigma^2/n$. Vietoje kvartilių imdami kvantilius $x(0,1015)$ ir $x(0,8985)$ asymptotinę dispersiją sumažiname nuo $2,0814\sigma^2/n$ iki $1,5441\sigma^2/n$.

- I.1.54.** Statistika $F(\hat{x})$ yra empirinė mediana, gauta stebint a.d. $Y \sim U(0, 1)$. Tvirtinimas išplaukia iš **I.1.44** pratimo.

- I.1.55.** A.d. $X \sim \mathcal{E}(\lambda)$ mediana $x(1/2) = \ln 2/\lambda$. Remiantis **I.1.45** pratimu

$$\lambda \sqrt{2n+1}(\tilde{x} - \ln 2/\lambda) \xrightarrow{d} Z \sim N(0, 1).$$

- I.1.56.** A.d. $S_k \sim Be(k, n-k+1)$. Remiantis sąryšiu su gama skirstiniu (žr. 1 priedo 1.P.3 lentelę) $S_k = Y/(Y+Z)$; čia Y ir Z nepriklausomi ir $Y \sim G(1, k)$, $Z \sim G(1, n-k+1)$. Jeigu k fiksotas, o $n \rightarrow \infty$, tai

$$nS_k = Y/((Y+Z)/n) \xrightarrow{d} Y \sim G(1, k),$$

nes $Y+Z \sim G(1, n+1)$ ir remiantis didžiuoju skaičių dėsniu

$$\frac{Y+Z}{n} = \frac{Y+Z}{n+1} \frac{n+1}{n} \xrightarrow{P} 1, \quad n \rightarrow \infty.$$

- I.1.57.** Pagal **I.1.56** pratimą a.d. $U_k = nF(X_{(k)}) \xrightarrow{d} Y \sim G(1, k)$. Kadangi $F(x) = (x-a)/(b-a)$, $a < x < b$, tai a.d. $X_{(k)} = a + (b-a)U_k/n$. Taigi a.d. $X_{(k)} - a$ skirstinys aproksimuojamas gama skirstiniu $G(n/(b-a), k)$.

A.d. $V_k = n(1 - F(X_{(n-k+1)})) \xrightarrow{d} Y \sim G(1, k)$, o $X_{(n-k+1)} = b - (b-a)V_k/n$ yra a.d. V_k tiesinė funkcija.

- I.1.58.** Eksponentinio skirstinio $\mathcal{E}(\lambda)$ pasiskirstymo funkcija $F(x) = 1 - e^{-\lambda x}$. Iš lygybės $U_k = nF(X_{(k)}) = n(1 - e^{-\lambda X_{(k)}})$ gauname $X_{(k)} = -(1/\lambda) \ln(1 - U_k/n) \approx U_k/(n\lambda)$. Kadangi U_k skirstinys aproksimuojamas skirstiniu $G(1, k)$, tai a.d. $X_{(k)}$ skirstinį galima aproksimuoti skirstiniu $G(n\lambda, k)$.

Iš lygybės $V_k = n(1 - F(X_{(n-k+1)}))$ gauname $X_{(n-k+1)} = -(1/\lambda)(\ln V_k - \ln n)$. A.d. V_k skirstinys aproksimuojamas gama skirstiniu $G(1, k)$. Tada $-\ln V_k$ aproksimuojamas skirstiniu, kurio tankis

$$g(y) = \frac{1}{(k-1)!} e^{-ky} e^{-\lambda e^{-y}}.$$

Matome, kad a.d. $X_{(n-k+1)}$ asymptotinis skirstinys yra dvigubo eksponentinio (ekstremalių reikšmių) tipo.

I.1.4 skyrelis

I.1.59. Gauname $\bar{X} = \frac{1}{n} \sum_{i=1}^k n_i \bar{X}_i$, $n = n_1 + \dots + n_k$;

$$s^2 = \left\{ \sum_{i=1}^k (n_i - 1)s_i^2 + \sum_{i=1}^k n_i \bar{X}_i^2 - n \bar{X}^2 \right\} / (n - 1).$$

I.1.60. Gauname I tipo kino juostoms $\bar{X}^{(1)} = 22,333$, $(s^{(1)})^2 = 11,278$; II tipo kino juostoms $\bar{X}^{(2)} = 18,282$, $(s^{(2)})^2 = 12,368$.

I.1.61. Gauname $\bar{X}_{n+1} = (n \bar{X}_n + X_{n+1}) / (n + 1)$;

$$s_{n+1}^2 = [(n - 1)s_n^2 + n \bar{X}_n^2 - (n + 1)\bar{X}_{n+1}^2] / n.$$

I.1.62. Remsimės charakteristinių funkcijų išraiškomis iš 1 priedo 1.P.2-1.P.3 lentelių.

- a) a. d. $X \sim N(\mu, \sigma^2)$ charakteristinė funkcija $\varphi_X(t) = e^{i\mu t - t^2 \sigma^2/2}$; tada a. d. \bar{X} charakteristinė funkcija $\varphi_{\bar{X}}(t) = e^{i\mu t - t^2 \sigma^2/(2n)}$, t. y. $\bar{X} \sim N(\mu, \sigma^2/n)$;
- b) a. d. $X \sim K(\mu, \sigma)$ charakteristinė funkcija $\varphi_X(t) = e^{i\mu t - |t|\sigma}$; tada a. d. \bar{X} charakteristinė funkcija $\varphi_{\bar{X}}(t) = e^{i\mu t - |t|\sigma}$, t. y. $\bar{X} \sim K(\mu, \sigma)$;
- c) a. d. $X \sim G(\lambda, \eta)$ charakteristinė funkcija $\varphi_X(t) = (\lambda/(\lambda - it))^\eta$; tada a. d. $n \bar{X}$ charakteristinė funkcija $\varphi_{n \bar{X}}(t) = (\lambda/(\lambda - it))^{n\eta}$, t. y. $n \bar{X} \sim G(\lambda, n\eta)$;
- d) a. d. $X \sim B(k, p)$ charakteristinė funkcija $\varphi_X(t) = (q + pe^{it})^k$; tada a. d. $n \bar{X}$ charakteristinė funkcija $\varphi_{n \bar{X}}(t) = (q + pe^{it})^{kn}$, t. y. $n \bar{X} \sim B(nk, p)$;
- e) a. d. $X \sim \mathcal{P}(\lambda)$ charakteristinė funkcija $\varphi_X(t) = e^{\lambda(e^{it} - 1)}$; tada a. d. $n \bar{X}$ charakteristinė funkcija $\varphi_{n \bar{X}}(t) = e^{n\lambda(e^{it} - 1)}$, t. y. $n \bar{X} \sim \mathcal{P}(n\lambda)$.

I.1.63. A. d. $\bar{X} - \bar{Y} \sim N(\mu_1 - \mu_2, \sigma^2((1/m) + (1/n)))$ arba $Z = (\bar{X} - \bar{Y} - (\mu_1 - \mu_2)) / (\sigma^2((1/m) + (1/n))) \sim N(0, 1)$. Toliau $s_1^2(m-1)/\sigma^2 \sim \chi^2(m-1)$, $s_2^2(n-1)/\sigma^2 \sim \chi^2(n-1)$, tada $V = [s_1^2(m-1) + s_2^2(n-1)]/\sigma^2 \sim \chi^2(m+n-2)$. Pagal Stjudento skirstinio apibrėžimą

$$t = \frac{Z}{\sqrt{V/(m+n-2)}} \sim S(m+n-2).$$

I.1.64. Tegu i -osios imties elementai yra $X_{i1}, \dots, X_{in_i}, i = 1, \dots, k$. Nagrinėkime deštinį

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \mu)^2 / \sigma^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i + \bar{X}_i - \bar{X} + \bar{X} - \mu)^2 / \sigma^2 =$$

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2 / \sigma^2 + \sum_{i=1}^k n_i (\bar{X}_i - \bar{X})^2 / \sigma^2 + n (\bar{X} - \mu)^2 / \sigma^2.$$

Kairėje lygybės pusėje turime kvadratinę formą, kuri turi χ^2 skirstinį su n laisvės laipsniu. Dešinėje pusėje pirmasis démuo yra $U = \sum_{i=1}^k (n_i - 1)s_i^2 / \sigma^2 \sim \chi^2(n-k)$. Kadangi $\bar{X} \sim N(\mu, \sigma^2/n)$, tai paskutinis démuo $W \sim \chi^2(1)$. Remiantis Fišerio ir Kočreno teorema (žr. [15], 3b.4 skyrelj) vidurinysis dešinės pusės narys $V \sim \chi^2(k-1)$ ir U, V, W yra nepriklausomi.

I.1.65. Išplaukia iš Fišerio skirstinio apibrėžimo.

I.1.66. Tegu $Z_i = X_{1i} - X_{2i}$, $\mathbf{E}Z_i = \mu_1 - \mu_2$, $\mathbf{V}Z_i = \sigma^2 = \sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2$. A. d. Z_1, \dots, Z_n yra paprastoji imtis, gauta stebint a. d. $Z \sim N(\mu_1 - \mu_2, \sigma^2)$. Remiantis [2], 2.5.1 teorema

$$\sqrt{n}(\bar{Z} - (\mu_1 - \mu_2))/s_Z \sim S(n-1), \quad \bar{Z} = \sum_{i=1}^n Z_i/n, \quad s_Z^2 = \sum_{i=1}^n (Z_i - \bar{Z})^2/(n-1).$$

Tačiau

$$\begin{aligned} s_Z^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_{1i} - X_{2i} - (\bar{X}_1 - \bar{X}_2))^2 = \frac{1}{n-1} \sum_{i=1}^n (X_{1i} - \bar{X}_1)^2 + \frac{1}{n-1} \sum_{i=1}^n (X_{2i} - \bar{X}_2)^2 \\ &\quad - 2 \frac{1}{n-1} \sum_{i=1}^n (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2) = s_1^2 + s_2^2 - 2rs_1s_2. \end{aligned}$$

I.1.67. Randame

$$\begin{aligned} \bar{Z} - \bar{X} &= \frac{m}{m+n}(\bar{Y} - \bar{X}), \quad \mathbf{E}(\bar{Z} - \bar{X}) = \frac{m}{m+n}(\mathbf{E}Y_i - \mathbf{E}X_i); \\ \mathbf{V}(\bar{Z} - \bar{X}) &= \frac{m^2}{(m+n)^2} \left(\frac{\sigma^2}{m} + \frac{\sigma^2}{n} \right) = \frac{m\sigma^2}{n(m+n)}. \end{aligned}$$

I.1.68. Randame $\mathbf{V}X = \sigma^2$, $F(X) \sim U(0, 1)$, $\mathbf{V}(F(X)) = 1/12$,

$$\begin{aligned} \mathbf{Cov}(X, F(X)) &= \mathbf{Cov}(X - \mu, F(X)) = \mathbf{E}((X - \mu)F(X)) = \\ &= \int_{-\infty}^{\infty} \frac{x - \mu}{\sigma} \Phi\left(\frac{x - \mu}{\sigma}\right) \varphi\left(\frac{x - \mu}{\sigma}\right) dx = \frac{\sigma}{\sqrt{2\pi}} \int_{-\infty}^{\infty} t\Phi(t)e^{-t^2/2} dt = \\ &= -\frac{\sigma}{\sqrt{2\pi}} \int_{-\infty}^{\infty} \Phi(t)de^{-t^2/2} = \frac{\sigma}{2\pi} \int_{-\infty}^{\infty} e^{-t^2} dt = \frac{\sigma}{2\sqrt{\pi}}. \end{aligned}$$

Gauname $\rho(X, F(X)) = \mathbf{Cov}(X, F(X))/\sqrt{\mathbf{V}X\mathbf{V}(F(X))} = \sqrt{3/\pi}$.

I.1.69. Imdami $SS(\alpha, \beta)$ išvestines pagal α ir β ir prilyginę išvestines nuliui, gauname lygčių sistemą

$$2 \sum_i (Y_i - \alpha - \beta(x_i - \bar{x})) = 0,$$

$$2 \sum_i (Y_i - \alpha - \beta(x_i - \bar{x}))(x_i - \bar{x}) = 0.$$

Išsprendę gauname $\hat{\alpha} = \bar{Y}$, $\hat{\beta} = \sum_i Y_i(x_i - \bar{x}) / \sum_i (x_i - \bar{x})^2$. A. d. $\hat{\alpha}$ ir $\hat{\beta}$ turi normaliuosius skirstinius, nes yra normaliuoję a. d. Y_i tiesiniai dariniai. Randame $\mathbf{V}(\hat{\alpha}) = \sigma^2/n$, $\mathbf{V}(\hat{\beta}) = \sigma^2 / \sum_i (x_i - \bar{x})^2$ ir $\mathbf{Cov}(\hat{\alpha}, \hat{\beta}) = 0$. Taigi a. d. $\hat{\alpha}$ ir $\hat{\beta}$ yra nepriklausomi. Nesunku patikrinti, kad $\mathbf{Cov}(\hat{\alpha}, Y_i - \hat{\alpha} - \hat{\beta}(x_i - \bar{x})) = 0$, $\mathbf{Cov}(\hat{\beta}, Y_i - \hat{\alpha} - \hat{\beta}(x_i - \bar{x})) = 0$. Todėl SS_E nepriklauso nuo $\hat{\alpha}$ ir $\hat{\beta}$.

Nagrinėkime kvadratinę formą

$$\sum_i (Y_i - \alpha - \beta(x_i - \bar{x}))^2 / \sigma^2 = \sum_i [(Y_i - \hat{\alpha} - \hat{\beta}(x_i - \bar{x})) + (\hat{\alpha} - \alpha) + (\hat{\beta} - \beta)(x_i - \bar{x})]^2 / \sigma^2 = \\ SS_E / \sigma^2 + n(\hat{\alpha} - \alpha)^2 / \sigma^2 + (\hat{\beta} - \beta)^2 \sum_i (x_i - \bar{x})^2 / \sigma^2,$$

nes visos dvigubos sandaugos lygios nuliui. Kairėje lygybės pusėje kvadratinė forma turi χ^2 skirstinį su n laisvės laipsnių. Dešinėje pusėje du paskutiniai nariai turi χ^2 skirstinius su 1 laisvės laipsniu. Remiantis Fišerio ir Kočreno teorema (žr. [15], 3b.4 skyrelį), SS_E / σ^2 turi χ^2 skirstinį su $n - 2$ laisvės laipsniais.

I.1.70. A. d. Y_j turi normaliųjį skirstinį, nes yra normaliųjų a. d. tiesinis darinys. Tiesiogiai patikriname, kad $\mathbf{V}Y_j = \sigma^2$, $\mathbf{Cov}(Y_j, Y_{j'}) = 0, j \neq j'$. Taigi a. d. Y_1, \dots, Y_{n-1} yra nepriklausomi ir vienodai pasiskirstę pagal $N(0, \sigma^2)$.

I.1.71. $Ed = \sum_{i=1}^n \mathbf{E}|X_i - \mu|/n = \mathbf{E}|X_i - \mu|, \mathbf{V}d = \mathbf{V}|X_i - \mu|/n$. Randame

$$\mathbf{E}|X_i - \mu| = \frac{2}{\sqrt{2\pi}\sigma} \int_0^\infty (x - \mu)e^{-(x-\mu)^2/(2\sigma^2)} dx = \frac{2\sigma}{\sqrt{2\pi}} \int_0^\infty te^{-t^2/2} dt = \sqrt{\frac{2}{\pi}}\sigma;$$

$$\mathbf{V}d = \mathbf{V}|X_i - \mu|/n = [\mathbf{E}(X_i - \mu)^2 - (\mathbf{E}|X_i - \mu|)^2]/n = \sigma^2(1 - 2/\pi)/n.$$

I.1.72. Randame

$$\mathbf{E}\bar{X} = \frac{1}{n} \sum_i \mathbf{E}X_i = \mu; \quad \mathbf{V}\bar{X} = \frac{1}{n^2} \sum_i \mathbf{V}X_i = \frac{\sigma^2}{n}.$$

Pažymėkime $Y_i = X_i - \mu$, $\mathbf{E}Y_i = 0$, $\mathbf{E}Y_i^2 = \sigma^2$, $\mathbf{E}Y_i^3 = \mu_3$, $\mathbf{E}Y_i^4 = \mu_4$. Tada

$$\mu_3(\bar{X}) = \mathbf{E}(\bar{X} - \mu)^3 = \frac{1}{n^3} \mathbf{E}(\sum_i Y_i)^3 = \frac{1}{n^3} \mathbf{E}(\sum_i Y_i^3) = \frac{\mu_3}{n^2},$$

nes kitose sumose bus démenys pavidalo $Y_i^2 Y_j, i \neq j$, arba pavidalo $Y_i Y_j Y_l, i \neq j \neq l$. Kadangi Y_1, \dots, Y_n nepriklausomi ir $\mathbf{E}Y_i = 0$, tai tokį sumų vidurkiai lygūs nuliui.

$$\mu_4(\bar{X}) = \frac{1}{n^4} \mathbf{E}(\sum_i Y_i)^4 = \frac{1}{n^4} \mathbf{E}(\sum_i Y_i^4 + 3 \sum_{i \neq j} Y_i^2 Y_j^2) = \frac{\mu_4 + 3(n-1)\sigma^4}{n^3}.$$

Randame

$$\gamma_1(\bar{X}) = \frac{\mu_3(\bar{X})}{\mathbf{V}(\bar{X})^{3/2}} = \frac{\mu_3}{\sigma^3 \sqrt{n}} = \frac{\gamma_1}{\sqrt{n}};$$

$$\gamma_2(\bar{X}) = \frac{\mu_4(\bar{X})}{\mathbf{V}(\bar{X})^2} - 3 = \frac{1}{n} \left(\frac{\mu_4}{\sigma^4} - 3 \right) = \frac{\gamma_2}{n}.$$

Aritmetinio vidurkio asimetrija \sqrt{n} , o ekscesas n kartų mažesni už stebėto a. d. asimetriją ir ekscesą.

I.1.73. Pirmasis tvirtinimas yra CRT atskiras atvejis. Antrasis tvirtinimas išplaukia iš to, kad $\sqrt{m_2} \xrightarrow{P} \sigma$.

I.1.74. Tai atskiras atvejis CRT, nes \bar{X} yra suma vienodai pasiskirsčiusių a.d., $\mathbf{E}_\lambda(\bar{X}) = \lambda$, $\mathbf{V}_\lambda(\bar{X}) = \lambda/n$.

I.1.75. Kadangi $\sqrt{n}(\bar{X} - \lambda) \xrightarrow{d} Y \sim N(0, \lambda)$, tai remiantis delta metodu (žr. [2], 2.4 skyrelj)

$$\sqrt{n}(g(\bar{X}) - g(\lambda)) \xrightarrow{d} Yg'(\lambda) \sim N(0, \lambda[g'(\lambda)]^2).$$

Kadangi $g(\lambda) = \sqrt{\lambda}$, $[g'(\lambda)]^2 = 1/(4\lambda)$, tai

$$2\sqrt{n}(\sqrt{\bar{X}} - \sqrt{\lambda}) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.76. Kadangi $\sqrt{n}(\bar{X} + 1/(2n) - \lambda) \xrightarrow{d} Y \sim N(0, \lambda)$, tai remiantis delta metodu

$$\sqrt{n}(g(\bar{X}) - g(\lambda)) \xrightarrow{d} Yg'(\lambda) \sim N(0, \lambda[g'(\lambda)]^2).$$

Kadangi $g(\lambda) = \lambda^{2/3}$, $[g'(\lambda)]^2 = 4/(9\lambda^{2/3})$, tai

$$\sqrt{n} \frac{(\bar{X} + 1/(2n))^{2/3} - \lambda^{2/3}}{2\lambda^{1/6}/3} \xrightarrow{d} Z \sim N(0, 1).$$

I.1.77. Pirmasis tvirtinimas yra CRT atskiras atvejis. Antrasis tvirtinimas išplaukia iš to, kad $\bar{X} \xrightarrow{P} p$.

I.1.78. Kadangi $\sqrt{n}(\bar{X} - p) \xrightarrow{d} Y \sim N(0, p(1-p))$, tai remiantis delta metodu (žr. [2], 2.4 skyrelj)

$$\sqrt{n}(g(\bar{X}) - g(p)) \xrightarrow{d} Yg'(p) \sim N(0, p(1-p)[g'(p)]^2).$$

Kadangi $g(p) = \arcsin(2p - 1)$, $[g'(p)]^2 = 1/(p(1-p))$, tai

$$\sqrt{n}(\arcsin(2\bar{X} - 1) - \arcsin(2p - 1)) \xrightarrow{d} Z \sim N(0, 1).$$

I.1.79. A. d. $X \sim U(0, \theta)$ vidurkis ir dispersija yra $\mathbf{E}_\theta X = \theta/2$, $\mathbf{V}_\theta X = \theta^2/12$. Tada $\mathbf{E}_\theta(2\bar{X}) = \theta$, $\mathbf{V}_\theta(2\bar{X}) = \theta^2/(3n)$ ir pritaikome CRT.

I.1.80. A. d. $X_{(n)}$ tankio funkcija $f_n(x) = nx^{n-1}/\theta^n$, $0 < x < \theta$. Randame

$$\mathbf{E}_\theta X_{(n)} = \frac{n}{n+1}\theta, \quad \mathbf{E}_\theta(X_{(n)}^2) = \frac{n\theta^2}{n+2}, \quad \mathbf{V}_\theta(X_{(n)}) = \frac{n\theta^2}{(n+1)^2(n+2)}.$$

Tada

$$\mathbf{E}_\theta\left(\frac{n+1}{n}X_{(n)}\right) = \theta, \quad \mathbf{V}_\theta\left(\frac{n+1}{n}X_{(n)}\right) = \frac{\theta^2}{n(n+2)} = O\left(\frac{1}{n^2}\right).$$

I.1.81. Remiantis I.1.79 pratimu $\sqrt{n}(2\bar{X} - \theta) \xrightarrow{d} Y \sim N(0, \theta^2/3)$; $g(\theta) = \ln \theta$, $[g'(\theta)]^2 = 1/\theta^2$. Remiantis delta metodu

$$\sqrt{3n}(\ln(2\bar{X}) - \ln \theta) \xrightarrow{d} X \sim N(0, 1).$$

I.1.82. Kadangi stebimo a. d. pirmieji momentai yra $\mathbf{E}_p X = 1/p$, $\mathbf{V}_p X = q/p^2$, tai tvirtinimas yra CRT atskiras atvejis.

I.1.83. Pagal I.1.82 pratimą $\sqrt{n}(\bar{X} - 1/p) \xrightarrow{d} Y \sim N(0, q/p^2)$, tai remiantis delta metodu (žr. [2], 2.4 skyrelį)

$$\sqrt{n}(g(\bar{X}) - g(1/p)) \xrightarrow{d} Yg'(1/p) \sim N(0, (q/p^2)[g'(1/p)]^2).$$

Kadangi $g(1/p) = \ln[(1+\sqrt{q})/p - 1/2]$, $[g'(1/p)]^2 = p^2/q$, tai išrašę gauname suformuluotą tvirtinimą.

I.1.84. Centriniai empiriniai momentai nekinta keičiant imties elementus X_i į $Y_i = X_i - \mu$. Tada $\mathbf{E}Y_i = 0$, $\mathbf{V}Y_i = \mathbf{V}X_i = \sigma^2$

$$m_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2 = \frac{1}{n} \sum_{i=1}^n Y_i^2 - \bar{Y}^2.$$

Randame

$$\mathbf{E}m_2 = \frac{1}{n} \sum_{i=1}^n \mathbf{E}Y_i^2 - \mathbf{E}\bar{Y}^2 = \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n}\sigma^2 \neq \sigma^2.$$

Nepaslinktoji empirinė dispersija

$$s^2 = \frac{n}{n-1} m_2 = \frac{n}{n-1} \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2, \quad \mathbf{E}s^2 = \sigma^2.$$

I.1.85. Turime $\mathbf{V}m_2 = \mathbf{E}(m_2)^2 - (\mathbf{E}m_2)^2$, $\mathbf{E}m_2 = (n-1)\sigma^2/n$.

$$\mathbf{E}m_2^2 = \mathbf{E}(a_2 - \bar{Y}^2)^2 = \mathbf{E}(a_2^2 - 2a_2\bar{Y}^2 + \bar{Y}^4).$$

$$\mathbf{E}a_2^2 = \frac{1}{n^2} \mathbf{E}(\sum_j Y_j^2)^2 = \frac{\mu_4 + (n-1)\sigma^4}{n},$$

$$\mathbf{E}(a_2\bar{Y}^2) = \frac{1}{n^3} \mathbf{E}(\sum_j Y_j^2(\sum_i Y_i^2 + \sum_{i \neq k} Y_i Y_k)) = \frac{\mu_4 + (n-1)\sigma^4}{n^2},$$

$$\mathbf{E}\bar{Y}^4 = \frac{1}{n^4} \mathbf{E}(\sum_j Y_j^2 + \sum_{i \neq k} Y_i Y_k)^2 = \frac{1}{n^4} \mathbf{E}(\sum_j Y_j^4 + \sum_{j \neq l} Y_j^2 Y_l^2$$

$$+ 2 \sum_j Y_j^2 \sum_{i \neq k} Y_i Y_k + \sum_{i \neq k} Y_i Y_k \sum_{i' \neq k'} Y_{i'} Y_{k'}) = \frac{\mu_4 + 3(n-1)\sigma^4}{n^3}.$$

Gauname

$$\mathbf{E}m_2^2 = \frac{(n-1)^2}{n^3} \mu_4 + \frac{(n-1)(n^2-2n+3)}{n^3} \sigma^4.$$

Atėmę $(\mathbf{E}m_2)^2$ ir išrikiavę narius n laipsniais, gauname

$$\mathbf{V}m_2 = \frac{\mu_4 - \sigma^4}{n} - \frac{2\mu_4 - 2\sigma^4}{n^2} + \frac{\mu_4 - 3\sigma^4}{n^3} = \frac{\mu_4 - \sigma^4}{n} + O(\frac{1}{n^2}).$$

I.1.86. Statistika $n\alpha_k$ yra suma nepriklausomų vienodai pasiskirsčiusių a. d. X_1^k, \dots, X_n^k su vidurkiais $\mathbf{E}X_i^k = \alpha_k$ ir dispersijomis $\mathbf{V}X_i^k = \mathbf{E}X_i^{2k} - (\mathbf{E}X_i^k)^2 = \alpha_{2k} - \alpha_k^2$. Pakanka pasinaudoti sustiprintu DSD ir CRT.

I.1.87. Statistika $n\alpha$ yra suma nepriklausomų vienodai pasiskirsčiusių a. v. $(X_i^1, X_i^2, \dots, X_i^k)^T$, $i = 1, 2, \dots, n$, su vidurkių vektoriumi $\boldsymbol{\alpha}$ ir kovariacijų matrica $\boldsymbol{\Sigma} = [\sigma_{ij}]_{k \times k}$, $\sigma_{ij} = \text{Cov}(X^i, X^j) = \mathbf{E}X^{i+j} - \mathbf{E}(X^i)\mathbf{E}(X^j) = \alpha_{i+j} - \alpha_i\alpha_j$, $i, j = 1, \dots, k$. Pakanka pasinaudoti daugiamate CRT.

I.1.88. a) $m_2 = a_2 - \bar{X}^2$; kadangi $a_2 \xrightarrow{P} \alpha_2$, $a_2^2 \xrightarrow{P} \alpha_1^2$, tai $m_2 = a_2 - a_2^2 \xrightarrow{P} \alpha_2 - \alpha_1^2 = \sigma^2$.
 b) Nagrinėjant empirinę dispersiją (ar kitus aukštesnių eilių centrinius empirinius momentus), nemažinant bendrumo galima tarti, kad $\mathbf{E}X = \alpha_1 = 0$, ir pradinis momentus α_j galima pakeisti centriniais μ_j , $j = 2, 3, \dots$

Remiantis I.1.87 pratimu

$$\sqrt{n}(\bar{X} - \alpha_1, a_2 - \alpha_2)^T \xrightarrow{d} \mathbf{Y} \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma});$$

čia $\boldsymbol{\mu} = (0, 0)^T$, $\boldsymbol{\Sigma} = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = \mu_2$, $\sigma_{12} = \mu_3$, $\sigma_{22} = \mu_4 - \sigma^4$. Statistika m_2 yra momentų \bar{X} ir a_2 funkcija; $m_2 = g(\bar{X}, a_2) = a_2 - \bar{X}^2$; $g(\alpha_1, \alpha_2) = \alpha_2 - \alpha_1^2$; $g'_{\alpha_1}(\alpha_1, \alpha_2) = 0$, $g'_{\alpha_2}(\alpha_1, \alpha_2) = 1$. Remiantis delta metodu

$$\sqrt{n}(m_2 - \sigma^2) \xrightarrow{d} Y \sim N(0, \mu_4 - \sigma^4),$$

arba

$$\sqrt{n}(m_2 - \sigma^2)/\sqrt{\mu_4 - \sigma^4} \xrightarrow{d} Z \sim N(0, 1).$$

Remiantis I.1.85 pratimu $\mathbf{V}m_2 = (\mu_4 - \sigma^4)/n + O(1/n^2)$, tai $(\mu_4 - \sigma^4)/n$ galima pakeisti $\mathbf{V}m_2$. Kadangi $s^2 = nm_2/(n-1)$, tai m_2 galime pakeisti s^2 .

c) Žr. [2], 2.5.1 teorema.

I.1.89. Kadangi

$$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2}} \xrightarrow{d} Z \sim N(0, 1),$$

tai reikia tik pasinaudoti tuo, kad $s_1^2 \xrightarrow{P} \sigma_1^2$, $s_2^2 \xrightarrow{P} \sigma_2^2$.

I.1.90. $\text{Cov}(\bar{X}, s^2) = \text{Cov}(\bar{Y}, s^2)$, kai $Y_i = X_i - \mu$, $\mathbf{E}Y_i = 0$, $\mathbf{E}Y_i^k = \mu_k$.

$$\begin{aligned} \text{Cov}(\bar{Y}, s^2) &= \mathbf{E}(\bar{Y}s^2) = \frac{1}{n(n-1)} \mathbf{E}\left[\sum_i Y_i \left(\sum_j Y_j^2 - \right.\right. \\ &\quad \left.\left. \frac{1}{n} \left(\sum_j Y_j^2 + \sum_{j \neq l} Y_j Y_l\right)\right)\right] = \frac{\mu_3}{n}. \end{aligned}$$

I.1.91. Jeigu pažymėsime $Y_i = X_i - \mu$, tai

$$m_3 = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^3 = a_3 - 3a_2\bar{Y} + 2\bar{Y}^3.$$

$$\mathbf{E}m_3 = \mathbf{E}\left[\frac{1}{n} \sum_{i=1}^n Y_i^3 - \frac{3}{n^2} \sum_{i=1}^n Y_i^2 \sum_{j=1}^n Y_j + \right]$$

$$\frac{2}{n^3} \left(\sum_{i=1}^n Y_i^2 + \sum_{i \neq j} Y_i Y_j \right) \sum_{l=1}^n Y_l = \frac{(n-1)(n-2)}{n^2} \mu_3.$$

Analogiškai gauname

$$\mathbf{E}m_4 = \frac{(n-1)(n^2 - 3n + 3)}{n^3} \mu_4 + \frac{3(n-1)(2n-3)}{n^3} \sigma^4.$$

Jeigu imsime statistikas

$$m_3^* = \frac{n^2}{(n-1)(n-2)} m_3, \quad m_4^* = \left[m_4 - \frac{3(2n-3)}{n^2 - 2n + 3} m_2^2 \right] \frac{n(n^2 - 2n + 5)}{(n-1)(n-2)(n-3)},$$

tai $\mathbf{E}m_3^* = \mu_3$, $\mathbf{E}m_4^* = \mu_4$.

I.1.92. Kadangi

$$m_k = C_k^0 a_k - C_k^1 a_{k-1} a_1 + \dots + (-1)^k a_1^k$$

yra pradinių momentų a_1, \dots, a_k tolydi funkcija, tai remiantis daugiamate CRT (**I.1.87** pratimas) statistika m_k asimptotiškai turi normalujį skirstinį. Pagal delta metodą asimptotinės dispersijos pagrindinė dalis $B_k^2 = \psi^T \Sigma \psi$; vektorius $\psi = (\psi_1, \dots, \psi_k)^T$ gaunamas imant m_k dalines išvestines taške α (primename, kad nagrinėjant centrinius momentus galima imti $\alpha_1 = 0, \alpha_j = \mu_j$).

Randame $\psi_1 = -k\alpha_{k-1}, \psi_2 = \dots = \psi_{k-1} = 0, \psi_k = 1$.

$$\begin{aligned} nB_k^2 &= \psi_1^2 \alpha_2 + 2\psi_1 \psi_k \alpha_{k+1} + \psi_k^2 (\alpha_{2k} - \alpha_k^2) = \\ &= \mu_{2k} - \mu_k^2 - 2k\mu_{k-1}\mu_{k+1} + k^2\mu_{k-1}^2\sigma^2. \end{aligned}$$

Normaliojo skirstinio atveju $\mu_{2r} = \sigma^{2r}(2r-1)!!$, $\mu_{2r+1} = 0$.

I.1.93. Gauname analogiškai ankstesniams pratimui taikydami delta metodą dvimačiu atveju.

I.1.94. Kadangi funkcija $H(\lambda)$ tolydi, o a. d. \bar{X} galioja CRT, t. y. $\sqrt{n}(\bar{X} - \lambda) \xrightarrow{d} Y \sim N(0, \lambda)$, tai, remdamiesi delta metodu, gauname

$$\sqrt{n} \left(\frac{1}{\bar{X}^3} - \frac{1}{\lambda^3} \right) \xrightarrow{d} Y \sim N(0, B^2),$$

$$B^2 = [H'(\lambda)]^2 V X = \frac{9}{\lambda^7}.$$

I.1.95. a) Atlikta transformacija $s = H(s^2) = \sqrt{s^2}$. Funkcija H tolydi, o statistikai s^2 galioja CRT. Remiantis delta metodu funkcijai s irgi galioja CRT, o asimptotinės dispersijos pagrindinė dalis $B^2/n = [H'(\sigma^2)]^2 V s^2 = (\mu_4 - \sigma^4)/(4n\sigma^2)$.

Kai skirstinys normalusis, s momentus galima rasti remiantis tuo, kad $(n-1)s^2/\sigma^2 \sim \chi^2(n-1)$.

b) Statistika $g_1 = H(m_2, m_3) = m_3/\sqrt{m_2^3}$. Tegu $H_1 = H'_{m_2}(\mu_2, \mu_3) = -3\mu_3/(2\sigma^5)$, $H_2 = H'_{m_3}(\mu_2, \mu_3) = 1/(\sigma^3)$. Tada remiantis delta metodu asimptotinės dispersijos pagrindinė dalis $B_1^2/n = [H_1^2 V m_2 + 2H_1 H_2 \text{Cov}(m_2, m_3) + H_2^2 V m_3]/n$. Irašę dispersijų ir

kovariacijos išraiškas (**I.1.90**, **I.1.91** pratimai) ir sutraukę panašiuosius narius, gausime pratime pateiktą išraišką.

c) Statistika $g_2 = H(m_2, m_4) = m_4/m_2^2 - 3$. Tegu $H_1 = H'_{m_2}(\mu_2, \mu_4) = -2\mu_4/\sigma^6$, $H_2 = H'_{m_3}(\mu_2, \mu_4) = 1/(\sigma^4)$. Tada remiantis delta metodu asimptotinės dispersijos pagrindinė dalis $B_r^2/n = [H_1^2 \mathbf{V} m_2 + 2H_1 H_2 \mathbf{Cov}(m_2, m_4) + H_2^2 \mathbf{V} m_4]$. Irašę dispersijų ir kovariacijos išraiškas (**I.1.90**, **I.1.91** pratimai) ir sutraukę panašiuosius narius, gausime pratime pateiktą išraišką.

I.1.96. Kaip ir ankstesniuose pratimuose nemažinant bendrumo galima tarti, kad $\mathbf{E}X_i = \mathbf{E}Y_i = 0$. a) Randame

$$\mathbf{E}m_{11} = \mathbf{E}(a_{11} - a_{10}a_{01}) = \mathbf{E}\left[\frac{1}{n} \sum_{i=1}^n X_i Y_i - \frac{1}{n^2} \left(\sum_{i=1}^n X_i Y_i + \sum_{i \neq j} X_i Y_j\right)\right] = \frac{n-1}{n} \mu_{11};$$

$$\mathbf{V}m_{11} = \mathbf{E}(a_{11}^2 - 2a_{11}a_{10}a_{01} + a_{10}^2 a_{01}^2) - ((n-1)\mu_{11}/n)^2,$$

$$\mathbf{E}a_{11}^2 = \frac{1}{n^2} \mathbf{E}\left(\sum_{i=1}^n X_i Y_i\right)^2 = \frac{1}{n^2} \mathbf{E}\left(\sum_{i=1}^n X_i^2 Y_i^2 + \sum_{i \neq j} X_i Y_i X_j Y_j\right) = \frac{\mu_{22} + (n-1)\mu_{11}^2}{n},$$

$$\mathbf{E}(a_{11}a_{10}a_{01}) = \frac{1}{n^3} \mathbf{E}\left[\sum_{i=1}^n X_i Y_i \left(\sum_{j=1}^n X_j Y_j + \sum_{l \neq j} X_l Y_l\right)\right] = \frac{\mu_{22} + (n-1)\mu_{11}^2}{n^2}.$$

Nesunku įsitikinti, kad $\mathbf{E}(a_{10}^2 a_{01}^2) = O(1/n^2)$. Sutraukę panašiuosius narius, gauname

$$\mathbf{V}(m_{11}) = \frac{\mu_{22} - \mu_{11}^2}{n} + O\left(\frac{1}{n^2}\right).$$

b) Analogiškai gauname

$$\mathbf{Cov}(m_{20}, m_{11}) = \frac{\mu_{31} - \mu_{11}\mu_{20}}{n} + O\left(\frac{1}{n^2}\right), \quad \mathbf{Cov}(m_{20}, m_{11}) = \frac{\mu_{22} - \mu_{02}\mu_{20}}{n} + O\left(\frac{1}{n^2}\right).$$

I.1.97. Statistika $r = H(m_{11}, m_{20}, m_{02}) = m_{11}/\sqrt{m_{20}m_{02}}$. Tegu $H_1 = H'_{m_{11}}(\mu_{11}, \mu_{20}, \mu_{02}) = \rho/\mu_{11}$, $H_2 = H'_{m_{20}}(\mu_{11}, \mu_{20}, \mu_{02}) = -\rho/\mu_{20}$, $H_3 = H'_{m_{02}}(\mu_{11}, \mu_{20}, \mu_{02}) = -\rho/\mu_{02}$. Tada remiantis delta metodu asimptotinės dispersijos pagrindinė dalis

$$\begin{aligned} B_r^2/n = & [H_1^2 \mathbf{V} m_{11} + H_2^2 \mathbf{V} m_{20} + H_3^2 \mathbf{V} m_{02} + 2H_1 H_2 \mathbf{Cov}(m_{11}, m_{20}) + \\ & + 2H_1 H_3 \mathbf{Cov}(m_{11}, m_{02}) + 2H_2 H_3 \mathbf{Cov}(m_{20}, m_{02})]. \end{aligned}$$

Irašę dispersijų ir kovariacijos išraiškas ir sutraukę panašiuosius narius, gausime pratime pateiktą išraišką.

Normaliojo skirstinio atveju tardami, kad dispersijos vienetinės, naudodamai charakterinę funkciją gausime $\mu_{04} = \mu_{40} = 3$, $\mu_{31} = \mu_{13} = 3\rho$, $\mu_{11} = \rho$, $\mu_{22} = 1 + 2\rho^2$. Tada asimptotinės dispersijos pagrindinė dalis $B_r^2/n = (1 - \rho^2)^2/n$.

I.1.98. Remiantis **I.1.97** pratimu $\sqrt{n}(r - \rho) \xrightarrow{d} Y \sim N(0, (1 - \rho^2)^2)$. Naudojama Fišerio dispersiją stabilizuojanti transformacija $g(r) = (1/2) \ln((1+r)/(1-r))$. Kadangi $(g'(\rho))^2 = 1/(1 - \rho^2)^2$, o dispersijos $\mathbf{V}r$ pagrindinė dalis $(1 - \rho^2)^2/n$, tai asimptotinio skirstinio dispersija nepriklauso nuo parametru ρ :

$$\sqrt{n}\left(\frac{1}{2} \ln \frac{1+r}{1-r} - \frac{1}{2} \ln \frac{1+\rho}{1-\rho}\right) \xrightarrow{d} Z \sim N(0, 1).$$

I.2. Parametru įvertiniai

I.2.1. Įvertiniai ir jų klasifikacija

I.2.1. Kokio didumo turi būti a. d. $X \sim N(\mu, 4)$ imtis, kad paramетro μ įvertinio $\hat{\mu} = \bar{X}$ absoliuočioji paklaida būtų ne didesnė už 0,1 su tikimybe, ne mažesne kaip 0,99?

I.2.2. Kokio didumo turi būti normaliojo a. d. imtis, kad dispersijos σ^2 įvertinio $\hat{\sigma}^2 = s^2$ santykinės paklaidos modulis būtų ne didesnis už 0,1 su tikimybe, ne mažesne kaip 0,99?

I.2.3. Kokio didumo turi būti a. d. $X \sim G(1/\lambda, 5)$ imtis, kad parametro λ įvertinio $\hat{\lambda} = \bar{X}/5$ santykinės paklaidos modulis būtų ne didesnis už 0,1 su tikimybe, ne mažesne kaip 0,99?

I.2.4. Jūros gylis matuojamas prietaisu, kurio sisteminė paklaida 0, o atsitiktinė paklaida pasiskirčiusi pagal normalujį dėsnį su vidutiniu kvadratiniu nuokrypiu $\sigma = 25$ m. Kiek kartų reikia nepriklausomai matuoti jūros gylį, kad matavimo paklaida būtų ne didesnė kaip 15 m su tikimybe, ne mažesne už 0,99?

I.2.5. Parametro θ įvertinio $\hat{\theta}_n = T_n = T_n(X_1, \dots, X_n)$ poslinkis yra

$$\mathbf{E}T_n - \theta = \sum_{i=1}^{\infty} \frac{a_i}{n^i} = O\left(\frac{1}{n}\right), \quad n \rightarrow \infty.$$

Įrodykite, kad statistikos $T'_n = nT_n - (n-1)\bar{T}_{n-1}$ poslinkis yra $O(1/n^2)$; statistikos $T''_n = [n^2T'_n - (n-1)\bar{T}'_{n-1}]/[n^2 - (n-1)^2]$ poslinkis yra $O(1/n^3)$ ir t. t. Čia \bar{T}_{n-1} yra aritmetinis vidurkis statistikų T_{n-1} , apskaičiuotų pagal visus didumo $n-1$ imties poaibius.

I.2.6. $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso Veibulo skirstinių šeimai $\mathcal{P} = \{f(x|\rho), 0 < \rho < \infty\}$; čia tankio funkcija yra

$$f(x|\rho) = \alpha\rho^\alpha x^{\alpha-1}e^{-(\rho x)^\alpha}, \quad 0 < x < \infty,$$

o $\alpha > 1$ – žinoma konstanta. Įrodykite, kad funkcijos $\gamma(\rho) = \rho^r$ nepaslinktasis įvertinys, kai $n > r/\alpha$, yra

$$\hat{\gamma} = \left(\sum_{i=1}^n X_i^\alpha \right)^{-r/\alpha} \frac{(n-1)!}{\Gamma(n-r/\alpha)}.$$

I.2.7. Tegu $\bar{\theta} = \bar{\theta}(\mathbf{X})$ yra nepaslinktasis θ įvertinys. Įrodykite, kad bet kuris nepaslinktasis θ įvertinys $\tilde{\theta}$ yra tokio pavidalas:

$$\tilde{\theta} = \bar{\theta} - U(\mathbf{X});$$

čia $U(\mathbf{X})$ tenkina sąlygą $\mathbf{E}_\theta(U(\mathbf{X})) \equiv 0$.

I.2.8. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim U(0, \theta)$, $0 < \theta < \infty$. Raskite θ įvertinio $cX_{(n)}$ poslinkį ir dispersiją; čia c – žinoma teigiamai konstanta. Raskite c tokį, kad $cX_{(n)}$ būtų nepaslinktasis θ įvertinys.

I.2.9. Tarkime, $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \{\theta_1, \dots, \theta_k\}\}$ su fiksuoju natūraliuoju skaičiumi

k. Tegu $T_n(X)$ yra θ įvertinys, įgyjantis reikšmes iš aibės $\{\theta_1, \dots, \theta_k\}$. Irodykite, kad $T_n(X)$ yra pagrįstasis tada ir tik tada, kai $\mathbf{P}_\theta\{T_n(X) = \theta\} \rightarrow 1$, $n \rightarrow \infty$.

I.2.10. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim U(\theta - 1/2, \theta + 1/2)$, $\theta \in \mathbf{R}$ yra nežinomas. Irodykite, kad $\bar{\theta} = (X_{(1)} + X_{(n)})/2$ yra n^α , $\alpha < 1$, pagrįstas θ įvertinys, t. y. $n^\alpha(\bar{\theta} - \theta) \xrightarrow{P} 0$, kai $n \rightarrow \infty$.

I.2.11. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji a. d. $X \sim B(1, p)$ imtis. Tarkime, statistika T įgyja reikšmę 0, jei ne mažiau kaip pusė visų X_i yra 0; įgyja reikšmę 1, jeigu daugiau negu pusė visų X_i yra 1; įgyja reikšmę 1/2, jeigu lygiai pusė visų X_i yra 0. Irodykite, kad statistika T nėra pagrįstasis tikimybės p įvertinys.

I.2.12. Tegu g_1, g_2, \dots yra tokios tolydžiosios, apibrėžtos intervale $(a, b) \subset \mathbf{R}$, funkcijos, kad $g_n(x) \rightarrow g(x)$ tolygiai pagal x bet kuriamoje intervale, priklausančiamje (a, b) . Tegu T_n yra pagrįstasis $\theta \in (a, b)$ įvertinys. Irodykite, kad $g_n(T_n)$ yra pagrįstasis parametras $\vartheta = g(\theta)$ įvertinys.

I.2.13. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio vidurkis $\mu \in \mathbf{R}$ ir dispersija $\sigma^2 > 0$ nežinomi. Be to, $g(\mu) = 0$, kai $\mu \neq 0$, ir $g(0) = 1$. Nurodykite pagrįstajį $\vartheta = g(\mu)$ įvertinį.

I.2.14. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < \infty$, $\sigma > 0$. Irodykite, kad aritmetinis vidurkis \bar{X} ir empirinė mediana $\hat{x}(0, 5)$ yra vidurkio μ pagrįstieji įvertiniai.

I.2.15. Tarkime, $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim K(\mu, \sigma)$, $-\infty < \mu < \infty$, $\sigma > 0$. Irodykite, kad aritmetinis vidurkis \bar{X} nėra pagrįstasis, o empirinė mediana $\hat{x}(0, 5)$ yra pagrįstasis parametras μ įvertinys.

I.2.16. Tegu X ir Y yra nepaslinktieji atitinkamai parametru θ ir θ^2 įvertiniai. Raskite a. d. X dispersijos $\mathbf{V}_\theta X$ nepaslinktajį įvertinį.

I.2.17. Tegu X ir Y yra nepriklausomi atsitiktiniai dydžiai, vienodai pasiskirstę pagal $N(\mu, \sigma^2)$. Ar $|X - Y|$ ir $|X - Y|^2$ yra nepaslinktieji parametrai σ ir σ^2 įvertiniai? Raskite šiu įvertinių poslinkius.

I.2.18. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim U(-\theta, \theta)$, $0 < \theta < \infty$. Iš kokios konstantos reikia padauginti statistiką $T = X_{(n)} - X_{(1)}$, kad gautume nepaslinktajį parametras θ įvertinį? Kokia gautojo įvertinio dispersija?

I.2.2. Pakankamosios statistikos. NMD įvertiniai

I.2.19. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim \mathcal{E}(\lambda, \mu)$, $0 < \lambda < \infty$, $-\infty < \mu < \infty$. Irodykite, kad $\mathbf{T} = (X_{(1)}, X_{(2)} + \dots + X_{(n)})^T$ yra pakankamoji parametras $(\lambda, \mu)^T$ statistika.

I.2.20. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim W(\eta, \sigma)$, $0 < \eta < \infty$, $0 < \sigma < \infty$, turinčio Veibulo skirstinį. Irodykite, kad: a) kai η nežinomas, egzistuoja tik triviali pakankamoji statistika; b) kai η žinomas, $T = \sum_i X_i^\eta$ yra parametras σ pakankamoji statistika.

I.2.21. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = \{f(x; \lambda, \eta, \mu), 0 < \lambda, \eta < \infty, -\infty < \mu < \infty\}$; čia tankio funkcija

$$f(x; \lambda, \eta, \mu) = \frac{\lambda^\eta}{\Gamma(\eta)} x^{\eta-1} e^{-\lambda(x-\mu)}, \quad x \geq \mu.$$

Raskite pakankamają statistiką: a) parametru η , kai μ ir λ žinomi; b) parametru λ , kai μ ir η žinomi; c) parametrų η ir λ , kai μ žinomas; d) parametru μ , kai λ žinomas, o $\eta = 1$.

I.2.22. Tegu Y_1, \dots, Y_n yra n. a. d. ir $Y_i \sim N(\alpha + \beta x_i, \sigma^2)$; čia x_1, \dots, x_n – žinomos konstantos, $-\infty < \alpha, \beta < \infty$, $0 < \sigma < \infty$ – nežinomi parametrai. Įrodykite, kad $\mathbf{T} = (\sum_i Y_i, \sum_i Y_i x_i, \sum_i Y_i^2)^T$ yra pilnoji ir pakankamoji parametru $\boldsymbol{\theta} = (\alpha, \beta, \sigma)^T$ statistika.

I.2.23. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d., kurio skirstinys priklauso šeimai $\mathcal{P} = \{P_{\boldsymbol{\theta}}, \boldsymbol{\theta} \in \Theta\}$. Raskite parametru $\boldsymbol{\theta}$ pakankamają statistiką, kai $P_{\boldsymbol{\theta}}$ yra:

- a) Puasono skirstinys $\mathcal{P}(\lambda)$, $\lambda \in (0, \infty)$;
- b) neigiamas binominis skirstinys $B^-(n, p)$ su žinomu n , $p \in (0, 1)$;
- c) eksponentinis skirstinys $\mathcal{E}(\theta)$, $\theta \in (0, \infty)$;
- d) gama skirstinys $G(\lambda, \eta)$, $\boldsymbol{\theta}^T = (\lambda, \eta) \in (0, \infty) \times (0, \infty)$;
- e) beta skirstinys $Be(\gamma, \eta)$, $\boldsymbol{\theta}^T = (\gamma, \eta) \in (0, \infty) \times (0, \infty)$;
- f) lognormalusis skirstinys $LN(\mu, \sigma)$, $\boldsymbol{\theta}^T = (\mu, \sigma) \in \mathcal{R} \times (0, \infty)$.

I.2.24. Atsitiktinio dydžio X skirstinys priklauso šeimai $\mathcal{P} = \{f(x; \theta), 0 < \theta < \infty\}$; čia tankis $f(x; \theta) = 2(\theta - x)/\theta^2$, kai $0 < x < \theta$, ir lygus 0, kai x įgyja kitas reikšmes. Raskite šeimos \mathcal{P} netrivialią pakankamają statistiką pagal a. d. X didumo n paprastąjį imti.

I.2.25. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio tankio funkcija

$$f(x; \theta) = \theta(1+x)^{-(\theta+1)}, \quad x \geq 0;$$

čia $\theta > 0$ nežinomas parametras.

- a) Įrodykite, kad $T = \sum_{i=1}^n \ln(1+X_i)$ yra pakankamoji θ statistika.
- b) Raskite T vidurkį ir dispersiją.

I.2.26. Įrodykite: jei T yra pakankamoji statistika ir $T = h(S)$, čia h yra mačioji funkcija, S – kita statistika, tai S taip pat yra pakankamoji statistika.

I.2.27. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio skirstinys yra Pareto ir tankis

$$f(x|a, \theta) = \theta a^\theta / x^{\theta+1}, \quad 0 < a, \theta < \infty, \quad a < x < \infty.$$

Raskite parametru $(a, \theta)^T$ pakankamają statistiką.

I.2.28. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio skirstinys priklauso visų absoliučiai tolydžiųjų skirstinių šeimai \mathcal{P} . Įrodykite, kad variacinė eilutė $(X_{(1)}, \dots, X_{(n)})^T$ yra šeimos \mathcal{P} pakankamoji statistika.

I.2.29. Įrodykite, kad $\mathcal{P} = \{P_{\boldsymbol{\theta}} : \boldsymbol{\theta} \in \Theta\}$ yra eksponentinė šeima. Užrašykite jos kanoninį pavidał ir natūraliąją parametrų erdvę, kai $P_{\boldsymbol{\theta}}$ yra:

- a) Puasono skirstinys $\mathcal{P}(\lambda)$, $\lambda \in \Theta = (0, \infty)$;
- b) neigiamas binominis skirstinys $B^-(n, p)$ su fiksuotu n ir $p \in \Theta = (0, 1)$;
- c) eksponentinis skirstinys $E(a, \theta)$ su fiksuotu a ir $\theta \in \Theta = (0, \infty)$;
- d) gama skirstinys $G(\lambda, \eta)$, $\boldsymbol{\theta}^T = (\lambda, \eta) \in \Theta = (0, \infty) \times (0, \infty)$;
- e) beta skirstinys $Be(\gamma, \eta)$, $\boldsymbol{\theta}^T = (\gamma, \eta) \in \Theta = (0, 1) \times (0, 1)$;
- f) Veibulo skirstinys $W(\alpha, \theta)$ su fiksuotu $\alpha > 0$ ir $\theta \in \Theta = (0, \infty)$.

I.2.30. Įrodykite, kad eksponentinių skirstinių šeima $\mathcal{E}(a, \theta)$ su dviem nežinomais parametrais a ir θ nėra eksponentinė šeima.

I.2.31. Įrodykite, kad neigiamų binominių skirstinių šeima $B^-(n, p)$ su dviem nežinomais parametrais p ir n nėra eksponentinė šeima.

I.2.32. Įrodykite, kad Koši skirstinių šeima $K(\mu, \sigma)$ su dviem nežinomais parametrais μ ir σ nėra eksponentinė šeima.

I.2.33. Įrodykite, kad Veibulo skirstinių šeima $W(\alpha, \theta)$ su dviem nežinomais parametrais α ir θ nėra eksponentinė šeima.

I.2.34. Įrodykite, kad k -mačių normaliuju skirstinių šeima $N_k(\boldsymbol{\mu}, \Sigma)$ yra eksponentinė šeima. Užrašykite jos kanoninį pavidalą.

I.2.35. Raskite gama skirstinio $G(\lambda, \eta)$ momentų generuojančią funkciją.

I.2.36. Diskrečiojo a. d. X skirstinys nusakomas tikimybėmis

$$\mathbf{P}\{X = k\} = \gamma(k) \frac{\theta^k}{c(\theta)}, \quad k = 0, 1, 2, \dots.$$

Įrodykite, kad šie skirstiniai, kai $\theta > 0$, sudaro eksponentinę šeimą, ir raskite X momentų generuojančią funkciją.

I.2.37. Tegu X yra a. d., kurio skirstinys priklauso šeimai $\mathcal{P} = \{P_{\boldsymbol{\theta}} : \boldsymbol{\theta} \in \Theta\}$ ir $f_{\boldsymbol{\theta}}$ yra $P_{\boldsymbol{\theta}}$ tankio funkcija σ -baigtinio mato ν atžvilgiu, o A yra įvykis, kurio $\mathbf{P}_{\boldsymbol{\theta}}\{A\} > 0$. Nagrinėjama nupjautinių skirstinių šeima, $\mathcal{P}_A = \{f_{\boldsymbol{\theta}} I_{\{A\}} / P_{\boldsymbol{\theta}}\{A\}, \boldsymbol{\theta} \in \Theta\}$. Įrodykite, kad:

- a) jeigu $T(X)$ yra pakankamoji šeimos \mathcal{P} statistika, tai ji pakankamoji ir šeimos \mathcal{P}_A statistika;
- b) jeigu $T(X)$ yra pilnoji ir pakankamoji šeimos \mathcal{P} statistika, tai ji pilnoji ir pakankamoji ir šeimos \mathcal{P}_A statistika.

I.2.38. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio tankis

$$f(x|\theta) = c(\theta) \exp\{-\theta x\}, \quad 0 < x < a, \quad \theta > 0,$$

konstanta a žinoma. Raskite parametru θ pilnają ir pakankamają statistiką.

I.2.39. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim U(\theta, \theta + 1)$, $0 < \theta < \infty$. Įrodykite, kad pakankamoji statistika $(X_{(1)}, X_{(n)})^T$ nėra pilnoji.

I.2.40. Tegu $\psi(x)$, $x \in \mathbf{R}$, yra tokia teigiamą Borelio funkcija, kad bet kuriems a ir b , $-\infty < a < b < \infty$, $\int_a^b \psi(x) dx < \infty$. Tegu $\boldsymbol{\theta} = (a, b)^T$. Apibréžkime tankio funkciją

$$f(x|a, b) = \frac{\psi(x)}{\int_a^b \psi(u) du}, \quad a < x < b.$$

Įrodykite, kad $(X_{(1)}, X_{(n)})^T$ yra šeimos $\mathcal{P} = \{f(x|\boldsymbol{\theta}), \boldsymbol{\theta} \in \Theta\}$ pilnoji ir pakankamoji statistika.

I.2.41. Tegu X yra diskretusis a. d., kurio skirstinys nusakytas tikimybėmis

$$\mathbf{P}\{X = k|\theta\} = \begin{cases} \theta, & k = 0, \\ (1 - \theta)^2 \theta^{k-1}, & k = 1, 2, \dots, \end{cases}$$

čia $\theta \in (0, 1)$. Irodykite, kad X nėra pilnoji, tačiau yra aprėžtai pilnoji.

I.2.42. Tegu $(X_1, \dots, X_n)^T$ yra paprastojo imtis, gauta stebint Bernulio a.d. $X \sim B(1, p)$. Irodykite, kad $S_n = X_1 + \dots + X_n$ yra pakankamoji statistika a) remdamiesi pakankamosios statistikos apibrėžimu; b) naudodami Neimano ir Fišerio faktorizacijos kriterijų.

I.2.43. (**I.2.42** pratimo tēsinys). Irodykite, kad $S_n = X_1 + \dots + X_n$ yra pilnoji statistika a) remdamiesi apibrėžimu; b) remdamiesi tuo, kad Bernulio skirstinys priklauso eksponentinio tipo skirstinių šeimai.

I.2.44. (**I.2.42** pratimo tēsinys). Raskite parametru $\gamma = \gamma(p) = p^i(1-p)^j$, $0 \leq i, j \leq n$, $1 \leq i+j \leq n$, dviem būdais a) vidurkindamai nepaslinktajį įvertinį pakankamosios statistikos atžvilgiu; b) spręsdami funkcinę lygtį $\mathbf{E}_p h(S_n) \equiv \gamma(p)$ funkcijos h atžvilgiu.

I.2.45. (**I.2.42** pratimo tēsinys). Irodykite, kad a) polinomo $t_k(p) = \sum_{i=1}^k a_i p^i$ NMD įvertinys yra $\hat{t}_k(p) = \sum_{i=1}^k a_i S_n^{[i]} / n^{[i]}$; b) parametru p^k , kai $k > n$, NMD įvertinys neegzistuoja.

I.2.46. (**I.2.42** pratimo tēsinys). Atlikus $n = 50$ Bernulio eksperimentą, kai įvykio A tikimybė yra p , įvykis A įvyko 12 kartų. Raskite parametrų $q + p^3, pq, p^{12}q^{38}, q^{50}, p^{49}$ NMD įvertinių realizacijas (jverčius).

I.2.47. Tegu $(X_1, \dots, X_n)^T$ yra paprastojo imtis, gauta stebint Puasono a.d. $X \sim \mathcal{P}(\lambda)$. Irodykite, kad $S_n = X_1 + \dots + X_n$ yra pakankamoji statistika a) remdamiesi pakankamosios statistikos apibrėžimu; b) naudodami Neimano ir Fišerio faktorizacijos kriterijų.

I.2.48. (**I.2.47** pratimo tēsinys). Irodykite, kad $S_n = X_1 + \dots + X_n$ yra pilnoji statistika a) remdamiesi apibrėžimu; b) remdamiesi tuo, kad Puasono skirstinys priklauso eksponentinio tipo skirstinių šeimai.

I.2.49. (**I.2.47** pratimo tēsinys). a) Raskite parametru $\gamma = \gamma(\lambda) = \lambda^k$ NMD įvertinį; b) Irodykite, kad parametru $1/\lambda$ NMD įvertinys neegzistuoja.

I.2.50. (**I.2.47** pratimo tēsinys). a) Raskite tikimybės $\pi_m(\lambda) = \lambda^m e^{-\lambda} / m!$ NMD įvertinį; b) Raskite generuojančios funkcijos $g(s) = e^{\lambda(s-1)}$ NMD įvertinį.

I.2.51. Tegu $(X_1, \dots, X_n)^T$ yra paprastojo imtis, gauta stebint a.d. $X \sim B^-(1, p)$. Irodykite, kad $S_n = X_1 + \dots + X_n$ yra pilnoji ir pakankamoji statistika.

I.2.52. (**I.2.51** pratimo tēsinys). Raskite imties sąlyginį skirstinį, kai pakankamoji statistika $S_n = t$ yra fiksuota.

I.2.53. (**I.2.51** pratimo tēsinys). Raskite parametru $\gamma = \gamma(p) = p^m q^l$, $l = 0, 1, \dots, 1 \leq m \leq n$, NMD įvertinį.

I.2.54. (**I.2.51** pratimo tēsinys). Raskite parametrų $q/p, p, p^2, pq$ NMD įvertinius.

I.2.55. (**I.2.51** pratimo tēsinys). Atliekant Bernulio eksperimentus įvykis A pirmą kartą įvyko per 14 bandymą. Raskite parametru $p \ln p$ NMD įvertinio realizaciją; čia p yra įvykio A pasiodynimo tikimybė per atskirą bandymą.

I.2.56. Tegu a.v. $\mathbf{X} = (X_1, \dots, X_n)^T$ turi k -matį polinominį skirstinį $\mathcal{P}_k(n; (p_1, \dots, p_k))$, $0 < p_i < 1$, $p_1 + \dots + p_k = 1$. a) Irodykite, kad a.v. $(X_1, \dots, X_{k-1})^T$ yra parametru $\boldsymbol{\theta} = (p_1, \dots, p_{k-1})^T$ pilnoji ir pakankamoji statistika. b) Raskite parametrų p_i^m ir $p_i^k p_j^l$ NMD įvertinius.

I.2.57. Tegu $(X_1, \dots, X_n)^T$ yra paprastoji imtis, gauta stebint a. d.

$$X \sim U(0, \theta), \quad \theta > 0.$$

Įrodykite, kad $X_{(n)}$ yra pilnoji ir pakankamoji parametru θ statistika.

I.2.58. (I.2.57 pratimo tēsinys). Raskite parametru θ NMD ivertinį.

I.2.59. Tegu $(X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim U(\theta, \theta + 1), \theta > 0$. Įrodykite, kad vienmatė pakankamoji statistika neegzistuoja. Dvimatė statistika $\mathbf{T} = (X_{(1)}, X_{(n)})^T$ yra pakankamoji, tačiau nėra pilnoji.

I.2.60. Tegu $(X_1, \dots, X_n)^T$ yra paprastoji imtis, gauta stebint a. d.

$$X \sim U(\theta_1, \theta_2), \quad \theta_1 < \theta_2.$$

Įrodykite, kad a) $(X_{(1)}, X_{(n)})^T$ yra pilnoji ir pakankamoji parametru $(\theta_1, \theta_2)^T$ statistika; b) parametrų $\gamma_1 = (\theta_1 + \theta_2)/2$ ir $\gamma_2 = \theta_2 - \theta_1$ NMD ivertiniai yra $\hat{\gamma}_1 = (X_{(1)} + X_{(n)})/2$, $\hat{\gamma}_2 = (n+1)(X_{(n)} - X_{(1)})/(n-1)$, o jų dispersijos $\mathbf{V}_{\theta_1, \theta_2} \hat{\gamma}_1 = \gamma_2^2/(2(n+1)(n+2))$, $\mathbf{V}_{\theta_1, \theta_2} \hat{\gamma}_2 = 2\gamma_2^2/((n-1)(n+2))$.

I.2.61. Tegu $(X_1, \dots, X_n)^T$ yra paprastoji imtis, gauta stebint a. d.

$$X \sim U(-\theta, \theta), \quad \theta > 0.$$

Įrodykite, kad a) $T = \max(-X_{(1)}, X_{(n)})$ yra pilnoji ir pakankamoji parametru θ statistika; b) parametru θ NMD ivertinys yra $\hat{\theta} = (n+1)T/n$.

I.2.62. Paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d.

$$X \sim N(\mu, \sigma^2), \quad -\infty < \mu < \infty, \quad \sigma > 0.$$

Įrodykite, kad a) $\mathbf{T} = (\bar{X}, s^2)^T$, $\bar{X} = \sum_{i=1}^n X_i/n$, $s^2 = \sum_{i=1}^n (X_i - \bar{X})^2/(n-1)$, yra pilnoji ir pakankamoji parametru $(\mu, \sigma^2)^T$ statistika; b) \bar{X} ir s^2 yra parametrų μ ir σ^2 NMD ivertiniai.

I.2.63. (I.2.62 pratimo tēsinys). Įrodykite, kad parametru σ NMD ivertinys yra

$$\hat{\sigma} = s/M_{n-1}, \quad M_\nu = \sqrt{2/\nu} \Gamma((\nu+1)/2)/\Gamma(\nu/2).$$

I.2.64. (I.2.62 pratimo tēsinys). Įrodykite, kad a) jeigu parametras μ žinomas, tai parametru σ^2 pilnoji ir pakankamoji statistika yra $s_0^2 = \sum_{i=1}^n (X_i - \mu)^2/n$, o parametrų σ^2 ir σ NMD ivertiniai yra s_0^2 ir s_0/M_n ; b) jeigu parametras σ žinomas, parametru μ pilnoji ir pakankamoji statistika yra \bar{X} , kuri yra parametru μ NMD ivertinys.

I.2.65. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d.

$$X \sim \mathcal{E}(\mu, \lambda), \quad -\infty < \mu < \infty, \quad \lambda > 0.$$

Įrodykite, kad a) $(X_{(1)}, \sum_{i=1}^n X_i)^T$ yra pilnoji ir pakankamoji parametru $(\mu, \lambda)^T$ statistika; b) $n\lambda(X_{(1)} - \mu) \sim \mathcal{E}(1)$, $\lambda T_2(\mathbf{X}) = \lambda[\sum_{i=1}^n X_i - nX_{(1)}] \sim G(1, n-1)$, o $X_{(1)}$ ir $T_2(\mathbf{X})$ nepriklausomi; c) parametrų $\gamma_1 = \mu^l$ ir $\gamma_2 = 1/\lambda^m$ NMD ivertiniai yra $\hat{\gamma}_1 = X_{(1)}^l - lT_2(\mathbf{X})X_{(1)}^{l-1}/(n(n-1))$ ir $\hat{\gamma}_2 = T_2^m(\mathbf{X})\Gamma(n-1)/\Gamma(n+m-1)$.

I.2.66. (I.2.65 pratimo tēsinys). Įrodykite, kad a) jei parametras μ žinomas, tai parametru $1/\lambda$ NMD ivertinys yra $\bar{X} - \mu$; b) jeigu λ žinomas, tai parametru μ NMD ivertinys yra $\hat{\mu} = X_{(1)} - 1/(n\lambda)$.

I.2.67. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim G(\lambda, \eta)$, $\lambda, \eta > 0$. Raskite parametru $(\lambda, \eta)^T$ pilnają ir pakankamają statistiką. Irodykite, kad \bar{X} yra parametru $\gamma = \eta/\lambda$ NMD įvertinys.

I.2.68. (I.2.67 pratimo tešinys). Irodykite, kad jei parametras η žinomas, tai parametru λ pilnoji ir pakankamoji statistika yra $T = \sum_{i=1}^n X_i$. Parametru $\gamma = \lambda^k$ NMD įvertinys yra $\hat{\gamma} = \Gamma(n\eta)/[\Gamma(n\eta - k)T^k]$, $n\eta > k$.

I.2.69. (I.2.67 pratimo tešinys). Irodykite, kad jei parametras λ žinomas, tai parametru $\gamma = \Gamma'(\eta)/\Gamma(\eta)$ NMD įvertinys yra $\ln \lambda + (\sum_i \ln X_i)/n$.

I.2.70. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. X , kurio tankio funkcija $f((x - \theta_1)/\theta_2)/\theta_2$ priklauso nuo poslinkio ir mastelio parametrų $-\infty < \theta_1 < \infty, \theta_2 > 0$. Tarkime, egzistuoja pilnoji ir pakankamoji parametru $\boldsymbol{\theta} = (\theta_1, \theta_2)^T$ statistika $\mathbf{T}(\mathbf{X}) = (T_1(\mathbf{X}), T_2(\mathbf{X}))^T$ ir tokie įvertiniai $\hat{\theta}_1, \hat{\theta}_2$, kad statistikos $U(\mathbf{X}) = (X_1 - \hat{\theta}_1)/\hat{\theta}_2$ skirstinys nepriklauso nuo parametru $\boldsymbol{\theta}$. Irodykite, kad jei egzistuoja funkcija $h(z)$, kad $\mathbf{E}_{\boldsymbol{\theta}}(h(X_1)) = \tau(\boldsymbol{\theta}) < \infty$ su visais $\boldsymbol{\theta}$, tai parametru $\tau(\boldsymbol{\theta})$ NMD įvertinys yra

$$\hat{\tau}(\mathbf{T}(\mathbf{X})) = \int_{-\infty}^{\infty} h(u\hat{\theta}_2 + \hat{\theta}_1)g(u)du,$$

čia $g(u)$ yra statistikos $U(\mathbf{X})$ tankis. Jeigu vienas iš parametrų θ_1 arba θ_2 yra žinomas, tai $U(\mathbf{X})$ ir $\hat{\tau}(\mathbf{T})$ išraiškose reikia atitinkamą įvertinį pakeisti žinomu parametru.

I.2.71. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim N(\mu, 1)$, $-\infty < \mu < \infty$. Raskite parametru $\gamma_1 = \Phi(y - \mu)$ ir $\gamma_2 = \varphi(y - \mu)$ NMD įvertinius.

I.2.72. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim N(0, \sigma^2)$, $\sigma > 0$. Raskite parametru $\gamma_1 = \Phi(y/\sigma)$ ir $\gamma_2 = \varphi(y/\sigma)/\sigma$ NMD įvertinius.

I.2.73. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim N(\mu, \sigma^2)$, su abiem nežinomais parametrais $-\infty < \mu < \infty, \sigma > 0$. Irodykite, kad parametru $\gamma = \Phi((y - \mu)/\sigma)$ NMD įvertinys yra

$$\hat{\gamma} = \int_{-\sqrt{1-1/n}}^{(y-\bar{X})/S} g(u)du, \text{ kai } |y - \bar{X}|/S \leq \sqrt{1-1/n},$$

čia $\bar{X} = \sum_i X_i/n$, $S^2 = \sum_i (X_i - \bar{X})^2$,

$$g(u) = \frac{\Gamma((n-1)/2)}{\sqrt{\pi}\Gamma((n-2)/2)} \sqrt{\frac{n}{n-1}} \left(1 - \frac{nu^2}{n-1}\right)^{(n-4)/2}, \quad |u| \leq \sqrt{1-1/n}.$$

I.2.74. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim \mathcal{E}(\theta, 1)$, $-\infty < \theta < \infty$. Irodykite, kad parametru $\gamma = \mathbf{P}_{\lambda}\{X > y\} = e^{-(y-\theta)}$ NMD įvertinys yra

$$\hat{\gamma} = \frac{n-1}{n} e^{-(y-X_{(1)})}, \quad y > X_{(1)}.$$

I.2.75. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim \mathcal{E}(a, \lambda)$, $\lambda > 0$, parametras a žinomas. Raskite parametru $\gamma = P\{X > y\}$ NMD įvertinį.

I.2.76. Tegu paprastoji imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. X , kuris turi Pareto skirstinį su tankio funkcija

$$f(x|\alpha, \sigma) = \sigma\alpha^\sigma/y^{\sigma+1}, \quad y > \alpha, \quad \sigma > 0.$$

Įrodykite, kad parametras $\gamma = \alpha^m$, $m < n\sigma$, NMD jvertinys, kai σ žinomas, yra

$$\hat{\gamma} = [\ln X_{(1)}]^m \left(1 - \frac{m}{n\sigma}\right).$$

I.2.77. Tegu paprastojo imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. X , kurio tankio funkcija

$$f(x|\theta) = e^{-(x-\theta)} \exp\{-e^{-(x-\theta)}\}, \quad -\infty < x, \theta < \infty.$$

Raskite parametras $\gamma = f(z|\theta)$ NMD jvertinį.

I.2.78. Didumo N gaminų partijoje defektinių gaminų skaičius M nežinomas. Atsitiktinai negrąžinant atrenkama n gaminų. Tegu $X_i = 1$, jei i -asis atrinktas gaminys defektinis, ir $X_i = 0$ priešingu atveju. Tarsime, kad $0 < n < N$ yra žinomi, o M nežinomas parametras, įgyjantis reikšmes $0, 1, \dots, N$. Įrodykite, kad $T = \sum_{i=1}^n X_i$ yra parametras M pilnoji ir pakankamoji statistika.

I.2.79. Turima didumo $n = 1$ imtis diskrečiojo a. d. X , kurio skirstinys, priklausantis nuo nežinomo parametru θ , $0 < \theta < 1$, nusakytas tikimybėmis

$$\mathbf{P}\{X = -1\} = \theta, \quad \mathbf{P}\{X = k\} = (1 - \theta)^2 \theta^k, \quad k = 0, 1, 2, \dots$$

Įrodykite, kad

- a) X yra pakankamoji parametru θ statistika, tačiau nėra pilnoji;
- b) $T(X) = \mathbf{1}_{\{0\}}(X)$ yra parametras $\gamma = (1 - \theta)^2$ NMD jvertinys;
- c) $\hat{\theta} = \mathbf{1}_{\{-1\}}(X) + cX$, kai c bet kokia konstanta yra nepaslinktasis parametras θ jvertinys, o NMD jvertinys neegzistuoja.

I.2.80. A. d. X turi nupjautą Puasono skirstinį: $\mathbf{P}\{X = k\} = e^{-\lambda} \lambda^k / (k!(1 - e^{-\lambda}))$, $k = 1, 2, \dots$. Įrodykite, kad parametras $\gamma = 1 - e^{-\lambda}$ NMD jvertinys $\hat{\gamma}$ yra toks: $\hat{\gamma} = 0$, kai X nelyginis, ir $\hat{\gamma} = 2$, kai X lyginis.

I.2.81. Tarkime, paprastosios imtys $\mathbf{X} = (X_1, \dots, X_n)^T$, $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ gautos stebint n. a. d. $X_i \sim N(\mu_1, \sigma_1^2)$, $Y_i \sim N(\mu_2, \sigma_2^2)$. Įrodykite, kad a) $\mathbf{T}(\mathbf{X}, \mathbf{Y}) = (\sum_i X_i, \sum_i Y_i, \sum_i X_i^2, \sum_i Y_i^2)^T$ yra pilnoji ir pakankamoji parametras $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1, \sigma_2)^T$ statistika; b) jeigu žinoma, kad $\mu_1 = \mu_2 = \mu$, tai $\mathbf{T}(\mathbf{X}, \mathbf{Y})$ yra pakankamoji parametras $(\mu, \sigma_1, \sigma_2)^T$ statistika, tačiau ji nėra pilna; c) jeigu žinoma, kad $\sigma_1 = \sigma_2 = \sigma$, tai $\mathbf{T}(\mathbf{X}, \mathbf{Y})$ yra pakankamoji parametras $(\mu_1, \mu_2, \sigma)^T$ statistika, tačiau ji nėra pilna; statistika $\mathbf{T}^*(\mathbf{X}, \mathbf{Y}) = (\sum_i X_i, \sum_i Y_i, \sum_i X_i^2 + \sum_i Y_i^2)^T$ yra pilnoji ir pakankamoji parametras $(\mu_1, \mu_2, \sigma)^T$ statistika.

I.2.82. Tegu paprastojo imtis $(X_i, Y_i)^T$, $i = 1, 2, \dots, n$, gauta stebint a. v. $(X, Y)^T \sim N_2(\boldsymbol{\mu}, \Sigma)$, $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, $\Sigma = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = \sigma_1^2$, $\sigma_{22} = \sigma_2^2$, $\sigma_{12} = \rho \sigma_1 \sigma_2$. Įrodykite, kad $\mathbf{T} = (\sum_i X_i, \sum_i Y_i, \sum_i X_i^2, \sum_i Y_i^2, \sum_i X_i Y_i)^T$ yra pilnoji ir pakankamoji parametras $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1, \sigma_2, \rho)^T$ statistika.

I.2.83. Tarkime, paprastosios imtys $\mathbf{X} = (X_1, \dots, X_n)^T$, $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ gautos stebint n. a. d. $X_i \sim N(\mu_1, 1)$, $Y_i \sim N(\mu_2, 1)$. Raskite parametras $\gamma = \mathbf{P}_{\mu_1, \mu_2}\{Y_1 < X_1\}$ NMD jvertinį.

I.2.84. Tarkime, paprastosios imtys $\mathbf{X} = (X_1, \dots, X_n)^T$, $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ gautos stebint n. a. d. $X_i \sim G(\lambda_1, 1)$, $Y_i \sim G(\lambda_2, 1)$. Raskite parametras $\gamma = \mathbf{P}_{\lambda_1, \lambda_2}\{Y_1 < X_1\}$ NMD jvertinį.

I.2.85. Paprastojo imtis $(X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim U(0, \theta), \theta > 0$. Tarkime, funkcija $\gamma(\theta)$ turi tolydžią išvestinę ir $\mathbf{E}(\gamma'(X_{(n)})) < \infty$. Raskite parametru $\gamma = \gamma(\theta)$ NMD įvertinį.

I.2.86. Tegu Y_1, \dots, Y_n yra n. a. d. ir $Y_i \sim N(\alpha + \beta x_i, \sigma^2)$; čia x_1, \dots, x_n – žinomos konstantos, $-\infty < \alpha, \beta < \infty, \sigma > 0$ – nežinomi parametrai. Irodykite, kad $T = (\sum_i Y_i, \sum_i Y_i x_i, \sum_i Y_i^2)$ yra pilnoji ir pakankamoji parametru $\boldsymbol{\theta} = (\alpha, \beta, \sigma^2)^T$ statistika.

I.2.87. Tarkime, n kartų atliekami kampų matavimai ir k -ojo matavimo metu kampo didumas yra $k\varphi$, $k = 1, 2, \dots, n$. Sisteminių matavimų paklaidos lygios 0, o atsitiktinių paklaidos sumuojamos, t. y. k -ojo matavimo atsitiktinė paklaida yra $Z_1 + \dots + Z_k$; čia Z_1, \dots, Z_n yra vienodai pasiskirstę nepriklausomi atsitiktiniai dydžiai ir $Z_i \sim N(0, \sigma^2)$. Raskite parametru φ ir σ^2 NMD įvertinius.

I.2.88. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = \{p(i|\theta), \theta > 0\}$; čia $p(i|\theta) = \mathbf{P}\{X = i|\theta\} = a_i \theta^i / f(\theta)$, $i = c, c+1, \dots$. Irodykite: a) $T = X_1 + \dots + X_n$ yra pilnoji ir pakankamoji šeimos \mathcal{P} statistika, o jos skirstinys yra nusakomas tokio pavidalo tikimybėmis $\mathbf{P}\{T = k|\theta\} = b_k \theta^k / (f(\theta))^n$, $k = nc, nc+1, \dots$; b) parametru θ^r NMD įvertinys yra $U_r(T) = (b_{T-r})/b_T$, kai $T \geq nc+r$, ir $U_r(T) = 0$, kai $T < nc+r$; c) įvertinio $U_r(T)$ dispersijos NMD įvertinys yra $(U_r(T))^2 - U_{2r}(T)$.

Taip pasiskirstę daugelis diskrečiųjų a. d., kurių galimų reikšmių skaičius yra begalinis (Puasono, geometrinis ir pan., išskaitant ir nupjautinius iš kairės).

I.2.89. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo atsitiktinė imtis a. d. $X \sim N(\mu, \sigma^2)$, $0 < \mu < \infty$, $0 < \sigma < \infty$. Vertinamas parametras $\vartheta = \mu^2$. Apskaičiuokite ϑ įvertinio \bar{X}^2 poslinkį ir dispersiją. Raskite ϑ NMD įvertinį ir palyginkite jo dispersiją su įvertinio \bar{X}^2 dispersija.

I.2.90. Tegu $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra paprastosios atsitiktinės imtys, gautos stebint n. a. d. $X \sim N(\mu_x, \sigma_x^2)$ ir $Y \sim N(\mu_y, \sigma_y^2)$.

- a) Raskite parametrų $\mu_x - \mu_y$ ir $(\sigma_x/\sigma_y)^r$, $r > 0$ NMD įvertinius, kai $\mu_x \in \mathbf{R}$, $\mu_y \in \mathbf{R}$, $\sigma_x > 0$ ir $\sigma_y > 0$.
- b) Raskite σ_x^2 ir $(\mu_x - \mu_y)/\sigma_x$ NMD įvertinius, kai $\mu_x \in \mathbf{R}$, $\mu_y \in \mathbf{R}$, $\sigma_x = \sigma_y > 0$.
- c) Raskite μ_x NMD įvertinį, kai $\mu_x = \mu_y \in \mathbf{R}$, $\sigma_x > 0$, $\sigma_y > 0$ ir $\sigma_x^2/\sigma_y^2 = \gamma$ yra žinomas.
- d) Irodykite, kad μ_x NMD įvertinys neegzistuoja, kai $\mu_x = \mu_y \in \mathbf{R}$, $\sigma_x > 0$, $\sigma_y > 0$.
- e) Raskite $\mathbf{P}\{X_1 \leq Y_1\}$ NMD įvertinį, kai $\mu_x = \mu_y \in \mathbf{R}$, $\sigma_x > 0$, $\sigma_y > 0$.
- f) Atlikite e) punkto užduotį, kai $\sigma_x = \sigma_y$.

I.2.91. Tegu $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra paprastosios atsitiktinės imtys, gautos stebint n. a. d. $X \sim \mathcal{E}(a_x, \theta_x)$ ir $Y \sim \mathcal{E}(a_y, \theta_y)$; čia $\theta_x, \theta_y > 0$ ir $a_x, a_y \in \mathbf{R}$.

- a) Raskite $a_x - a_y$ ir θ_x/θ_y NMD įvertinius.
- b) Raskite θ_x ir $(a_x - a_y)/\theta_x$ NMD įvertinius, kai $\theta_x = \theta_y$.
- c) Irodykite, kad a_x NMD įvertinys neegzistuoja, kai $a_x = a_y$.

I.2.3. Rao ir Kramerio nelygybė. Efektyvieji įvertiniai

I.2.92. Tarkime, imties \mathbf{X} skirstinys priklauso nuo parametru $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)^T$, $k > 1$, ir Fišerio informacinių matrica $\mathbf{I} = [I_{ij}]_{k \times k}$ neišsigimus. Pažymėkime $\mathbf{I}^{-1} = [I^{ij}]_{k \times k}$

matricos \mathbf{I} atvirkštinę matricą. Įrodykite, kad teisinga nelygybė $I^{ii} \geq 1/I_{ii}$.

I.2.93. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. X , kurio skirstinys priklauso binominių skirstinių šeimai $\mathcal{P} = \{B(1, p), 0 < p < 1\}$. Raskite funkcijų p , pq , p^2 nepaslinktujų jvertinių dispersijų ribas remdamiesi Rao ir Kramerio nelygybe.

I.2.94. (I.2.93 pratimo tēsinys). Raskite tišlesnę funkcijų p^2, pq nepaslinktujų jvertinių dispersijų ribas remdamiesi patikslinta Rao ir Kramerio nelygybe.

I.2.95. (I.2.93 pratimo tēsinys). Apskaičiuokite funkcijų p , pq , p^2 NMD jvertinių dispersijas ir palyginkite jas su gautomis I.2.93 ir I.2.94 pratimuose ribomis.

I.2.96. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. X , kurio skirstinys priklauso Puasono skirstinių šeimai $\mathcal{P} = \{\mathcal{P}(\lambda), 0 < \lambda < \infty\}$. Raskite funkcijų λ , λ^2 , $e^{-\lambda}$ nepaslinktujų jvertinių dispersijų ribas pagal Rao ir Kramerio nelygybę.

I.2.97. (I.2.96 pratimo tēsinys). Raskite tišlesnes funkcijų $\lambda^2, e^{-\lambda}$ nepaslinktujų jvertinių dispersijų ribas remdamiesi patikslinta Rao ir Kramerio nelygybe.

I.2.98. (I.2.96 pratimo tēsinys). Apskaičiuokite funkcijų λ , λ^2 , $e^{-\lambda}$ NMD jvertinių dispersijas ir palyginkite jas su gautomis I.2.96 ir I.2.97 pratimuose ribomis.

I.2.99. (I.2.96 pratimo tēsinys). Įrodykite, kad parametras $\gamma = e^{-\lambda}$ jvertiniai $\tilde{\gamma} = e^{-\bar{X}}$ ir $\hat{\gamma} = (1 - 1/n)^{n\bar{X}}$ yra a) asimptotiškai efektyvūs; b) asimptotiškai efektyvūs pagal Rao.

I.2.100. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < \infty$, $0 < \sigma < \infty$. Tarkime, parametras σ žinomas. a) Raskite parametrų μ ir μ^2 NMD jvertinius ir jų dispersijas. b) Raskite parametrų μ ir μ^2 nepaslinktujų jvertinių dispersijų ribas Rao ir Kramerio nelygybėje. c) Raskite parametruo μ^2 nepaslinktojo jvertinio dispersijos ribą patikslinus Rao ir Kramerio nelygybę.

I.2.101. (I.2.100 pratimo tēsinys). Tarkime, kad parametras μ žinomas. a) Raskite parametrų σ^2 ir σ NMD jvertinius ir jų dispersijas. b) Raskite parametrų σ^2 ir σ nepaslinktujų jvertinių dispersijų ribas Rao ir Kramerio nelygybėje.

I.2.102. (I.2.100 pratimo tēsinys). Užrašykite Rao ir Kramerio nelygybę vektorinės funkcijos $\theta = (\mu, \sigma^2)^T$ nepaslinktojo jvertinio kovariacijų matricai.

I.2.103. (I.2.100 pratimo tēsinys). a) Raskite P -osios kritinės reikšmės $x_P = \sigma z_P + \mu$ NMD jvertinį ir jo dispersiją. b) Raskite parametruo x_P nepaslinktojo jvertinio dispersijos ribą Rao ir Kramerio nelygybėje.

I.2.104. Atsitiktinio dydžio X skirstinys priklauso ekstremaliųjų skirstinių šeimai. Tankio funkcija

$$f(x|\theta) = \exp\{-(x - \theta) - \exp\{-(x - \theta)\}\}, \quad -\infty < \theta < \infty.$$

Pagal didumo n paprastają imtį raskite parametruo θ ir parametruo $\alpha = \exp\{-\theta\}$ Fišerio informacijos kiekį.

I.2.105. Tarkime, kad X_1, \dots, X_n n. a. d. Tegu X_i tankio funkcija

$$f_i(x; \beta) = \frac{1}{\beta t_i} \exp(-x/(\beta t_i)), \quad x \geq 0;$$

čia t_1, \dots, t_n – žinomos konstantos.

a) Įrodykite, kad

$$\hat{\beta} = \frac{1}{n} \sum_{i=1}^n X_i / t_i$$

yra nepaslinktasis β įvertinys.

b) Apskaičiuokite nepaslinktojo β įvertinio dispersijos ribą Rao ir Kramerio nelygybėje. Ar įvertinio, nurodyto a) punkte, dispersija pasiekia šią ribą?

I.2.106. Tegu X skirstinys priklauso šeimai $\mathcal{P} = \{P_{\theta}, \theta \in \Theta\}$. Raskite Fišerio informaciją $I(\theta)$ pagal didumo n paprastąją imtį, kai P_{θ} yra:

- a) $N(\mu, \sigma^2)$ skirstinys, $\theta = \mu \in \mathbb{R}$; σ žinomas;
- b) $N(\mu, \sigma^2)$ skirstinys, $\theta = \sigma^2 > 0$; μ žinomas;
- c) $N(\mu, \sigma^2)$ skirstinys, $\theta = \sigma > 0$; μ žinomas;
- d) $N(\sigma, \sigma^2)$ skirstinys, $\theta = \sigma > 0$;
- e) $N(\mu, \sigma^2)$ skirstinys, $\theta = (\mu, \sigma^2)^T$;
- f) neigiamas binominis skirstinys $B^-(k, p)$, $\theta = p \in (0, 1)$; k žinomas;
- g) gama skirstinys $G(\alpha, \gamma)$, $\theta^T = (\alpha, \gamma) \in (0, \infty) \times (0, \infty)$;
- h) beta skirstinys $B(\alpha, \beta)$, $\theta^T = (\alpha, \beta) \in (0, \infty) \times (0, \infty)$.

I.2.107. (**I.2.106** pratimo tēsinys). Raskite θ funkciją, kurios informacijos kiekis nepriklauso nuo θ , kai P_{θ} yra:

- a) Puasono skirstinys $P(\theta)$, $\theta > 0$;
- b) binominis skirstinys $B(n, p)$, $\theta = p \in (0, 1)$; n žinomas;
- c) gama skirstinys $G(\theta, \gamma)$, $\theta > 0$; γ žinomas.

I.2.108. (**I.2.106** pratimo tēsinys). Raskite Fišerio informacijos matricą, kai P_{θ} yra:

- a) Koši skirstinys $K(\mu, \sigma)$, $\mu \in \mathbb{R}$, $\sigma > 0$;
- b) ekstremalių reikšmių skirstinys, kurio parametrai $\mu \in \mathbb{R}$, $\theta > 0$;
- c) logistinis skirstinys $LG(\mu, \sigma)$, kurio parametrai $\mu \in \mathbb{R}$, $\sigma > 0$;
- d) $F_r(\frac{x-\mu}{\sigma})$, čia F_r yra Stjudento skirstinio su žinomu laisvės laipsnių skaičiumi r pasiskirstymo funkcija, $\mu \in \mathbb{R}$, $\sigma > 0$.

I.2.109. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim U(0, \theta)$ su $\theta > 0$.

a) Įrodykite, kad Rao ir Kramerio teoremos sąlygos netenkinamos.

b) Įrodykite, kad paramетro θ NMD įvertinio dispersija yra eilės $O(1/n^2)$, $n \rightarrow \infty$ (reikia pažymėti, kad reguliariu atveju, kai Rao ir Kramerio nelygybė galioja, dispersijos riba Rao ir Kramerio nelygybėje yra eilės $O(1/n)$).

I.2.110. Tegu X yra a. d., turintis ekstremalių reikšmių skirstinį su parametrais $\mu = 0$ ir $\theta > 0$. Raskite nurodytų parametrų NMD įvertinius ir kiekvienu atveju nustatykite, ar NMD įvertinio dispersija pasiekia Rao ir Kramerio nelygybėje nurodytą ribą: a) $\vartheta = \theta$;
b) $\vartheta = \theta^r$, čia $r > 1$ žinomas.

I.2.111. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < \infty$, σ – žinomas.

a) Raskite $\vartheta = e^{t\mu}$ NMD įvertinį, kai $t \neq 0$ fiksotas.

b) Nustatykite, ar a) punkte rasto įvertinio dispersija pasiekia Rao ir Kramerio nelygybėje nurodytą ribą.

c) Įrodykite, kad asimptotiškai ($n \rightarrow \infty$) tenkinama Rao ir Kramerio nelygybė.

I.2.112. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim G(1/\lambda, \eta)$, $0 < \lambda, \eta < \infty$. Tarkime, parametras η žinomas. a) Raskite parametrų λ ir λ^2 NMD įvertinius

ir jų dispersijas. b) Raskite parametru λ ir λ^2 nepaslinktujų įvertinių dispersijų ribas Rao ir Kramerio nelygybėje. c) Raskite parametru λ^2 nepaslinktujų įvertinių dispersijos ribą patikslinus Rao ir Kramerio nelygybę.

I.2.113. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim G(\lambda, \eta)$, $0 < \lambda, \eta < \infty$. Tarkime, parametras η žinomas. a) Raskite parametru λ ir λ^2 NMD įvertinius ir jų dispersijas. b) Raskite parametru λ ir λ^2 nepaslinktujų įvertinių dispersijų ribas Rao ir Kramerio nelygybėje.

I.2.114. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim N(\mu, 1)$, $\mu \in \mathbf{R}$. Tegu $\vartheta = \mathbf{P}\{X_1 \leq c\}$, čia c – fiksuota konstanta. Nagrinėjami tokie ϑ įvertiniai: $T_{1n} = \hat{F}_n(c)$, čia \hat{F}_n yra empirinė pasiskirstymo funkcija, ir $T_{2n} = \Phi(c - \bar{X})$, čia Φ yra standartinio normaliojo skirstinio pasiskirstymo funkcija. Raskite įvertinio T_{1n} ASE T_{2n} atžvilgiu.

I.2.115. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim N(0, \sigma^2)$, čia $\sigma > 0$ nežinomas. Vertinama $\vartheta = \sigma$.

Raskite įvertinio $\hat{\sigma}_1 = \sqrt{\pi/2} \sum_{i=1}^n |X_i|/n$ ASE įvertinio $\hat{\sigma}_2 = (\sum_{i=1}^n X_i^2/n)^{1/2}$ atžvilgiu.

I.2.116. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio $EX = \mu$, $VX = 1$ ir $EX^4 < \infty$. Tegu $T_{1n} = n^{-1} \sum_{i=1}^n X_i^2 - 1$ ir $T_{2n} = \bar{X}^2 - n^{-1}$ yra $\vartheta = \mu^2$ įvertiniai.

- a) Raskite įvertinio T_{1n} ASE atžvilgiu įvertinio T_{2n} .
- b) Irodykite, kad ASE ≤ 1 , jeigu $X_i - \mu$ pasiskirstymo funkcija yra simetrinė 0 atžvilgiu.
- c) Raskite skirstinį, kurio ASE > 1 .

I.2.117. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim B(1, p)$, $0 < p < 1$. Vertinamas parametras p . Tegu a ir b yra teigiamos konstantos. Raskite įvertinio $(a + n\bar{X})/(a + b + n)$ ASE įvertinio \bar{X} atžvilgiu.

I.2.118. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim U(0, \theta)$, $0 < \theta < \infty$. Nagrinėjami tokie θ įverčiai: $T_{1n} = (n+1)X_{(n)}/n$ ir $T_{2n} = X_{(n)}$. Raskite poslinkius $b_{T_{jn}}(\theta)$, $j = 1, 2$ ir įvertinio T_{1n} ASE įvertinio T_{2n} atžvilgiu.

I.2.119. Tegu paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim N(0, \sigma^2)$. Dispersijos įvertiniu imkime $n\bar{X}^2$ ir s^2 . Koks įvertinio $n\bar{X}^2$ efektyvumas įvertinio s^2 atžvilgiu.

I.2.120. Paprastoji imtis X_1, \dots, X_n gauta stebint a. d. X , kurio tankio funkcija

$$f(x|\mu) = \frac{\lambda}{2} e^{-\lambda|x-\mu|}, \quad -\infty < x, \mu < \infty,$$

parametras $\lambda > 0$ žinomas. Raskite parametru μ įvertinio $\hat{\mu}_2 = \bar{X}$ ASE empirinės medianos $\hat{\mu}_1 = \hat{x}_{1/2}$ atžvilgiu.

I.2.121. Vertinant atsitiktinio dydžio $X \sim N(\mu, \sigma^2)$ parametrą μ , gautos trys paprastosios atsitiktinės nepriklausomos imtys, iš kurių gauti įverčiai: $\bar{X}_1 = 17, 24$ (didumo $n_1 = 5$ imtis); $\bar{X}_2 = 16, 81$ (didumo $n_2 = 10$ imtis); $\bar{X}_3 = 17, 22$ (didumo $n_3 = 100$ imtis). Raskite parametru μ NMD įvertinio realizacijos reikšmę naudodamiesi visais matavimais.

I.2.4. Įvertinių radimo metodai

I.2.122. Momentų metodu raskite parametru α ir β įvertinius pagal didumo n paprastąjį atsitiktinę imtį a. d. X , kurio skirstinys yra $N(0, 1)$ su tikimybe β ir $N(\alpha, 1)$ su tikimybe $1 - \beta$.

I.2.123. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = U(\theta_1, \theta_2), -\infty < \theta_1 < \theta_2 < \infty\}$. a) Raskite parametru $\mu = (\theta_1 + \theta_2)/2$ ir $\sigma = \theta_2 - \theta_1$ NMD įvertinius. b) Palyginkite jų dispersijas su momentų metodo įvertinių dispersijomis. c) Raskite parametru μ ir σ DT įvertinius.

I.2.124. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra a. d. X paprastoji imtis. Raskite parametru DT įvertinius ir palyginkite juos su tų pačių parametru NMD įvertiniais, kai a. d. X skirstinys priklauso a) normaliųjų skirstinių šeimai $\mathcal{P} = \{N(\mu, \sigma^2), -\infty < \mu < \infty, \sigma > 0\}$; b) gama skirstinių šeimai $\mathcal{P} = \{G(\lambda, \eta), 0 < \lambda < \infty\}, \eta > 0$ – žinoma konstanta; c) tolygiųjų skirstinių šeimai $\mathcal{P} = \{U(0, \theta), 0 < \theta < \infty\}$.

I.2.125. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = \{p(x|\theta), 0 < \theta < \infty\}$; čia

$$p(i|\theta) = \mathbf{P}\{X = i|\theta\} = \frac{a_i \theta^i}{f(\theta)}, i = 0, 1, 2, \dots$$

Įrodykite, kad paramетro θ DT įvertinis randamas iš lygties

$$\theta f'(\theta)/f(\theta) = \bar{X},$$

kuri sutampa su lygtimi, gaunama θ įvertinio ieškant momentų metodu.

I.2.126. (I.2.125 pratimo tēsinys). Užrašykite lygtis, iš kurių randami DT parametru įvertiniai, kai skirstinys yra Puasono, binominis $B(1, p)$, logaritminis, taip pat nupjautinis Puasono (praleista reikšmė 0).

I.2.127. (I.2.125 pratimo tēsinys). Palyginkite binominio ir Puasono skirstinių parametru p^2 ir λ^2 DT ir NMD įvertinių kvadratinės rizikos funkcijas.

I.2.128. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso tolygiųjų skirstinių šeimai: a) $\mathcal{P}_1 = \{U(\theta, 2\theta), 0 < \theta < \infty\}$; b) $\mathcal{P}_2 = \{U(\theta - 1/2, \theta + 1/2), -\infty < \theta < \infty\}$. Įrodykite, kad šeimos \mathcal{P}_1 parametru θ DT įvertinis yra $\hat{\theta} = X_{(n)}/2$, o šeimos \mathcal{P}_2 parametru θ DT įvertinis nėra vienareikšmis, – jis gali būti bet kuri statistika, įgyjanti reikšmes iš intervalo $(X_{(n)} - 1/2, X_{(1)} + 1/2)$.

I.2.129. (I.2.128 pratimo tēsinys). Palyginkite DT įvertinių dispersijas su įvertinių, gautų momentų metodu, dispersijomis.

I.2.130. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso Laplaso skirstinių šeimai $\mathcal{P} = \{f(x|\theta), -\infty < \theta < \infty\}$; čia $f(x|\theta) = \exp\{-|x - \theta|/2\}, -\infty < x < \infty$. Įrodykite, kad parametru DT įvertinis yra empirinė mediana $\hat{x}_{0,5}$ ir

$$\sqrt{n}(\hat{x}_{0,5} - \theta) \xrightarrow{d} Z \sim N(0, 1/4), n \rightarrow \infty.$$

I.2.131. Tegu $\mathbf{X} = \{(X_{1i}, \dots, X_{ki})^T, i = 1, \dots, n\}$ yra paprastoji imtis a. v. $(X_1, \dots, X_k)^T$, kurio skirstinys priklauso polinominės skirstinių šeimai $\mathcal{P} = \{\mathcal{P}_k = (1, \boldsymbol{\pi})\}$; čia $\boldsymbol{\pi} = (\pi_1, \dots, \pi_k)^T$ yra k -mačiai vektoriai, kurių $0 < \pi_i < 1, \pi_1 + \pi_2 + \dots + \pi_k = 1$. Raskite parametrų π_1, \dots, π_k DT įvertinius, jų dispersijas ir kovariacijas.

I.2.132. (I.2.131 pratimo tēsinys). Raskite parametru α DT jvertini, kai $k = 3$, $\pi_1 = (1 + \alpha)/2$, $\pi_2 = \pi_3 = (1 - \alpha)/4$, ir jo asimptotinj ($n \rightarrow \infty$) skirstinj.

I.2.133. (I.2.131 pratimo tēsinys). Dviej berniuk, dviej mergaiči ir mišrių dvynuk, kai pirmasis gimē berniukas ir pirmoji gimē mergaitė, tikimybės atitinkamai yra $\pi_1 = p^2$, $\pi_2 = (1 - p)^2 = q^2$, $\pi_3 = \alpha(1 - p^2 - q^2)$ ir $\pi_4 = (1 - \alpha)(1 - p^2 - q^2)$. Raskite parametru p ir α DT jvertinius.

I.2.134. Realizujant $n = 8000$ kartu nepriklausomus eksperimentus, kuriu metu gali jvykti vienas iš trijų nesutaikomų jvykių A , B ir C su tikimybėmis $1/2 - 2\alpha$, $1/2 + \alpha$ ir α , $0 \leq \alpha \leq 1/4$, užregistruoti šiu jvykių dažnai: 2 014, 5 012 ir 974. Raskite parametru α didžiausiojo tikėtinumo jverti.

I.2.135. Tegu $(X_i, Y_i)^T$, $i = 1, \dots, n$, yra imtis a. v. $(X, Y)^T$, kurio skirstinys priklauso dvimačių normaliųjų skirstinių šeimai $\mathcal{P} = N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$; čia $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, $-\infty < \mu_1, \mu_2 < \infty$, $\boldsymbol{\Sigma} = [\sigma_{ij}]$, $\sigma_{11} = \sigma_1^2$, $\sigma_{22} = \sigma_2^2$, $\sigma_{12} = \sigma_{21} = \rho\sigma_1\sigma_2$, $0 < \sigma_1, \sigma_2 < \infty$, $|\rho| < 1$. Raskite parametru DT jvertinius. Apskaičiuokite matricos, atvirkštines informacinei matricai, elementus.

I.2.136. Asimptotiškai ($n \rightarrow \infty$) palyginkite dispersijas ekstremaliųj reikšmių skirstinio parametru jvertinių, gautų pagal didumo n paprastają imtj DT ir momentų metodais.

I.2.137. Asimptotiškai ($n \rightarrow \infty$) palyginkite dispersijas gama skirstinio parametru jvertinių, gautų pagal didumo n paprastają imtj DT ir momentų metodais.

I.2.138. Asimptotiškai ($n \rightarrow \infty$) palyginkite dispersijas neigiamojo binominio skirstinio parametru jvertinių, gautų pagal didumo n paprastają imtj DT ir momentų metodais.

I.2.139. Asimptotiškai ($n \rightarrow \infty$) palyginkite dispersijas Koši skirstinio parametru jvertinių, gautų pagal didumo n paprastają imtj: a) DT metodu, b) grindžiamu statistikomis $\hat{x}_{0,5}$, $\hat{x}_{0,25}$, $\hat{x}_{0,75}$.

I.2.140. Tegu T_n yra pagrjstasis ir asimptotiškai normalusis parametru θ jvertinys, t. y.

$$\sqrt{n}(T_n - \theta) \xrightarrow{d} X \sim N(0, \sigma^2(\theta)), n \rightarrow \infty.$$

Įrodykite, kad jvertinys

$$T'_n = \begin{cases} \alpha T_n, & \text{kai } |T_n| \leq n^{-1/4}, \\ T_n, & \text{kai } T_n > n^{-1/4}, \end{cases}$$

taip pat asimptotiškai ($n \rightarrow \infty$) normalusis ir dispersija lygi $\alpha^2 \sigma^2(\theta)$, kai $\theta = 0$, ir $\sigma^2(\theta)$, kai $\theta \neq 0$. Taigi jvertinio T'_n dispersija gali būti mažesnė už T_n dispersiją, kai $\theta = 0$, ir lygi T_n dispersijai, kai $\theta \neq 0$.

I.2.141. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim N(0, \sigma^2)$, $\sigma > 0$.

- a) Įrodykite, kad $\mathbf{E}(|X_i|) = \sigma \sqrt{2/\pi}$.
- b) Naudodamiesi a) punkte gautu rezultatu, momentų metodu raskite σ jvertinj $\hat{\sigma}_n$. Raskite $\sqrt{n}(\hat{\sigma}_n - \sigma)$ asimptotinj skirstinj.
- c) Kitas momentų metodu, kai naudojamas antrasis momentas, gautas σ jvertinys

yra

$$\tilde{\sigma}_n = \left(\frac{1}{n} \sum_{i=1}^n X_i^2 \right)^{1/2}.$$

Raskite $\sqrt{n}(\tilde{\sigma}_n - \sigma)$ asimptotinė skirstinė ir palyginkite ją su b) punkto rezultatu.

I.2.142. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim \mathcal{E}(\mu, 1)$, $\mu \in \mathbf{R}$.

- a) Įrodykite, kad $X_{(1)} = \min(X_1, \dots, X_n)$ yra pakankamoji μ statistika.
- b) Įrodykite, kad $X_{(1)} \xrightarrow{P} \mu$, kai $n \rightarrow \infty$.

I.2.143. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę a. d., kurių tankio funkcija

$$f(x; \theta_1, \theta_2) = \begin{cases} a(\theta_1, \theta_2)h(x), & \text{kai } \theta_1 \leq x \leq \theta_2, \\ 0, & \text{kitais atvejais;} \end{cases}$$

čia $h(x) > 0$ – žinoma tolydžioji funkcija, apibrėžta realiųjų skaičių tiesėje.

Įrodykite, kad θ_1 ir θ_2 DT įvertiniai yra atitinkamai $X_{(1)}$ ir $X_{(n)}$.

I.2.144. Tegu $(X_1, Y_1)^T, \dots, (X_n, Y_n)^T$ yra nepriklausomos vienodai pasiskirsčiusios normaliųjų a. d. poros; čia $X_i, Y_i \sim N(\mu_i, \sigma^2)$.

- a) Raskite parametrų μ_1, \dots, μ_n ir σ^2 DT įvertinius.
- b) Įrodykite, kad parametras σ^2 DT įvertinys nėra pagrįstasis. Ar šis rezultatas prieštarauja teorijai apie DT įvertinių pagrįstumą? Kodėl?
- c) Stebimi tik Z_1, \dots, Z_n ; čia $Z_i = X_i - Y_i$. Raskite σ^2 DT įvertinį, gautą naudojant Z_1, \dots, Z_n , ir įrodykite, kad jis yra pagrįstasis.

I.2.145. Tegu $X_1, \dots, X_n, Y_1, \dots, Y_n$ yra nepriklausomi a. d., turintys eksponentinius skirstinius. Tegu X_i tankio funkcija

$$f_i(x) = \lambda_i \theta \exp(-\lambda_i \theta x), \quad x \geq 0,$$

o Y_i tankio funkcija

$$g_i(x) = \lambda_i \exp(-\lambda_i x), \quad x \geq 0;$$

čia $\lambda_1, \dots, \lambda_n$ ir θ yra nežinomi parametrai.

- a) Įrodykite, kad parametras θ DT įvertinys tenkina lygtį

$$\frac{n}{\hat{\theta}} - 2 \sum_{i=1}^n \frac{R_i}{1 + \hat{\theta} R_i} = 0;$$

čia $R_i = X_i/Y_i$.

- b) Įrodykite, kad R_i tankio funkcija yra

$$f_R(x; \theta) = \theta(1 + \theta x)^{-2}, \quad x \geq 0,$$

o θ DT įvertinys, gautas naudojant R_1, \dots, R_n , sutampa su pateikiamu a) punkte.

- c) Tegu $\hat{\theta}_n$ yra DT įvertinys, nurodytas b) punkte. Raskite $\sqrt{n}(\hat{\theta}_n - \theta)$ ribinė skirstinė.

d) Lentelėje pateikiama (X_i, Y_i) , $i = 1, \dots, n$ duomenys. Apskaičiuokite θ DT įvertį artutiniu metodu. Parinkite tinkamą pradinį artinį ir pagrįskite pasirinkimą.

x_i	y_i	x_i	y_i	x_i	y_i	x_i	y_i
0,7	3,8	20,2	2,8	1,1	2,8	15,2	8,8
11,3	4,6	0,3	1,9	1,9	3,2	0,2	7,6
2,1	2,1	0,9	1,4	0,5	8,5	0,7	1,3
30,7	5,6	0,7	0,4	0,8	14,5	0,4	2,2
4,6	10,3	2,3	0,9	1,2	14,4	2,3	4,0

e) Pateikite DT išverčio, gauto d) punkte, standartinės paklaidos pagrįstajį ivertį.

I.2.146. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę neneigiami a. d. ir gedimų intensyvumo funkcija

$$\lambda(x) = \begin{cases} \lambda_1, & \text{kai } x \leq x_0, \\ \lambda_2, & \text{kai } x > x_0; \end{cases}$$

čia λ_1 ir λ_2 yra nežinomi parametrai, o x_0 – žinoma konstanta.

X_i tankio funkcija

$$f(x; \lambda_1, \lambda_2) = \begin{cases} \lambda_1 \exp(-\lambda_1 x), & \text{kai } x \leq x_0, \\ \lambda_2 \exp(-\lambda_2(x - x_0) - \lambda_1 x_0), & \text{kai } x > x_0. \end{cases}$$

Raskite parametrų λ_1 ir λ_2 DT ivertinius ir jų ribinį bendrą skirstinį.

I.2.147. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = \{P_{\boldsymbol{\theta}}, \boldsymbol{\theta} \in \Theta\}$. Momentų metodu raskite parametrų ivertinius, kai $P_{\boldsymbol{\theta}}$ yra:

- a) gama skirstinys $G(\alpha, \gamma)$, $\boldsymbol{\theta} = (\alpha, \gamma)^T$, $\alpha > 0$, $\gamma > 0$;
- b) eksponentinis skirstinys $\mathcal{E}(\alpha, \gamma)$, $\boldsymbol{\theta} = (a, \gamma)^T$, $a \in \mathbf{R}$, $\theta > 0$;
- c) beta skirstinys $Be(\alpha, \beta)$, $\boldsymbol{\theta} = (\alpha, \beta)^T$, $\alpha > 0$, $\beta > 0$;
- d) lognormalusis skirstinys $LN(\mu, \sigma)$, $\boldsymbol{\theta} = (\mu, \sigma)^T$, $\mu \in \mathbf{R}$, $\sigma > 0$;
- e) tolygasis skirstinys $U(\theta - \frac{1}{2}, \theta + \frac{1}{2})$, $\theta \in \mathbf{R}$;
- f) neigiamas binominis skirstinys $B^-(n, p)$, $\boldsymbol{\theta} = (p, n)^T$, $p \in (0, 1)$, $n = 1, 2, \dots$;
- g) logaritminis skirstinys, kurio parametras $\theta = p \in (0, 1)$;
- h) chi kvadrato skirstinys $\chi^2(k)$, $\theta = k$, $k = 1, 2, \dots$.

I.2.148. Tegu \mathbf{X} yra imtis iš skirstinio, kurio tankio funkcija yra $f_{\boldsymbol{\theta}}$, o $T(\mathbf{X})$ – pakankamoji $\boldsymbol{\theta}$ statistika. Irodykite: jeigu egzistuoja DT ivertinys, tai jis yra T funkcija.

I.2.149. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę a. d., kurių tankio funkcija yra $f_{\boldsymbol{\theta}}$ σ baigtinio mato ν atžvilgiu. Raskite parametru $\boldsymbol{\theta}$ DT ivertinį tokiais atvejais:

- a) $f_{\theta}(x) = 1/\theta$, kai $x = 1, 2, \dots, \theta$, θ yra sveikasis skaičius tarp 1 ir θ_0 ;
- b) $f_{\theta}(x) = e^{-(x-\theta)}$, $\theta \leq x < \infty$, $\theta > 0$;
- c) $f_{\theta}(x) = \theta(1-x)^{\theta-1}$, $0 < x < 1$, $\theta > 1$;
- d) $f_{\theta}(x) = \frac{\theta}{1-\theta}x^{(2\theta-1)/(1-\theta)}$, $0 < x < \infty$, $\theta \in (\frac{1}{2}, 1)$;
- e) $f_{\theta}(x) = 2^{-1}e^{-|x-\theta|}$, $x \in \mathbf{R}$, $\theta > 0$;
- f) $f_{\theta}(x) = \theta x^{-2}$, $\theta < x < \infty$, $\theta > 0$;
- g) $f_{\theta}(x)$ yra tankio funkcija skirstinio $N(\theta, \theta^2)$, $\theta \in \mathbf{R}$;
- h) $f_{\boldsymbol{\theta}}(x)$ yra tankio funkcija eksponentinio skirstinio $\mathcal{E}(\mu, \sigma)$, $\boldsymbol{\theta}^T = (\mu, \sigma) \in \mathbf{R} \times (0, \infty)$;
- i) $f_{\boldsymbol{\theta}}(x)$ yra tankio funkcija lognormalaus skirstinio $LN(\mu, \sigma)$, $\boldsymbol{\theta}^T = (\mu, \sigma) \in \mathbf{R} \times (0, \infty)$;

- j) $f_\theta(x) = 1$, $x \in (0, 1)$, kai $\theta = 0$, ir $f_\theta(x) = (2\sqrt{x})^{-1}$, $x \in (0, 1)$, kai $\theta = 1$;
k) $f_\theta(x) = \beta^{-\alpha} \alpha x^{\alpha-1}$, $0 < x < \beta$, $\alpha > 0$, $\beta > 0$;
l) $f_\theta(x) = C_\theta^x p^x (1-p)^{\theta-x}$, $x = 0, 1, \dots, \theta$, $\theta = 1, 2, \dots$; čia $p \in (0, 1)$ yra žinomas.

I.2.150. Tegu $(Y_1, Z_1)^T, \dots, (Y_n, Z_n)^T$ yra nepriklausomi vienodai pasiskirstę a. v., kurių tankio funkcija

$$f(y, z | \lambda, \mu) = \lambda^{-1} \mu^{-1} e^{-y/\lambda} e^{-z/\mu}, \quad 0 < y, z < \infty,$$

čia $\lambda > 0$ ir $\mu > 0$.

a) Raskite $(\lambda, \mu)^T$ DT įvertinį.

b) Stebima tik $X_i = \min(Y_i, Z_i)$ ir $\Delta_i = 1$, kai $X_i = Y_i$, ir $\Delta_i = 0$, kai $X_i = Z_i$.

Raskite $(\lambda, \mu)^T$ DT įvertinį.

c) Raskite įvertinių asymptotinius skirstinius.

I.2.151. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę diskretieji a. d., kurių skirstinys nusakytas tikimybėmis

$$\mathbf{P}\{X_1 = x\} = [x!(1 - e^{-\theta})]^{-1} \theta^x e^{-\theta}, \quad x = 1, 2, \dots;$$

čia $\theta > 0$. Irodykite, kad tikėtinumo lygtis turi vienintelę šaknį, kai $\bar{x} > 1$. Ar ši šaknis yra θ DT įvertinys?

I.2.152. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. $X \sim \mathcal{E}(a, \theta)$, parametrai a ir θ nežinomi. Raskite parametrų a ir θ DT įvertinių ASE jų NMD įvertinių atžvilgiu.

I.2.153. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , kurio skirstinys yra Pareto su parametrais a ir θ .

a) Raskite (a, θ) DT įvertinį.

b) Raskite parametru a DT įvertinio ASE NMD įvertinio atžvilgiu.

I.2.154. Tegu $\mathbf{X}_1, \dots, \mathbf{X}_n$ yra nepriklausomi vienodai pasiskirstę k -mačiai a. v., turintys $N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ skirstinį su nežinomais $\boldsymbol{\mu}$ ir $\boldsymbol{\Sigma}$. Raskite $\boldsymbol{\mu}$ ir $\boldsymbol{\Sigma}$ DT įvertinius ir jų asymptotinius skirstinius.

I.2.155. Tegu X_1, \dots, X_n ir Y_1, \dots, Y_n yra nepriklausomi a. d., turintys atitinkamai $N(\mu, \sigma^2)$ ir $N(\mu, \tau^2)$ skirstinius su nežinomu $\boldsymbol{\theta} = (\mu, \sigma^2, \tau^2)^T$. Raskite $\boldsymbol{\theta}$ DT įvertinį ir irodykite, kad jis asymptotiškai efektyvus.

I.2.156. Tegu $X \sim B(n, p)$, $0 < p < 1$, p žinomas. Raskite parametru n DT įvertinį.

I.2.157. Tegu $X \sim H(N, M, n)$. Raskite parametru M DT įvertinį, kai N ir n žinomi.

I.2.5. Intervaliniai įvertiniai

I.2.158. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < \infty$, $\sigma > 0$ žinomas. Raskite parametru μ lygmens Q pasiklivimo intervalą.

I.2.159. (I.2.158 pratimo tēsinys). Tarkime, $\sigma > 0$ nežinomas parametras, o parametras μ žinomas. Raskite parametrų σ^2 ir σ lygmens Q pasiklivimo intervalus.

I.2.160. (I.2.158 pratimo tēsinys). Tarkime, abu parametrai μ ir $\sigma > 0$ nežinomi. Raskite parametrų μ ir σ^2 lygmens Q pasiklivimo intervalus.

I.2.161. (I.2.160 pratimo tēsinys). Raskite parametru σ^2 lygmens Q pasiklovimo intervalą, kurio vidutinis santykinis ilgis $b = \mathbf{E}_\sigma(\bar{\sigma}^2 - \underline{\sigma}^2)/\sigma^2$ būtų mažiausias. Palyginkite jo vidutinį santykinį ilgi su simetriško intervalo vidutiniu santykiniu ilgiu, kai $Q = 0, 95$, ir $n = 10; 20; 50; 100$.

I.2.162. (I.2.160 pratimo tēsinys). Irodykite, kad

$$C(\bar{X}, s^2) = \{(\mu, \sigma^2) : \sigma^2 > \frac{n(\bar{X} - \mu)^2}{\chi_{\alpha_1}^2(1)}, \frac{s^2(n-1)}{\chi_{\alpha_2}^2(n-1)} < \sigma^2 < \frac{s^2(n-1)}{\chi_{1-\alpha_2}^2(n-1)}\}$$

yra parametru $(\mu, \sigma^2)^T$ lygmens $Q = (1 - \alpha_1)(1 - 2\alpha_2)$ pasiklovimo sritis.

I.2.163. Pagal normaliojo a. d. didumo $n = 100$ paprastąją imtį gauti tokie pasiklovimo intervalo rėzai: $\underline{\mu} = 1,25$, $\bar{\mu} = 2,05$. Koks to intervalo pasiklovimo lygmuo, jei $\sigma^2 = 4$?

I.2.164. Kokio didumo turi būti atsitiktinio dydžio $X \sim N(\mu, 1)$ imtis, kad parametru μ pasiklovimo intervalo, kai pasiklovimo lygmuo $Q = 0, 95$, ilgis būtų ne didesnis kaip 0,1?

I.2.165. Pagal didumo $n = 25$ paprastąją imtį, gautą stebint a. d. $X \sim N(\mu, \sigma^2)$, gautos parametrų μ ir σ^2 NMD jvertinių realizacijos $\hat{\mu} = \bar{X} = 6,334$, $\hat{\sigma}^2 = s^2 = 0,012$. Raskite parametrų μ ir σ lygmens $Q = 0, 95$ pasiklovimo intervalų realizacijas.

I.2.166. Tarkime, paprastosios imtys X_1, \dots, X_m ir Y_1, \dots, Y_n gautos stebint n. a. d. $X \sim N(\mu_1, \sigma_1^2)$ ir $Y \sim N(\mu_2, \sigma_2^2)$, $-\infty < \mu_1, \mu_2 < \infty, \sigma_1, \sigma_2 > 0$. a) Raskite parametru $\beta = \sigma_1^2/\sigma_2^2$ lygmens Q pasiklovimo intervalą. b) Tarkime, žinoma, kad $\sigma_1^2/\sigma_2^2 = k$. Raskite parametru $\sigma^2 = \sigma_2^2$ ir parametru $\theta = \mu_1 - \mu_2$ lygmens Q pasiklovimo intervalus.

I.2.167. (I.2.166. pratimo tēsinys). Tarkime, apie dispersijas nieko nežinome, o imtys pakankamai didelės. Raskite asymptotinį parametru $\theta = \mu_1 - \mu_2$ pasiklovimo intervalą.

I.2.168. Tarkime, paprastoji imtis $(X_i, Y_i)^T, i = 1, \dots, n$, gauta stebint a. v.

$$(X, Y)^T \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \quad \boldsymbol{\mu} = (\mu_1, \mu_2)^T, \quad -\infty < \mu_1, \mu_2 < \infty,$$

$$\boldsymbol{\Sigma} = [\sigma_{ij}]_{2 \times 2}, \quad \sigma_{11} = \sigma_1^2, \quad \sigma_{22} = \sigma_2^2, \quad \sigma_{12} = \sigma_1 \sigma_2 \rho.$$

Raskite parametru $\theta = \mu_1 - \mu_2$ lygmens Q pasiklovimo intervalą.

I.2.169. (I.2.168 pratimo tēsinys). Raskite koreliacijos koeficiente ρ lygmens Q pasiklovimo intervalą.

I.2.170. (I.2.168 pratimo tēsinys). Raskite koreliacijos koeficiente ρ aproksimacinį lygmens Q pasiklovimo intervalą.

I.2.171. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d., turinti Relėjaus skirstinį su parametru $\sigma > 0$ (žr. 1 priedo 1.P.2 lentelę). Raskite parametru σ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.172. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d., turinti Maksvelo skirstinį su parametru $\sigma > 0$ (žr. 1 priedo 1.P.2 lentelę). Raskite parametru σ^2 lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.173. Tarkime, imties X_1, \dots, X_n nariai yra n. a. d. ir $X_i \sim G(\lambda, \eta_i), i = 1, \dots, n$, $\lambda > 0$. Parametrai η_1, \dots, η_n žinomi. Raskite parametru λ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.174. Tarkime, paprastoji imtis X_1, \dots, X_n , gauta stebint a. d. turintj ekstremalių reikšmių skirstinj, kurio tankio funkcija

$$f(x|\mu) = e^{x-\mu} \exp\{-e^{x-\mu}\}, \quad -\infty < \mu < \infty.$$

Raskite parametru μ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.175. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim \mathcal{P}(\lambda)$. Raskite parametru λ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.176. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint Bernulio a. d. $X \sim B(1, p), 0 < p < 1$. Raskite parametru p lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.177. Tegu paprastosios imtys X_1, \dots, X_n ir Y_1, \dots, Y_n gautos stebint n. a. d. $X \sim P(\lambda_1)$ ir $Y \sim P(\lambda_2), 0 < \lambda_1, \lambda_2 < \infty$. Raskite parametru $\beta = \lambda_1/\lambda_2$ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.178. Tarkime, imties X_1, \dots, X_n koordinatės yra n. a. d. ir $X_i \sim B^-(m_i, p), i = 1, \dots, n, 0 < p < 1$. Parametrai m_1, \dots, m_n žinomi. Raskite parametru p lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.179. Turime didumo N gaminių partiją, kurioje yra nežinomas skaičius M defektinių. Atsitiktinai negrąžinant atrenkama n gaminių. Tegu $X_i = 1$, jei i -sis atrinktas gaminys defektinis, ir $X_i = 0$ priešingu atveju. Gauname imtį X_1, \dots, X_n , kuri nėra paprastoji. Tegu N ir n žinomi, o $M = 0, 1, \dots, N$ yra nežinomas parametras. Raskite parametru M lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.180. (**I.2.179** pratimo tēsinys). Tarkime, partijos didumas $N = 300$. Patikrinus $n = 50$ gaminių rasti 6 defektiniai. Raskite parametru M taškinj ir intervalinj pasiklovimo lygmens $Q = 0, 9$ įverčius.

I.2.181. Tegu Y_1, \dots, Y_n yra n. a. d. ir $Y_i \sim N(\beta_0 + \beta_1(x_i - \bar{x}), \sigma^2), i = 1, \dots, n$; čia $x_1, \dots, x_n, \bar{x} = \sum_i x_i/n$ – žinomos konstantos, o $-\infty < \beta_0, \beta_1 < \infty, \sigma > 0$ nežinomi parametrai.

a) Raskite parametru σ^2 lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

b) Raskite parametru $\theta = a\beta_0 + b\beta_1$ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.182. (**I.2.181** pratimo tēsinys). Fiksuojuose taškuose $\tau_i, i = 1, \dots, n$, gauti nepriklausomi tiesinės funkcijos $\beta + \beta_1\tau$ matavimai X_1, \dots, X_n . Matavimo paklaidos $\varepsilon_i \sim N(0, \sigma^2)$. Raskite parametru $\gamma = 4\beta_0 + 4\beta_1\bar{\tau}$, kai $\beta_0 = \beta + \beta_1\bar{\tau}$, lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.183. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim U(0, \theta), 0 < \theta$. Raskite parametru θ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.184. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim U(-\theta, \theta), 0 < \theta$. Raskite parametru θ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.185. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim U(\theta - 1/2, \theta + 1/2)$. Raskite parametru θ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą ir raskite jo vidutinj ilgj.

I.2.186. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim U(\theta_1, \theta_1 + \theta_2), -\infty < \theta_1 < \infty, \theta_2 > 0$. Raskite parametru θ_2 lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

I.2.187. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim \mathcal{E}(a, 1/\theta), -\infty < a < \infty, 0 < \theta$. a) Raskite parametru θ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą.

b) Raskite parametru a lygmens $Q = 1 - 2\alpha$ pasiklivimo intervalą, kai parametras θ žinomas ir kai parametras θ nežinomas. c) Raskite parametru $(a, \theta)^T$ pasiklivimo sritį.

I.2.188. Tarkime, paprastojo imtis X_1, \dots, X_n gauta stebint a. d. $X \sim N(\mu, \sigma^2)$, $|\mu| < \infty, \sigma > 0$. Raskite nepriklausomo tolimesnio stebėjimo X_{n+1} lygmens $Q = 1 - 2\alpha$ prognozės intervalą.

I.2.189. Tarkime, paprastojo imtis X_1, \dots, X_n gauta stebint a. d. $X \sim K(\mu, 1)$, $-\infty < \mu < \infty$. a) Raskite parametru μ lygmens $Q = 1 - 2\alpha$ aproksimacijų intervalą, kai parametru μ taškiniu įverčiu imame empirinę medianą $\hat{x}_{1/2}$. b) Raskite parametru μ lygmens $Q = 1 - 2\alpha$ aproksimacijų intervalą, kai parametru μ įvertinys gaunamas DT metodu. Kuris iš šių intervalų trumpešnis?

I.2.190. Tegu X_1, \dots, X_n yra paprastojo imtis a. d. $X \sim \mathcal{P}(\lambda)$. a) Raskite parametru λ lygmens $Q = 1 - 2\alpha$ aproksimacijų pasiklivimo intervalą remdamiesi tuo, kad a. d. $\sqrt{n}(\bar{X} - \lambda)/\sqrt{\lambda}$ skirstinys asimptotiškai nepriklauso nuo nežinomo parametru.

b) Raskite parametru λ lygmens $Q = 1 - 2\alpha$ aproksimacijų pasiklivimo intervalą remdamiesi tuo, kad a. d. $\sqrt{n}(\bar{X} - \lambda)/\sqrt{\lambda}$ skirstinys asimptotiškai nepriklauso nuo nežinomo parametru.

c) Raskite parametru λ lygmens $Q = 1 - 2\alpha$ aproksimacijų pasiklivimo intervalą remdamiesi dispersiją stabilizuojančia transformacija, t. y. tuo, kad a. d. $\sqrt{n}(2\sqrt{\bar{X}} - 2\sqrt{\lambda})$ skirstinys asimptotiškai nepriklauso nuo nežinomo parametru.

d) Tegu pagal didumo $n = 50$ imtį gauta NMD įvertinio realizacija $\hat{\lambda} = 2,4$. Raskite lygmens $Q = 0,95$ p. a), b), c) aproksimacinius intervalus ir palyginkite juos su tiksliu pasiklivimo intervalu iš **I.2.175** pratimo.

I.2.191. Tegu Y_1, \dots, Y_n yra nepriklausomi vienodai pasiskirstę a. d. su baigtiniais $\mu_y = \mathbf{E}Y_1$, $\sigma_y^2 = \mathbf{V}(Y_1)$, $\alpha_3 = \mathbf{E}Y_1^3$ ir $\alpha_4 = \mathbf{E}Y_1^4$. Raskite statistiką, kurios skirstinys asimptotiškai ($n \rightarrow \infty$) nepriklausytų nuo nežinomų parametrų, ir sudarykite parametru $\theta = (\mu_y, \sigma_y^2)^T$ aproksimaciję pasiklivimo sritį.

I.2.192. Tegu X_1, \dots, X_n yra paprastojo imtis, gauta stebint a. d. $X \sim LN(\mu, \sigma)$.

- a) Įrodykite, kad $\theta = \mathbf{E}X = \exp\{\mu + \sigma^2/2\}$, $\gamma = \mathbf{V}X = \exp\{2\mu + \sigma^2\}(\exp\{\sigma^2\} - 1)$.
b) Įrodykite, kad parametru θ ir γ DT įvertinai yra

$$\hat{\theta} = \exp\{\bar{Y} + m_2/2\}, \quad \hat{\gamma} = \exp\{2\bar{Y} + m_2\}(\exp\{m_2\} - 1),$$

čia

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i, \quad m_2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2, \quad Y_i = \ln X_i, \quad i = 1, \dots, n.$$

c) Įrodykite, kad

$$\mathbf{E}_{\mu, \sigma} \hat{\theta} = \theta \exp\{-(n-1)\sigma^2/(2n)\} (n/(n-\sigma^2))^{(n-1)/2} = \theta + O(1/n^2), \quad n \rightarrow \infty;$$

$$\begin{aligned} \mathbf{V}_{\mu, \sigma} \hat{\theta} &= \exp\{2\mu + \sigma^2/n\} [\exp\{\sigma^2/n\} (n/(n-2\sigma^2))^{(n-1)/2} - (n/(n-\sigma^2))^{n-1}] = \\ &\quad \theta^2 \sigma^2/n + O(1/n^2). \end{aligned}$$

I.2.193. (**I.2.192** pratimo tēsinys). Tarkime, pagal didumo $n = 100$ imtį gauti įverčiai $\bar{Y} = 1,45$, $m_2 = 4,21$.

- a) Apskaičiuokite parametru θ ir γ DT įverčius.
b) Raskite parametru θ asimptotinį pasiklivimo intervalą ($Q = 0,95$).

I.2.194. Pasėjus kultūrą Petri lėkštéléje po tam tikro laiko registruojamas bakterijų skaičius $Y = X_1 + X_2 + \dots + X_N$; čia N – kolonijų skaičius, X_i – bakterijų skaičius i -oje kolonijoje. Tarkime, kad X_1, X_2, \dots yra vienodai pasiskirstę n. a. d., turintys Puasono skirstinį su parametru θ , o N yra nepriklausantis nuo X_1, X_2, \dots a. d., turintis Puasono skirstinį su parametru λ . Momentų metodu raskite parametrų λ ir θ įvertinius.

I.2.195. (I.2.194 pratimo tēsinys). Tarkime, pagal didumo $n = 20$ imtį, gautą stebint a. d. Y , apskaičiuoti nepaslinktieji vidurkio $\mu = \mathbf{E}Y$ ir dispersijos $\sigma^2 = \mathbf{V}Y$ įverčiai $\hat{\mu} = \bar{Y} = 50$ ir $\hat{\sigma}^2 = s^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2 / (n-1) = 360$.

a) Apskaičiuokite parametrų θ ir λ momentų metodo įverčius.

b) Raskite vidurkio $\mu = \lambda\theta$ lygmens $Q = 1 - 2\alpha$ asimptotinį pasikliovimo intervalą naudodami aproksimaciją

$$\sqrt{n}(\hat{\mu} - \mu)/s \xrightarrow{d} Z \sim N(0, 1)$$

ir aproksimaciją

$$\sqrt{n}(\hat{\mu} - \mu)/\sqrt{\mu(1 + \hat{\theta})} \xrightarrow{d} Z \sim N(0, 1).$$

I.2.196. Paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim N(\mu, \sigma^2)$. Raskite kritinės reikšmės $x_P = \mu + \sigma z_P$ ir funkcijos $F(x) = \Phi((x - \mu)/\sigma)$ aproksimacinius pasikliovimo intervalus.

I.2.197. (I.2.196 pratimo tēsinys). Tarkime, pagal didumo $n = 100$ paprastąjį imtį, gautą stebint a. d. $X \sim N(\mu, \sigma^2)$, apskaičiuotos empirinės charakteristikos $\bar{X} = 1,28$; $s^2 = 4$; $g_1 = -0,25$; $g_2 = 0,1$. Sudarykite parametrų $x(0,9)$; $F(0)$; γ_1 ; γ_2 lygmens $Q = 0,95$ aproksimacinius pasikliovimo intervalus.

I.2.198. Paprastoji imtis X_1, \dots, X_n gauta stebint a. d. $X \sim W(\theta, \nu)$, turintį Veibulo skirstinį, kurio pasiskirstymo funkcija

$$F(x|\theta, \nu) = 1 - e^{-(x/\theta)^\nu}, \quad x > 0.$$

Raskite eilės P kvantilio $t(P) = \theta(-\ln(1 - P))^{1/\nu}$ aproksimacinių pasikliovimo intervalą.

I.2.199. (I.2.198 pratimo tēsinys). Tarkime, kad gaminio darbo laikas aprašomas Veibulo skirstiniu su parametrais θ ir ν . Pagal paprastąjį imtį, gautą išbandžius 100 gaminį, surastos parametrų DT įvertinių realizacijos $\hat{\theta} = 0,198$, $\hat{\nu} = 2,15$. Raskite parametrų θ, ν ir kvantilio $t(0,9)$ lygmens $Q = 0,95$ aproksimacinius pasikliovimo intervalus.

I.2.6. Įverčių radimo pavyzdžiai

I.2.200. Bandant sportinių lėktuvą, gautos šios jo maksimalaus greičio (m/s) reikšmės: 422,2; 418,7; 425,6; 420,3; 425,8; 423,1; 431,5; 428,2; 438,3; 434,0; 411,3; 417,2; 413,5; 441,3; 423,0. Tarę, kad buvo stebimas normalusis a. d., raskite vidurkio ir vidutinio kvadratinio nuokrypio taškinius ir intervalinius ($Q = 0,95$) įverčius.

I.2.201. Lentelėje pateikti skaičiai m_i tokį vienodo ploto (0,25 kv. km) pietinės Londono dalies rajonų, į kuriuos Antrojo pasaulinio karo metu pataikė po i lėktuvų-sviedinių.

i	0	1	2	3	4	5	Σ
m_i	229	211	93	35	7	1	576

Tare, kad buvo stebimas Puasono a. d., raskite parametru λ taškinj ir intervalinj ($Q = 0,95$) jverčius.

I.2.202. Laikas nuo ušsakymo pateikimo iki jo gavimo (pristatymo laikas) yra pasiskirstęs pagal gama skirstinj $G(\lambda, \eta)$. Lentelėje pateikiamas atsitiktinai parinktų ušsakymų pristatymo laikas (i – eilės numeris, X_i – laikas).

i	X_i	i	X_i	i	X_i	i	X_i
1	10	6	7	11	10	16	7
2	10	7	11	12	6	17	6
3	6	8	12	13	13	18	16
4	11	9	12	14	8	19	9
5	8	10	6	15	12	20	5

a) Raskite parametrus λ ir η taškinius jverčius.

b) Tare, kad parametras η reikšmė lygi 10, DT metodu raskite parametru λ jvertj. Palyginkite jį su NMD jverčiu. Sudarykite parametru λ pasikliovimo intervalą ($Q = 0,95$).

I.2.203. Kiekvienomis iš 100 vienodų staklių gaminami I ir II rūšies gaminiai. Tikrinant produkcijos kokybę, atsitiktinai paimta po 10 gaminij, pagamintų skirtingomis staklėmis, ir nustatytas II rūšies gaminij skaičius. Bandymo rezultatai pateikiami lentelėje (m_i – skaičius imčių, kuriose rasta po i II rūšies gaminij).

i	0	1	2	3	4	5	Σ
m_i	1	10	27	36	25	1	100

Tare, kad buvo stebimas binominis a. d., raskite parametru p NMD jvertj ir pasikliovimo intervalą ($Q = 0,95$).

I.2.204. Bandant kiekvieną iš 10 prietaisų, nebuvo rasta nė vieno defektinio prietaiso. Raskite tikimybės, kad prietaisas yra defektinis, pasikliovimo intervalą, kai pasikliovimo lygmenys yra 0,8; 0,9; 0,99 ir defektinių prietaisų skaičiaus skirstinys yra binominis.

I.2.205. Nustatant 200 elektros lempučių degimo laiką T , gauti stebiniai, kurie pateikiami lentelėje.

i	$a_{i-1} - a_i$	S_i	i	$a_{i-1} - a_i$	S_i
1	0–300	53	7	1800–2100	9
2	300–600	41	8	2100–2400	7
3	600–900	31	9	2400–2700	5
4	900–1200	22	10	2700–3000	3
5	1200–1500	16	11	3000– ∞	2
6	1500–1800	12			

Šioje lentelėje a_{i-1} ir a_i yra i -ojo intervalo galai, o S_i stebinių, patekusiu į i -ajį intervalą, skaičius.

Tare, kad a. d. T skirstinys yra eksponentinis, raskite parametru λ taškinj ir asimptotinj intervalinj jverčius ($Q = 0,99$).

I.2.206. Pagal tris didumo $n_1 = 20, n_2 = 50, n_3 = 30$ imtis, gautas stebint n. a. d.

$X \sim N(\mu_1, \sigma^2)$, $Y \sim N(\mu_2, \sigma^2)$, $Z \sim N(\mu_3, \sigma^2)$, apskaičiuotos NMD įvertinių realizacijos $\hat{\mu}_1 = \bar{X} = 2,12$, $s_x^2 = 2,84$, $\hat{\mu}_2 = \bar{Y} = 1,09$, $s_y^2 = 3,91$, $\hat{\mu}_3 = \bar{Z} = 3,14$, $s_z^2 = 2,53$.

a) Raskite parametru σ^2 NMD įvertijų naudodami visus duomenis; raskite parametru σ lygmens $Q = 0,99$ pasiklovimo intervalą.

b) Raskite parametru $\theta = \mu_1 + \mu_2 - \mu_3$ NMD įvertijų; sudarykite parametru θ lygmens $Q = 0,95$ pasiklovimo intervalą.

I.2.207. Krakmolo kiekis bulvėse nustatomas dviem būdais. Norint palyginti tuos būdus, buvo paimta 16 bulvių ir kiekvienos iš jų krakmolo kiekis nustatytas abiem būdais. Gauti stebiniai (krakmolingumas procentais) surašyti lentelėje (X_i – krakmolingumas tiriant i -ają bulvę pirmu būdu; Y_i – antru būdu).

i	X_i	Y_i	i	X_i	Y_i
1	21,7	21,5	9	14,0	13,9
2	18,7	18,7	10	17,2	17,0
3	18,3	18,3	11	21,7	21,4
4	17,5	17,4	12	18,6	18,6
5	18,5	18,3	13	17,9	18,0
6	15,6	15,4	14	17,7	17,6
7	17,0	16,7	15	18,3	18,5
8	16,6	16,9	16	15,6	15,5

Priėmę normalumo prielaidą, palyginkite šiuos du krakmolingumo nustatymo metodus. a) Raskite parametru $\theta = EX - EY$ lygmens $Q = 0,95$ pasiklovimo intervalą remdamiesi I.2.160 pratimu. b) Raskite parametru θ lygmens $Q = 0,95$ pasiklovimo intervalą remdamiesi I.2.168 pratimu. c) Paaiškinkite, kodėl gaunami tokie skirtingi rezultatai. d) Raskite koreliacijos koeficiente ρ taškinį ir intervalinį ($Q = 0,95$) įverčius.

I.2.208. Per pirmą dieną skaitiklis užregistruavo 20 026 puasoninio srauto impulsus, o per antrą – 19 580. Raskite intensyvumų santykio $\theta = \lambda_1/\lambda_2$ pasiklovimo intervalą ($Q = 0,99$).

I.2.209. Dviejose nepriklausomose Bernulio bandymų schemose atlikus $n_1 = n_2 = 5000$ bandymų įvykis A įvyko $S_1 = 2602$ ir $S_2 = 2398$ kartus. Tegu įvykio A pasirodymo tikimybė pirmoje bandymų schemaje yra p_1 , o antroje – p_2 . Raskite parametru $\theta = p_1 - p_2$ asymptotinį pasiklovimo intervalą ($Q = 0,99$). Ar yra pagrindo teigti, kad įvykio A pasirodymo tikimybės abiejose schemose yra vienodos?

I.2.210. Tarkime, kad daugialypis integralas, kurio tikroji reikšmė yra 0,3, buvo skaičiuojamas Monte Karlo metodu. Kiek apytiksliai reikia atlikti nepriklausomų modeliavimų N , kad gautosios reikšmės absoluti santykinė paklaida su tikimybe, ne mažesne už 0,99, neviršytų a) 0,2; b) 0,1?

I.2.211. Lentelėje pateikti prapuolimo kampai 209 pašto balandžių, kai atliekant bandymą buvo bandoma paveikti jų „vidinį laikrodį“ (žr. [14]).

Duomenys sugrupuoti į 30° ilgio intervalus. Lentelėje nurodyti kampai φ_i , atitinkantys i -ojo intervalo pradžią, ir patekusių į i -ąjį intervalą dažniai n_i , $i = 1, \dots, 12$. Tardami, kad turimus duomenis galima traktuoti kaip paprastosios imties, gautos stebint atsitiktinį kampą $\varphi \sim M(\mu, \theta)$, realizaciją, raskite parametry μ, θ taškinius įverčius ir sudarykite aproksimacinius intervalus su pasiklovimo lygmeniu $Q = 0,95$.

Kryptis	Dažnis	Kryptis	Dažnis
0°–	26	180°–	14
30°–	22	210°–	11
60°–	26	240°–	12
90°–	30	270°–	5
120°–	29	300°–	5
150°–	18	330°–	11

I.2.212. Lentelėje pateikti duomenys apie užregistruotus susirgimo leukemija atvejus Anglijoje per 1946-1960 metų laikotarpį, sugrupuoti mėnesiniai intervalais (žr. [14]).

Mėnuo	Susirgo	Mėnuo	Susirgo	Mėnuo	Susirgo
Sausis	39	Gegužė	38	Rugsėjis	37
Vasaris	37	Birželis	59	Spalis	47
Kovas	29	Liepa	50	Lapkritis	34
Balandis	45	Rugpjūtis	54	Gruodis	37

Paverskite duomenis kampų stebėjimais sutapatindami metų intervalą su intervalu $(0, 2\pi]$, t. y. sausis atitinka sektorijų nuo 0° iki 30° ; vasaris – sektorijų nuo 30° iki 60° ir t. t. Tardami, kad buvo stebimas atsitiktinis kampus $\varphi \sim M(\mu, \theta)$ a) raskite taškinius parametrų (μ, θ) įverčius; b) sudarykite pasiklovimo lygmens $Q = 0, 95$ aproksimacinius pasiklovimo intervalus.

I.2.7. Sprendimai, nurodymai, atsakymai

I.2.1 skyrelis

I.2.1. A. d. $\sqrt{n}(\bar{X} - \mu)/2 \sim N(0, 1)$. Imties didumui n rasti gauname nelygybę

$$\begin{aligned} \mathbf{P}_\mu\{|\bar{X} - \mu| \leq 0, 1\} &= \mathbf{P}_\mu\{-0, 1\sqrt{n}/2 \leq \sqrt{n}(\bar{X} - \mu)/2 \leq 0, 1\sqrt{n}/2\} = \\ &2\Phi(0, 1\sqrt{n}/2) - 1 \geq 0, 99. \end{aligned}$$

Iš šios nelygybės randame

$$\Phi(0, 1\sqrt{n}/2) \geq 0, 995 \Leftrightarrow 0, 1\sqrt{n}/2 \geq z_{0,005} \Leftrightarrow n \geq 2654.$$

I.2.2. A. d. $s^2(n-1)/\sigma^2 \sim \chi^2(n-1)$. Imties didumui n rasti gauname nelygybę

$$\mathbf{P}_\sigma\{|s^2 - \sigma^2|/\sigma^2 \leq 0, 1\} = \mathbf{P}_\sigma\{0, 9(n-1) \leq s^2(n-1)/\sigma^2 \leq 1, 1(n-1)\} \geq 0, 99.$$

Iš šios nelygybės randame

$$\mathbf{P}\{0, 9(n-1) \leq \chi^2_{n-1} \leq 1, 1(n-1)\} \geq 0, 99 \Leftrightarrow n \geq 1330.$$

I.2.3. A. d. $n\bar{X} \sim G(1/\lambda, 5n)$. Remdamiesi gama skirstinio sąryšiu su χ^2 skirstiniu (žr. 1 priedo 1.P.3 lentelę) gauname $2n\bar{X}/\lambda \sim \chi^2(10n)$. Imties didumui n rasti gauname nelygybę

$$\mathbf{P}_\lambda\{|\bar{X}/5 - \lambda|/\lambda \leq 0, 1\} = \mathbf{P}_\lambda\{0, 9 \leq \bar{X}/(5\lambda) \leq 1, 1\} =$$

$$\mathbf{P}_\lambda\{9n \leq 2n\bar{X}/\lambda \leq 11n\} = \mathbf{P}_\lambda\{9n \leq \chi^2_{10n} \leq 11n\} \geq 0, 99.$$

Iš šios nelygybės randame $n \geq 133$.

I.2.4. A.d. $\sqrt{n}(\bar{X} - \mu)/25 \sim N(0, 1)$; čia μ – nežinomas jūros gylis. Matavimų skaičiui n rasti turime nelygybę

$$\mathbf{P}_\mu\{\bar{X} - \mu \leq 15\} = \mathbf{P}_\mu\{\sqrt{n}(\bar{X} - \mu)/25 \leq 3\sqrt{n}/5\} = \Phi(3\sqrt{n}/5) \geq 0, 99.$$

Išsprendę gauname

$$\Phi(3\sqrt{n}/5) \geq 0, 99 \Leftrightarrow 3\sqrt{n}/5 \geq z_{0,01} \Leftrightarrow n \geq 15.$$

I.2.5. Pažymėkime $T_{1n}, T_{2n}, \dots, T_{nn}$ imties narius. Yra n aibės $\{1, 2, \dots, n\}$ poaibių, susidedančių iš $n - 1$ elemento. Taigi yra n statistikų $T_{n-1}^{(1)}, \dots, T_{n-1}^{(n)}$, gautų iš didumo $n - 1$ imčių; $\bar{T}_{n-1} = \frac{1}{n} \sum_{j=1}^n T_{n-1}^{(j)}$. Kadangi

$$\mathbf{E}_\theta T_{n-1}^{(j)} = \theta + \sum_{i=1}^{\infty} a_i / (n-1)^i,$$

tai ir statistika \bar{T}_{n-1} tenkina sąlyga

$$\mathbf{E}_\theta \bar{T}_{n-1} - \theta = \sum_{i=1}^{\infty} a_i / (n-1)^i.$$

Taigi

$$\mathbf{E}_\theta T'_n = n\mathbf{E}_\theta T_n - (n-1)\mathbf{E}_\theta \bar{T}_{n-1} = \theta + \sum_{i=2}^{\infty} a_i (1/n^{i-1} - 1/(n-1)^{i-1}) =$$

$$\theta + a_2 (1/n - 1/(n-1)) + O(1/n^2) = \theta + O(1/n^2).$$

Analogiškai randame T''_n, T'''_n, \dots poslinkius.

I.2.6. Tegu $Y = X^\alpha$. Tada $Y \sim \mathcal{E}(\rho^\alpha)$. Suma $\sum_{i=1}^n X_i^\alpha \sim G(\rho^\alpha, n)$. Randame vidurki

$$\mathbf{E}_\rho \hat{\gamma} = \frac{\rho^{n\alpha}}{\Gamma(n-r/\alpha)} \int_0^\infty y^{n-r/\alpha-1} e^{-\rho^\alpha y} dy = \rho^r.$$

I.2.7. Jeigu $\bar{\theta}$ ir $\tilde{\theta}$ yra nepaslinktieji parametru θ įvertiniai, tai $\mathbf{E}_\theta(\bar{\theta} - \tilde{\theta}) \equiv 0$. Taigi nepaslinktieji įvertiniai gali skirtis tik tokia statistika U , kad $\mathbf{E}_\theta U \equiv 0$.

I.2.8. Statistikos $X_{(n)}$ tankio funkcija yra $f_n(x) = nx^{n-1}/\theta^n, 0 < x < \theta$. Įvertinio $cX_{(n)}$ vidurkis ir dispersija

$$\mathbf{E}_\theta(cX_{(n)}) = \frac{cn}{\theta^n} \int_0^\theta x^n dx = \theta \frac{cn}{n+1}, \quad \mathbf{E}_\theta(cX_{(n)})^2 = \frac{c^2 n}{\theta^n} \int_0^\theta x^{n+1} dx = \theta^2 \frac{c^2 n}{n+2},$$

$$\mathbf{V}_\theta(cX_{(n)}) = c^2 \theta^2 \frac{n}{(n+1)^2(n+2)}.$$

Įvertinys nepaslinktas, kai $c = (n+1)/n$. Tada

$$\mathbf{E}_\theta((n+1)X_{(n)}/n) = \theta, \quad \mathbf{V}_\theta((n+1)X_{(n)}/n) = \theta^2/(n(n+2)).$$

I.2.9. Tarkime, $\varepsilon < \min |\theta_i - \theta_j|$. Tada

$$\mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| \geq \varepsilon\} = 1 - \mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| < \varepsilon\} = 1 - \mathbf{P}_\theta\{T_n(\mathbf{X}) = \theta\}.$$

Taigi

$$\mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| \geq \varepsilon\} \rightarrow 0 \Leftrightarrow \mathbf{P}_\theta\{T_n(\mathbf{X}) = \theta\} \rightarrow 1.$$

Jeigu $\forall \varepsilon > 0$ tikimybė $\mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| \geq \varepsilon\} \rightarrow 0$, tai

$$\mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| \geq \varepsilon\} \rightarrow 0, \quad \forall \varepsilon < \min |\theta_1 - \theta_j| \Rightarrow \mathbf{P}_\theta\{T_n(\mathbf{X}) = \theta\} \rightarrow 1.$$

Atvirščiai, jeigu $\mathbf{P}_\theta\{T_n(\mathbf{X}) = \theta\} \rightarrow 1$, tai $\mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| < \varepsilon\} \rightarrow 1 \quad \forall \varepsilon > 0$. Iš čia gauname, kad $\forall \varepsilon > 0$ tikimybė $\mathbf{P}_\theta\{|T_n(\mathbf{X}) - \theta| \geq \varepsilon\} \rightarrow 0$.

I.2.10. Tegu $Y_i = X_i - (\theta - 1/2)$, $i = 1, \dots, n$. Tada Y_1, \dots, Y_n yra paprastoji imtis, gauta stebint a. d. $Y \sim U(0, 1)$; $\mathbf{E}_\theta((X_{(1)} + X_{(n)})/2) = \mathbf{E}((Y_{(1)} + Y_{(n)})/2) + \theta - 1/2$; $\mathbf{V}_\theta((X_{(1)} + X_{(n)})/2) = \mathbf{V}((Y_{(1)} + Y_{(n)})/2)$. Gauname

$$\mathbf{E}(Y_{(1)} + Y_{(n)}) = n \int_0^1 x(1-x)^{n-1} dx + n \int_0^1 x^n dx = nB(2, n) + n/(n+1) = 1,$$

$$\mathbf{E}_\theta((X_{(1)} + X_{(n)})/2)) = \mathbf{E}((Y_{(1)} + Y_{(n)})/2) + \theta - 1/2 = \theta,$$

A. v. $(Y_{(1)}, Y_{(n)})^T$ tankio funkcija (žr. [2], 2.3 skyrelj) yra $n(n-1)(y-x)^{n-2}$, $0 < x < y < 1$. Randame

$$\mathbf{E}(Y_{(1)} + Y_{(n)})^2 = n(n-1) \int_0^1 \int_0^y (x+y)^2 (y-x)^{n-2} dx dy.$$

Atlikę keitimą $x = yt$, $dx = ydt$, gauname

$$\begin{aligned} \mathbf{E}(Y_{(1)} + Y_{(n)})^2 &= n(n-1) \int_0^1 y^{n+1} dy \int_0^1 (1+t)^2 (1-t)^{n-2} dt = \\ &\frac{n(n-1)}{n+1} [B(1, n-1) + 2B(2, n-1) + B(3, n-1)] = \frac{n^2 + 3n + 4}{(n+1)(n+2)}; \end{aligned}$$

$$\mathbf{V}_\theta((X_{(1)} + X_{(n)})/2) = \mathbf{V}((Y_{(1)} + Y_{(n)})/2) = 1/(2(n+1)(n+2)).$$

Remdamies Čebyšovo nelygybe randame

$$\mathbf{P}_\theta\{n^\alpha |\hat{\theta} - \theta| \geq \varepsilon\} \leq \frac{n^{2\alpha}}{2(n+1)(n+2)\varepsilon^2} \rightarrow 0, \quad n \rightarrow \infty.$$

I.2.11. Tarkime, $S_n = X_1 + \dots + X_n$. Statistika T įgyja reikšmę 0 su tikimybe $P_n = \mathbf{P}\{S_n \leq n/2\}$ ir reikšmę 1 su tikimybe $Q_n = 1 - P_n$. Statistikos T pirmieji momentai $\mathbf{ET} = Q_n$, $\mathbf{VT} = P_n Q_n$. Jeigu $0 < p < 1/2$, tai

$$Q_n = \mathbf{P}_p\{S_n > n/2\} = \mathbf{P}_p\left\{\frac{S_n - np}{\sqrt{np(1-p)}} > \frac{\sqrt{n}(1/2 - p)}{\sqrt{p(1-p)}}\right\} \rightarrow 0,$$

kai $n \rightarrow \infty$. Taigi statistika $T \xrightarrow{P} p$ su visais $0 < p < 1$.

I.2.12. Iš funkcijos $g_n(x)$ tolygaus konvergavimo išplaukia, kad bet kuriam $\varepsilon > 0$ egzistuoja toks N , kad

$$|g_n(x) - g(x)| < \varepsilon/2, \quad \forall x \in (a, b), \quad n > N.$$

Remdamiesi $g_n(x)$ tolydumu ir tolygiu konvergavimu gauname, kad $g(x)$ yra tolydi funkcija. Taigi duotam $\varepsilon > 0$ egzistuoja toks $\delta > 0$, kad

$$|g(T_n) - g(\theta)| < \varepsilon/2,$$

jei $|T_n - \theta| < \delta$. Gauname

$$|g_n(T_n) - g(\theta)| \leq |g_n(T_n) - g(T_n)| + |g(T_n) - g(\theta)| < \varepsilon,$$

jeigu $n > N$ ir $|T_n - \theta| < \delta$. Taigi, kai $n > N$

$$\mathbf{P}_\theta\{|T_n - \theta| < \delta\} \leq \mathbf{P}_\theta\{|g_n(T_n) - g(\theta)| < \varepsilon\};$$

$$\begin{aligned} \mathbf{P}_\theta\{|T_n - \theta| < \delta\} &\rightarrow 1 \Rightarrow \mathbf{P}_\theta\{|g_n(T_n) - g(\theta)| < \varepsilon\} \rightarrow 1 \\ &\Rightarrow \mathbf{P}_\theta\{|g_n(T_n) - g(\theta)| > \varepsilon\} \rightarrow 0, \quad n \rightarrow \infty. \end{aligned}$$

I.2.13. Tegu $\hat{\vartheta} = 1$, kai $|\bar{X}| \leq c_n$, ir $\hat{\vartheta} = 0$, kai $|\bar{X}| > c_n$; čia $c_n = 1/n^\alpha$, $0 < \alpha < 1/2$. Gauname

$$\mathbf{P}\{|\hat{\vartheta} - g(\mu)| \geq \varepsilon\} = \mathbf{P}\{|1 - g(\mu)| \geq \varepsilon, |\bar{X}| \leq c_n\} + \mathbf{P}\{|g(\mu)| \geq \varepsilon, |\bar{X}| > c_n\}.$$

Tada

$$\mathbf{P}\{|\hat{\vartheta} - g(\mu)| \geq \varepsilon | \mu = 0, \sigma\} = \mathbf{P}\{|\bar{X} - \mathbf{E}\bar{X}| > c_n | \mu = 0, \sigma\} < \frac{\mathbf{V}_{\sigma}\bar{X}}{1/n^{2\alpha}} = \sigma^2 n^{2\alpha-1} \rightarrow 0;$$

$$\mathbf{P}\{|\hat{\vartheta} - g(\mu)| \geq \varepsilon | \mu \neq 0, \sigma\} = \mathbf{P}_{\mu, \sigma}\left\{\frac{-c_n - \mu}{\sigma\sqrt{n}} \leq \frac{\bar{X} - \mu}{\sigma\sqrt{n}} \leq \frac{c_n - \mu}{\sigma\sqrt{n}}\right\} \rightarrow \Phi(0) - \Phi(0) = 0,$$

nes pagal CRT $(\bar{X} - \mu)/(\sigma\sqrt{n}) \xrightarrow{d} Z \sim N(0, 1)$.

I.2.14. Žr. **I.1.50, I.1.62** pratimus.

I.2.15. Žr. **I.1.48, I.1.62** pratimus.

I.2.16. A. d. X dispersija $\mathbf{V}_\theta X = \mathbf{E}_\theta X^2 - (\mathbf{E}_\theta X)^2 = \mathbf{E}_\theta X^2 - \theta^2$. Imkime statistiką $T = X^2 - Y$. Tada $\mathbf{E}_\theta T = \mathbf{E}_\theta X^2 - \mathbf{E}_\theta Y = \mathbf{E}_\theta X^2 - \theta^2 = \mathbf{V}_\theta X$. Taigi T yra nepaslinktasis dispersijos $\mathbf{V}_\theta X$ įvertinys.

I.2.17. A. d. $X - Y \sim N(0, 2\sigma^2)$. Randame

$$\mathbf{E}_\sigma|X - Y| = \frac{1}{\sqrt{\pi}\sigma} \int_0^\infty xe^{-x^2/(4\sigma^2)} dx = \frac{2\sigma}{\sqrt{\pi}} \neq \sigma;$$

$$\mathbf{E}_\sigma(X - Y)^2 = 2\sigma^2 \neq \sigma^2.$$

I.2.18. Tegu $Y_i = (X_i + \theta)/(2\theta)$. Tada Y_1, \dots, Y_n yra paprastoji imtis a. d. $Y \sim U(0, 1)$; $\mathbf{E}_\theta(X_{(n)} - X_{(1)}) = 2\theta\mathbf{E}(Y_{(n)} - Y_{(1)})$, $\mathbf{V}_\theta(X_{(n)} - X_{(1)}) = 4\theta^2\mathbf{V}(Y_{(n)} - Y_{(1)})$.

Remiantis **I.1.37** pratimu a.d. $Y_{(n)} - Y_{(1)} \sim Be(n-1, 2)$. Tada (žr. 1 priedo 1.P.2 lentelę)

$$\mathbf{E}(Y_{(n)} - Y_{(1)}) = \frac{n-1}{n+1}, \quad \mathbf{V}(Y_{(n)} - Y_{(1)}) = \frac{2(n-1)}{(n+1)^2(n+2)}.$$

Nepaslinktasis parametras θ jvertinys $\hat{\theta} = (X_{(n)} - X_{(1)})(n+1)/(2(n-1))$

$$\mathbf{E}_\theta \hat{\theta} = \theta, \quad \mathbf{V}_\theta \hat{\theta} = \frac{2\theta^2}{(n-1)(n+2)}.$$

I.2.2 skyrelis

I.2.19. Tikėtinumo funkcija

$$L(\mu, \lambda) = \lambda^n e^{-\lambda \sum_{i=1}^n (X_i - \mu)}, \quad \mu < X_1, \dots, X_n < \infty.$$

Arba

$$L(\mu, \lambda) = \lambda^n e^{\lambda n \mu} e^{-\lambda (X_{(1)} + \dots + X_{(n)})} \mathbf{1}_{(\mu, \infty)}(X_{(1)}).$$

Remiantis Neimano ir Fišerio faktorizacijos kriterijumi $\mathbf{T} = (X_{(1)}, X_{(2)} + \dots + X_{(n)})^T$ yra parametras $(\mu, \lambda)^T$ pakankamoji statistika.

I.2.20. Tikėtinumo funkcija

$$L(\eta, \sigma) = \eta^n (1/\sigma)^{n\eta} \left(\prod_i X_i \right)^{\eta-1} e^{-(1/\sigma^\eta) \sum_i X_i^\eta}.$$

- a) jeigu η nežinomas, tai L priklauso nuo visų imties elementų;
- b) jeigu η žinomas, tai tikėtinumo funkcija

$$L(\sigma) = \eta^n \left(\prod_i X_i \right)^{\eta-1} (1/\sigma^{n\eta}) e^{-(1/\sigma^\eta) \sum_i X_i^\eta} = W(\mathbf{X}) q(T; \sigma),$$

kai $T = \sum_i X_i^\eta$. Remiantis Neimano ir Fišerio faktorizacijos kriterijumi T yra parametras σ pakankamoji statistika.

I.2.21. Tikėtinumo funkcija

$$L(\lambda, \eta, \mu) = \frac{\lambda^{n\eta}}{[\Gamma(\eta)]^n} \left(\prod_i X_i \right)^{\eta-1} e^{-\lambda \sum_i (X_i - \mu)} \mathbf{1}_{(\mu, \infty)}(X_{(1)}).$$

- a) Kai μ ir λ žinomi, tikėtinumo funkcija

$$L(\eta) = e^{-\lambda \sum_i (X_i - \mu)} \mathbf{1}_{(\mu, \infty)}(X_{(1)}) \frac{\lambda^{n\eta}}{[\Gamma(\eta)]^n} \left(\prod_i X_i \right)^{\eta-1} = W(\mathbf{X}) q(T; \eta),$$

kai $T = \prod_i X_i$. Remiantis Neimano ir Fišerio faktorizacijos kriterijumi T yra parametras η pakankamoji statistika.

- b) Kai μ ir η žinomi, tikėtinumo funkcija

$$L(\lambda) = \frac{1}{[\Gamma(\eta)]^n} \left(\prod_i X_i \right)^{\eta-1} \mathbf{1}_{(\mu, \infty)}(X_{(1)}) \lambda^{n\eta} e^{-\lambda \sum_i (X_i - \mu)} = W(\mathbf{X}) q(T; \lambda),$$

kai $T = \sum_i (X_i - \mu)$. Remiantis Neimano ir Fišerio faktorizacijos kriterijumi T yra parametru λ pakankamoji statistika.

c) Kai μ žinomas, tikėtinumo funkcija

$$L(\lambda, \eta) = \mathbf{1}_{(\mu, \infty)}(X_{(1)}) \frac{\lambda^{n\eta}}{[\Gamma(\eta)]^n} \left(\prod_i X_i \right)^{\eta-1} e^{-\lambda \sum_i (X_i - \mu)} = W(\mathbf{X})q(\mathbf{T}; \lambda, \eta),$$

kai $\mathbf{T} = (\sum_i X_i, \sum_i (X_i - \mu))^T$. Remiantis Neimano ir Fišerio faktorizacijos kriterijumi \mathbf{T} yra parametru $(\lambda, \eta)^T$ pakankamoji statistika.

d) Kai λ žinomas, o $\eta = 1$, tikėtinumo funkcija

$$L(\mu) = \lambda^n e^{-\lambda \sum_i X_i} e^{\lambda n \mu} \mathbf{1}_{(\mu, \infty)}(X_{(1)}) = W(\mathbf{X})q(T; \mu),$$

kai $T = X_{(1)}$. Remiantis Neimano ir Fišerio faktorizacijos kriterijumi T yra parametru μ pakankamoji statistika.

I.2.22. Tikėtinumo funkcija

$$\begin{aligned} L(\boldsymbol{\theta}) &= (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_i (Y_i - \alpha - \beta x_i)^2 - \frac{n}{2} \ln \sigma^2\right\} = \\ &= (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_i Y_i^2 + \frac{\alpha}{\sigma^2} \sum_i Y_i + \frac{\beta}{\sigma^2} \sum_i Y_i x_i - B(\boldsymbol{\theta})\right\} \end{aligned}$$

priklauso triparametrei eksponentinio tipo skirstinių šeimai. Parametrų kitimo sritis turi vidinių taškų. Taigi statistika \mathbf{T} yra pilnoji ir pakankamoji parametru $\boldsymbol{\theta}$ statistika.

I.2.23. Remdamiesi Neimano ir Fišerio faktorizacijos kriterijumi gauname pakankamas statistikas: a) b) c) $T = \sum_i X_i$; d) $\mathbf{T} = (\sum_i X_i, \sum_i X_i)^T$; e) $\mathbf{T} = (\sum_i X_i, \prod(1 - X_i))^T$; f) $\mathbf{T} = (\sum_i \ln X_i, \sum_i \ln^2 X_i)^T$.

I.2.24. Tikėtinumo funkcija

$$L(\theta) = (2/\theta^2)^n \prod_i (\theta - X_i) \mathbf{1}_{(0, \theta)}(X_{(n)}).$$

Egzistuoja tik triviali pakankamoji statistika $\mathbf{T} = (X_1, \dots, X_n)^T$.

I.2.25. a) Tikėtinumo funkcija

$$L(\theta) = \theta^n / \prod_i (1 + X_i)^{\theta+1} = \theta^n e^{-(\theta+1) \sum_i \ln(1 + X_i)};$$

remiantis Neimano ir Fišerio faktorizacijos kriterijumi $T = \sum_i \ln(1 + X_i)$ yra pakankamoji parametru θ statistika; b) nesunku patikrinti, kad a. d. $\ln(1 + X_i) \sim \mathcal{E}(\theta)$; $T = \sum_i \ln(1 + X_i) \sim G(\theta, n)$. Tada $\mathbf{E}_\theta T = n/\theta$, $\mathbf{V}_\theta T = n/\theta^2$.

I.2.26. Pagal Neimano ir Fišerio faktorizacijos kriterijų $L(\theta) = W(\mathbf{X})q(T; \theta)$. Tada $L(\theta) = W(\mathbf{X})q(h(S); \theta)$. Taigi S irgi pakankamoji statistika.

I.2.27. Tikėtinumo funkcija

$$L(\lambda, \theta) = \theta^n \alpha^{n\theta} / \left(\prod_i X_i \right)^{\theta+1} \mathbf{1}_{(\alpha, \infty)}(X_{(1)}).$$

Remiantis Neimano ir Fišerio faktorizacijos kriterijumi $\mathbf{T} = (X_{(1)}, \prod_i X_i)^T$ yra pakankamoji parametru $(\alpha, \theta)^T$ statistika.

I.2.28. Variacinės eilutės tikėtinumo funkcija $f_n(X_{(1)}, \dots, X_{(n)}) = n!f(X_{(1)}) \cdot \dots \cdot f(X_{(n)})$. Remiantis Neimano ir Fišerio faktorizacijos kriterijumi $(X_{(1)}, \dots, X_{(n)})^T$ yra šeimos \mathcal{P} pakankamoji statistika.

I.2.29. Eksponentinio tipo skirstinių tankio kanoninė forma yra

$$f(x|\boldsymbol{\eta}) = h(x) \exp\{\boldsymbol{\eta}^T \mathbf{T}(x) - B(\boldsymbol{\eta})\}.$$

- a) $h(x) = 1/x!, \eta = \ln \lambda, T(x) = x, B(\eta) = e^\eta; -\infty < \eta < \infty, x = 0, 1, \dots;$
- b) $h(x) = C_{n+x-1}^{n-1}, \eta = \ln(1-p), T(x) = x, B(\eta) = -\ln(1-e^\eta), -\infty < \eta < 0, x = 0, 1, \dots;$
- c) $h(x) = I_{(a, \infty)}(x), \eta = -\theta, T(x) = x, B(\eta) = \eta a - \ln(-\eta), -\infty < \eta < 0, 0 < x < \infty;$
- d) $h(x) = 1/x, \boldsymbol{\eta} = (\eta_1, \eta_2)^T = (-\lambda, \eta)^T, \mathbf{T}(x) = (x, \ln x)^T, B(\boldsymbol{\eta}) = \ln \Gamma(\eta_2) - \eta_2 \ln(-\eta_1), -\infty < \eta_1 < 0, 0 < \eta_2 < \infty, x > 0;$
- e) $h(x) = 1/[x(1-x)], \boldsymbol{\eta} = (\eta_1, \eta_2)^T = (\gamma, \eta)^T, \mathbf{T}(x) = (\ln x, \ln(1-x))^T, B(\boldsymbol{\eta}) = \ln[\Gamma(\eta_1)\Gamma(\eta_2)/\Gamma(\eta_1 + \eta_2)], 0 < \eta_1, \eta_2 < \infty, 0 < x < 1;$
- f) $h(x) = \alpha x^{\alpha-1}, \eta = -1/\theta^\alpha, T(x) = x^\alpha, B(\eta) = \ln(-1/\eta), -\infty < \eta < 0, 0 < x < \infty.$

I.2.30. Tankio funkcija $f(x|\alpha, \theta) = \theta e^{-\theta(x-\alpha)}, x > \alpha$ negali būti užrašyta eksponentinio tipo tankiu (žr. [2], 3.3.2 apibrėžimą).

I.2.31. Tankio funkcija $f(x|n, p) = C_{n+x-1}^x p^n (1-p)^x, x = 0, 1, \dots$ negali būti užrašyta eksponentinio tipo tankiu.

I.2.32. Tankio funkcija $f(x|\mu, \sigma) = (1/(\sigma\pi))(1/(1+(x-\mu)^2/\sigma^2))$ negali būti užrašyta eksponentinio tipo tankiu.

I.2.33. Tankio funkcija $f(x|\alpha, \theta) = (\alpha x^{\alpha-1}/\theta^\alpha)e^{-(x/\theta)^\alpha}$ negali būti užrašyta eksponentinio tipo tankiu.

I.2.34. Tankio funkciją $f(\mathbf{x}|\boldsymbol{\mu}, \Sigma) = (\sqrt{2\pi})^{-k}/\sqrt{|\Sigma|} \exp\{(-1/2)(\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})\}$ galima perrašyti $f(\mathbf{x}|\boldsymbol{\mu}, \Sigma) = (\sqrt{2\pi})^{-k} \exp\{(-1/2) \sum_i \sigma^{ii} x_i^2 - \sum_{i>j} \sigma^{ij} x_i x_j + \sum_i x_i \sum_j \mu_j \sigma^{ij} - (1/2) \sum_i \sum_j \mu_i \sigma^{ij} \mu_j - (1/2) \ln |\Sigma|\}$; čia $\Sigma^{-1} = [\sigma^{ij}]_{k \times k}$. Gauname $(k(k+1)/2)$ -matį eksponentinio tipo skirstinį. Kanoninės formos parametrai yra $\boldsymbol{\eta} = (-\sigma^{ii}/2, i = 1, \dots, k; -\sigma^{ij}, i > j, i, j = 1, \dots, k; \sum_j \mu_j \sigma^{ij}, i = 1, \dots, k)^T, \mathbf{T} = (\sum_i X_i^2, i = 1, \dots, k; \sum_{i < j} X_i X_j, i > j, i, j = 1, \dots, k; \sum_i X_i, i = 1, \dots, k)^T, B(\boldsymbol{\eta}) = (1/2) \sum_i \sum_j \mu_i \sigma^{ij} \mu_j + (1/2) \ln |\Sigma|$.

I.2.35. $M(t) = (1-t/\lambda)^{-\eta}, t < \lambda$.

I.2.36. Tankis skaičiuojančiojo mato atžvilgiu yra

$$f(x|\theta) = \gamma(x) e^{x \ln \theta - \ln c(\theta)}, \quad x = 0, 1, \dots$$

priklauso eksponentinio tipo skirstinių šeimai. Kadangi

$$\sum_{x=0}^{\infty} \gamma(x) \theta^x = c(\theta),$$

tai

$$M(t) = \mathbf{E}_\theta(e^{tX}) = \frac{1}{c(\theta)} \sum_{x=0}^{\infty} \gamma(x) e^{tx} \theta^x = \frac{c(\theta e^t)}{c(\theta)}.$$

I.2.37. a) Šeimos \mathcal{P} tikėtinumo funkcija

$$L(\theta) = \prod_{i=1}^n f(X_i|\theta) = W(\mathbf{X})q(T;\theta), \quad \theta \in \Theta.$$

Tada šeimos \mathcal{P}_A tikėtinumo funkcija

$$L(\theta) = \prod_{i=1}^n f(X_i|\theta)/[P_\theta(A)]^n = W(\mathbf{X})q(T;\theta)/[P_\theta(A)]^n, \quad \theta \in \Theta.$$

Taigi T yra ir šeimos \mathcal{P}_A pakankamoji statistika. b) Jeigu iš sąlygos $\mathbf{E}_\theta h(T) \equiv 0, \theta \in \Theta$ išplaukia, kad $h(T) = 0$ b. v. skirtinių \mathcal{P} atžvilgiu, tai tuo labiau iš sąlygos $\mathbf{E}_\theta(h(T)|A) \equiv 0, \theta \in \Theta$, išplaukia, kad $h(T) = 0$ b. v. skirtinių \mathcal{P}_A atžvilgiu.

I.2.38. Pilnoji ir pakankamoji statistika $T = X_1 + \dots + X_n$. *Nurodymas.* Pasiremkite **I.2.37** pratimų.

I.2.39. Vidurkis $\mathbf{E}_\theta(X_{(n)} - X_{(1)} - (n-1)/(n+1)) \equiv 0, 0 < \theta < \infty$, nors ši funkcija nėra tapačiai lygi 0.

I.2.40. Tikėtinumo funkcija

$$L(a, b) = \prod_{i=1}^n \psi(X_i)/[\int_a^b \psi(x)dx]^n \mathbf{1}_{(a, \infty)(X_{(1)})} \mathbf{1}_{(-\infty, b)(X_{(n)})}.$$

Remiantis Neimano ir Fišerio faktorizacijos kriterijumi $\mathbf{T} = (X_{(1)}, X_{(n)})^T$ yra parametro $(a, b)^T$ pakankamoji statistika. Statistikos \mathbf{T} tankio funkcija

$$g(x, y) = \frac{n(n-1)}{[\int_a^b \psi(x)dx]^n} \left[\int_x^y \psi(u)du \right]^{n-2} \psi(x)\psi(y), \quad a < x < y < b.$$

Tarkime,

$$\mathbf{E}_{a,b}h(X_{(1)}, X_{(n)}) = \int_a^b \int_a^y h(x, y) g(x, y) dx dy \equiv 0, \quad \forall a < b.$$

Diferencijuokime tapatybę

$$\int_a^b \int_a^y h(x, y) \left[\int_x^y \psi(u)du \right]^{n-2} \psi(x)\psi(y) dx dy \equiv 0$$

pagal b ir po to pagal a . Gausime

$$\left[\int_a^b \psi(u)du \right]^{n-2} \psi(a)\psi(b)h(a, b) \equiv 0, \quad \forall a < b.$$

Matome, kad funkcija $h(X_{(1)}, X_{(n)})$ b. v. lygi 0. Statistika $\mathbf{T} = (X_{(1)}, X_{(n)})^T$ yra pilnoji.

I.2.41. Randame

$$\mathbf{E}_\theta X = (1 - \theta)^2 \sum_{k=1}^{\infty} k\theta^{k-1} = (1 - \theta)^2 / (1 - \theta)^2 = 1, \quad 0 < \theta < 1.$$

Imdami $\psi(X) = X - 1$, gauname $\mathbf{E}_\theta(\psi(X)) \equiv 0, \forall \theta \in (0, 1)$. Tačiau $\psi(X)$ įgyja reikšmes $-1, 0, 1, 2, \dots$. Taigi statistika X nėra pilnoji.

Iš sąlygos

$$\begin{aligned} \mathbf{E}_\theta(\psi(X)) &= \theta\psi(0) + \sum_{k=1}^{\infty} \psi(k)(1 - 2\theta + \theta^2)\theta^{k-1} = \\ \psi(1) + \sum_{k=1}^{\infty} [\psi(k-1) - 2\psi(k) + \psi(k+1)]\theta^k &\equiv 0 \quad \forall \theta \in (0, 1), \end{aligned}$$

įspauskia, kad

$$\psi(1) = 0, \quad \psi(k) - 2\psi(k+1) + \psi(k+2) = 0, \quad k = 0, 1, 2, \dots$$

Nuosekliai spręsdami gauname $\psi(2) = -\psi(0)$, $\psi(3) = -2\psi(0), \dots, \psi(k) = -(k-1)\psi(0), \dots$

Jeigu $\psi(0) \neq 0$, tai funkcija ψ neaprēzta. Jeigu $\psi(0) = 0$, tai ψ aprēzta ir $\psi(k) = 0, k = 0, 1, 2, \dots$ Statistika X yra aprēztai pilnoji.

I.2.42. a) Reikia įrodyti, kad imties $(X_1, \dots, X_n)^T$ sąlyginis skirstinys, kai $S_n = X_1 + \dots + X_n = t$ fiksuotas, nepriklauso nuo nežinomo parametru. Randame

$$\begin{aligned} \mathbf{P}_p\{X_1 = m_1, \dots, X_n = m_n | S_n = t\} &= \frac{\mathbf{P}_p\{X_1 = m_1\} \cdot \dots \cdot \mathbf{P}_p\{X_n = m_n\}}{\mathbf{P}_p\{S_n = t\}} = \\ \frac{p^{m_1}(1-p)^{1-m_1} \dots p^{m_n}(1-p)^{1-m_n}}{C_n^t p^t (1-p)^{n-t}} &= \frac{1}{C_n^t}, \end{aligned}$$

kai $m_i = 0; 1, i = 1, \dots, n$ ir $m_1 + \dots + m_n = t$. Sąlyginis skirstinys nepriklauso nuo nežinomo parametru p . Taigi S_n yra pakankamoji parametru p statistika.

b) Tikėtinumo funkcija

$$L(p) = p^{\sum_i X_i} (1-p)^{n - \sum_i X_i}.$$

Remiantis faktorizacijos kriterijumi $S_n = X_1 + \dots + X_n$ yra pakankamoji statistika.

I.2.43. (I.2.42 pratimo tēsinys). a) Tarkime, kad

$$\mathbf{E}_p h(S_n) = \sum_{m=0}^n h(m) C_n^m p^m (1-p)^{n-m} \equiv 0, \quad 0 < p < 1.$$

Arba, pažymėjus $x = p/(1-p)$,

$$\sum_{m=0}^n h(m) C_n^m x^m \equiv 0, \quad 0 < x < \infty.$$

Kairėje tapatybės pusėje turime n -ojo laipsnio polinomą x atžvilgiu. Polinomas tapatin-gai lygus 0, kai koeficientai prie x laipsnių lygūs nuliui. Taigi $h(0) = h(1) = \dots = h(n) = 0$. Funkcija $h(S_n)$ lygi nuliui su tikimybe 1.

b) Bernulio skirstinio tankis skaičiuojančiojo mato atžvilgiu priklauso eksponentinio tipo skirstinių šeimai; tankis kanonine forma yra

$$f(x|p) = \exp\{x\theta + \ln(1 + e^\theta)\}, \quad \theta = \ln(p/(1 - p)).$$

Parametro θ kitimo sritis yra intervalas $(-\infty, \infty)$, taigi jai priklauso vidiniai taškai. Statistika S_n yra pilnoji.

I.2.44. (**I.2.42** pratimo tēsinys). a) Statistika $U(\mathbf{X}) = X_1 X_2 \dots X_i (1 - X_{i+1}) \dots (1 - X_{i+j})$ įgyja reikšmę 1 su tikimybe $p^i (1 - p)^j$ ir reikšmę 0 priešingu atveju. Statistika $U(\mathbf{X})$ yra nepaslinktasis γ įvertinys.

$$\mathbf{E}(U(\mathbf{X})|S_n = t) = \mathbf{P}\{U(\mathbf{X}) = 1|S_n = t\}.$$

Pastarają tikimybę galime rasti naudodami klasikinį tikimybės apibrėžimą. Elementariųjų įvykių skaičius lygus skaičiui skirtinį būdą, kuriai galima t simboliu 1 ir $n - t$ simboliu 0 išdėstyti į n vietas, t. y. C_n^t (žr. **I.2.42** pratimą). Palankią įvykių skaičius lygus skaičiui būdą, kuriai galima $t - i$ likusius simbolius 1 ir $n - t - j$ likusius simbolius 0 išdėstyti į likusias $n - i - j$ vietas, t. y. C_{n-i-j}^{t-i} . Taigi

$$\mathbf{E}[U(\mathbf{X})|S_n = t] = C_{n-i-j}^{t-i}/C_n^t = t^{[i]}(n-t)^{[j]}/n^{[i+j]},$$

čia $m^{[k]} = m(m-1)\dots(m-k+1)$. Paramетro γ NMD įvertinys yra

$$\hat{\gamma} = S_n^{[i]}(n - S_n)^{[j]}/n^{[i+j]}.$$

Pavyzdžiui, parametru p ; $p^2; p(1-p)$ NMD įvertiniai yra

$$S_n/n; \quad S_n(S_n - 1)/(n(n - 1)); \quad S_n(n - S_n)/(n(n - 1)).$$

b) Tegu h yra funkcija, tenkinanti tapatybę

$$\mathbf{E}_p h(S_n) = \sum_{m=0}^n h(m) C_n^m p^m (1 - p)^{n-m} \equiv p^i (1 - p)^j, \quad 0 < p < 1.$$

Padauginkime dešiniają tapatybės pusę iš 1:

$$\begin{aligned} \sum_{m=0}^n h(m) C_n^m p^m (1 - p)^{n-m} &\equiv p^i (1 - p)^j \sum_{k=0}^{n-i-j} C_{n-i-j}^k p^k (1 - p)^{n-i-j-k} = \\ &\sum_{k=0}^{n-i-j} C_{n-i-j}^k p^{k+i} (1 - p)^{n-i-k} = \sum_{m=i}^{n-j} C_{n-i-j}^{m-i} p^m (1 - p)^{n-m}. \end{aligned}$$

Sulyginę koeficientus prie $p^m (1 - p)^{n-m}$, kai $m = i, \dots, n - j$, gauname, kad

$$h(m) = C_{n-i-j}^{m-i}/C_n^m = m^{[i]}(n - m)^{[j]}/n^{[i+j]}.$$

Gauname tą patį NMD jvertinį, kaip ir p. a).

- I.2.45.** (I.2.42 pratimo tēsinys). a) *Nurodymas.* Pasiremkime I.2.44 pratimu.
b) Tarkime, kad parametras p^k NMD jvertinys egzistuoja. Tada egzistuoja tokia funkcija $h(m)$, kad

$$\sum_{m=0}^n h(m) C_n^m p^m (1-p)^{n-m} \equiv p^k.$$

Kairėje tapatybės pusėje yra n -ojo laipsnio polinomas p atžvilgiu, o dešinėje – polinomas didesnio negu n laipsnio. Tokia tapatybė negalima.

- I.2.46.** (I.2.42 pratimo tēsinys). $38/50 + 12 \cdot 11 \cdot 10/(50 \cdot 49 \cdot 48); 12 \cdot 38/(50 \cdot 49); 12!38!/50!; 0; 0$.

- I.2.47.** a) Imties $(X_1, \dots, X_n)^T$ salyginis skirtinys, kai $S_n = X_1 + \dots + X_n = t$ fiksotas, nusakomas tikimybėmis

$$\begin{aligned} \mathbf{P}_\lambda\{X_1 = m_1, \dots, X_n = m_n | S_n = t\} &= \\ &= \frac{\mathbf{P}_\lambda\{X_1 = m_1\} \cdot \dots \cdot \mathbf{P}_\lambda\{X_n = m_n\}}{\mathbf{P}_\lambda\{S_n = t\}} = \frac{t!}{m_1! \dots m_n!} \frac{1}{n^t}, \end{aligned}$$

kai $m_i \geq 0$ ir $m_1 + \dots + m_n = t$. Salyginis skirtinys yra polinominis $\mathcal{P}_n(t; (1/n, \dots, 1/n))$. Salyginis skirtinys nepriklauso nuo nežinomo parametras λ . Taigi S_n yra parametras λ pakankamoji statistika.

- b) Tikėtinumo funkcija

$$L(\lambda) = \lambda^{\sum_i X_i} e^{-n\lambda} / (X_1! \dots X_n!).$$

Remiantis faktorizacijos kriterijumi $S_n = X_1 + \dots + X_n$ yra pakankamoji statistika.

- I.2.48.** (I.2.47 pratimo tēsinys). a) Tarkime, kad

$$\mathbf{E}_\lambda(h(S_n)) = \sum_{k=0}^{\infty} h(k)(n\lambda)^k e^{-n\lambda} / k! \equiv 0, \quad 0 < \lambda < \infty.$$

Arba

$$\sum_{k=0}^{\infty} h(k)n^k \lambda^k / k! \equiv 0, \quad 0 < \lambda < \infty.$$

Laipsninė eilutė tapatingai lygi 0, kai koeficientai prie λ laipsnių lygūs nuliui. Taigi $h(0) = h(1) = \dots = h(k) = \dots = 0$. Funkcija $h(S_n)$ lygi nuliui su tikimybe 1.

- b) Puasono skirtinio tankis skaičiuojančiojo mato atžvilgiu priklauso eksponentinio tipo skirtinių šeimai; tankis kanonine forma yra

$$f(x|\lambda) = \exp\{x\theta - e^\theta\} / x!, \quad \theta = \ln(p/(1-p)).$$

Parametras $\theta = \ln \lambda$ kitimo sritis yra intervalas $(-\infty, \infty)$, taigi jai priklauso vidiniai taškai. Statistika S_n yra pilnoji.

- I.2.49.** (I.2.47 pratimo tēsinys). a) Atžvilgiu h sprendžiame funkcinę lygtį

$$\mathbf{E}h(S_n) = \sum_{k=0}^{\infty} h(k)(n\lambda)^k e^{-n\lambda} / k! \equiv \lambda^m,$$

arba

$$\sum_{k=0}^{\infty} h(k)n^k \lambda^k / k! \equiv \lambda^m e^{n\lambda} = \sum_{j=0}^{\infty} \lambda^{j+m} n^j / j! = \sum_{k=m}^{\infty} \lambda^k n^{k-m} / (k-m)!.$$

Sulyginę koeficientus prie vienodų laipsnių λ^k , gauname $h(0) = h(1) = \dots = h(m-1) = 0$, $h(k) = k^{[m]} / n^m$, kai $k \geq m$.

Taigi parametru $\gamma_m(\lambda) = \lambda^m$ NMD įvertinys yra $\gamma_m(\lambda) = S_n^{[m]} / n^m = S_n(S_n - 1) \dots (S_n - m + 1) / n^m$.

b) Tarkime priešingai, kad parametru $1/\lambda$ NMD įvertinys egzistuoja. Tada egzistuoja funkcija h , tenkinanti tapatybę

$$\sum_{k=0}^{\infty} h(k)(n\lambda)^k / k! e^{-n\lambda} \equiv 1/\lambda,$$

arba

$$\sum_{k=0}^{\infty} h(k)n^k \lambda^k / k! \equiv \sum_{j=0}^{\infty} n^j \lambda^{j-1} / j!, \quad \forall \lambda > 0.$$

Kairėje pusėje yra laipsninė eilutė atžvilgiu λ , kai laipsnio rodikliai yra $0, 1, 2, \dots$, o dešinėje tapatybės pusėje laipsnio rodikliai yra $-1, 0, 1, \dots$. Tokia tapatybė negalima. Prielaida buvo neteisinga.

I.2.50. (I.2.47 pratimo tēsinys). a) Atžvilgiu h sprendžiame funkcinę lygtį

$$\mathbf{E}_{\lambda} h(S_n) = \sum_{k=0}^{\infty} h(k)(n\lambda)^k e^{-n\lambda} / k! \equiv \lambda^m e^{-\lambda} / m!,$$

arba

$$\sum_{k=0}^{\infty} h(k)n^k \lambda^k / k! \equiv \sum_{j=0}^{\infty} \lambda^{j+m} (n-1)^j / (j!m!) = \sum_{k=m}^{\infty} \lambda^k (n-1)^{k-m} / (j!(k-m)!).$$

Sulyginę koeficientus prie vienodų laipsnių λ^k , gauname $h(0) = h(1) = \dots = h(m-1) = 0$ ir

$$h(m) = C_k^m (1/n)^m (1 - 1/n)^{k-m}, \quad k \geq m.$$

Taigi, kai $S_n \geq m$, tai puasoninė tikimybė $\pi_m(\lambda)$ vertinama binominio skirstinio $B(S_n, 1/n)$ tikimybe $C_{S_n}^m (\frac{1}{n})^m (1 - \frac{1}{n})^{S_n-m}$.

b) Atžvilgiu h sprendžiame funkcinę lygtį

$$\mathbf{E}_{\lambda} h(S_n) = \sum_{k=0}^{\infty} h(k)(n\lambda)^k e^{-n\lambda} / k! \equiv e^{\lambda(s-1)},$$

arba

$$\sum_{k=0}^{\infty} h(k)n^k \lambda^k / k! \equiv \sum_{j=0}^{\infty} \lambda^j (n+s-1)^j / j!, \quad h(k) = (1 - \frac{1}{n} + \frac{s}{n})^k.$$

Generuojančios funkcijos $g(s)$ NMD įvertinys yra binominio skirstinio generuojančioji funkcija

$$\hat{g}(s) = (1 - \frac{1}{n} + \frac{s}{n})^{S_n}.$$

I.2.51. A. d. X skirstinio tankis skaičiuojančiojo mato atžvilgiu

$$f(x|p) = pq^x = \exp\{x\theta + \ln(1 - e^\theta)\}, \quad -\infty < \theta = \ln q < 0$$

priklauso vienparametrei eksponentinių skirstinių šeimai. Pakankamoji statistika $S_n = X_1 + \dots + X_n$. Kadangi parametras θ kitimo sritis turi vidinių taškų, tai S_n yra pilnoji statistika.

I.2.52. (I.2.51 pratimo tēsinys). Imties $(X_1, \dots, X_n)^T$ sąlyginis skirstinys, kai $S_n = X_1 + \dots + X_n = t$ fiksotas, nusakomas tikimybėmis

$$\mathbf{P}_p\{X_1 = m_1, \dots, X_n = m_n | S_n = t\} = \frac{\mathbf{P}_p\{X_1 = m_1\} \cdot \dots \cdot \mathbf{P}_p\{X_n = m_n\}}{\mathbf{P}_p\{S_n = t\}} = \frac{1}{C_{n+t-1}^t},$$

kai $m_i \geq 0$ ir $m_1 + \dots + m_n = t$. Sąlyginis skirstinys nepriklauso nuo nežinomo parametru. Statistika S_n yra pakankamoji parametru p statistika.

I.2.53. (I.2.51 pratimo tēsinys). Tegu h yra funkcija, tenkinanti tapatybę

$$\mathbf{E}_p h(S_n) = \sum_{k=0}^{\infty} h(k) C_{n+k-1}^k p^n q^k \equiv p^m q^l, \quad 0 < p < 1.$$

Padauginkime dešiniajają tapatybės pusę iš 1:

$$\begin{aligned} \sum_{k=0}^{\infty} h(k) C_{n+k-1}^k p^n q^k &\equiv p^m q^l \sum_{j=0}^{\infty} C_{n-m+j-1}^j p^{n-m} q^j = \\ &\sum_{k=l}^{\infty} C_{n+k-m-l-1}^{k-l} p^n q^k. \end{aligned}$$

Sulygine koeficientus prie $p^n q^k$, kai $k \geq l$, gauname

$$h(k) = C_{n+k-m-l-1}^{k-l} / C_{n+k-1}^k, \quad k \geq l.$$

Parametras $\gamma = p^m q^l$ NMD įvertinys

$$\hat{\gamma} = C_{n+S_n-m-l-1}^{S_n-l} / C_{n+S_n-1}^{S_n}, \quad S_n \geq l.$$

I.2.54. (I.2.51 pratimo tēsinys). Kadangi $\mathbf{E}_p S_n = nq/p$, tai parametras q/p NMD įvertinys yra $\bar{X} = S_n/n$. Kitų parametrų įvertiniai gaunami iš I.2.53 pratimo

$$\hat{p} = \frac{n-1}{n+S_n-1}, \quad \hat{p}^2 = \frac{(n-1)(n-2)}{(n+S_n-1)(n+S_n-2)}, \quad \hat{pq} = \frac{S_n(n-1)}{(n+S_n-1)(n+S_n-2)}.$$

I.2.55. (I.2.51 pratimo tēsinys). Funkcijos h atžvilgiu spręsdami funkcinę lygtį $\mathbf{E}_p(h(X)) \equiv p \ln p$, gauname

$$\mathbf{E}_p(h(X)) = p \sum_{k=1}^{\infty} h(k) q^{k-1} \equiv p \ln(1-q) = -p \sum_{k=1}^{\infty} q^k/k.$$

Sulyginę koeficientus prie vienodų q^k laipsnių gausime $h(k) = -1/(k-1)$, $k > 1$. Taigi parametru $\gamma = p \ln p$ NMD įvertinys yra $\hat{\gamma} = -1/(X-1)$, $X > 1$. Įvertinio realizacija yra $-1/13$.

I.2.56. a) Tikėtinumo funkcija

$$L(\boldsymbol{\theta}) = W(\mathbf{X}) \exp\{X_1 \ln p_1 + X_2 \ln p_2 + \dots + X_k \ln p_k\}, \quad W(\mathbf{X}) = \frac{n!}{X_1! \dots X_k!},$$

čia $X_k = n - X_1 - \dots - X_{k-1}$, $p_k = 1 - p_1 - \dots - p_{k-1}$; priklauso eksponentinio tipo skirstinių šeimai. Statistika $\mathbf{T} = (X_1, \dots, X_{k-1})^T$ yra pakankamoji. Kadangi parametru $(\ln p_1, \dots, \ln p_{k-1})^T$ kitimo sritis turi vidinių taškų, tai statistika \mathbf{T} yra pilnoji.

b) A. v. $(X_i, X_j)^T$ generuojančioji funkcija

$$\psi(s_1, s_2) = \mathbf{E}(s_1^{X_i} s_2^{X_j} | p_i, p_j) = \sum_{k_1, k_2} \frac{n!}{k_1! k_2! (n - k_1 - k_2)!} (p_i e^{s_1})^{k_1} ((p_j e^{s_2})^{k_2})$$

$$(1 - p_i - p_j)^{n - k_1 - k_2} = (p_i s_1 + p_j s_2 + 1 - p_i - p_j)^n.$$

Imdami funkcijos ψ m -ają išvestinę pagal s_1 taške $s_1 = s_2 = 1$, gauname faktorialinį momentą $\mathbf{E}(X_i^{[m]} | p_i, p_j) = n^{[m]} p_i^m$; imdami ψ k -ają išvestinę pagal s_1 ir l -ają išvestinę pagal s_2 taške $s_1 = s_2 = 1$, gaume $\mathbf{E}(X_i^{[k]} X_j^{[l]} | p_i, p_j) = n^{[k+l]} p_i^k p_j^l$. Taigi parametru p_i^m ir $p_i^k p_j^l$ NMD įvertiniai yra $X_i^{[m]} / n^{[m]}$ ir $X_i^{[k]} X_j^{[l]} / n^{[k+l]}$.

I.2.57. Tikėtinumo funkcija

$$L(\theta) = 1/\theta^n, \quad \text{kai } 0 < X_1, \dots, X_n < \theta,$$

arba

$$L(\theta) = (1/\theta^n) \mathbf{1}_{(0,\theta)}(X_{(n)}).$$

Remiantis faktorizacijos kriterijumi $T = X_{(n)}$ yra pakankamoji statistika.

Statistikos T tankio funkcija

$$f_n(x|\theta) = nx^{n-1}/\theta^n, \quad 0 < x < \theta.$$

Tarkime, kad funkcijos $h(X_{(n)})$ vidurkis tapatingai lygus 0:

$$\mathbf{E}_\theta h(X_{(n)}) = \frac{n}{\theta^n} \int_0^\theta h(x) x^{n-1} dx \equiv 0, \quad 0 < \theta < \infty.$$

Diferencijuodami tapatybę

$$\int_0^\theta h(x) x^{n-1} dx \equiv 0, \quad 0 < \theta < \infty$$

pagal θ gausime $h(\theta)\theta^{n-1} \equiv 0$, kai $0 < \theta < \infty$. Taigi funkcija $h(X_{(n)})$ lygi 0 su tikimybe 1. Statistika T yra pilnoji.

I.2.58. (I.2.57 pratimo tėsinys). Randame

$$\mathbf{E}_\theta X_{(n)} = \frac{n}{\theta^n} \int_0^\theta x x^{n-1} dx = \frac{n}{n+1} \theta, \quad \mathbf{E}_\theta \hat{\theta} = \mathbf{E}_\theta((n+1)X_{(n)}/n) = \theta.$$

Kadangi $\hat{\theta}$ yra pilnosios ir pakankamosios statistikos $X_{(n)}$ funkcija ir $\mathbf{E}_\theta \hat{\theta} = \theta$, tai $\hat{\theta}$ yra parametru θ NMD įvertinys.

I.2.59. Tikėtinumo funkcija

$$L(\theta) = \mathbf{1}_{(\theta, \infty)}(X_{(1)}) \mathbf{1}_{(-\infty, \theta+1)}(X_{(n)}).$$

Pakankamoji statistika $\mathbf{T} = (X_{(1)}, X_{(n)})^T$ yra dvimatičių.

Randame $\mathbf{E}_\theta X_{(1)} = \theta + 1/(n+1)$, $\mathbf{E}_\theta X_{(n)} = \theta + 1 - 1/(n+1)$. Tokiu būdu vidurkis $\mathbf{E}_\theta(X_{(n)} - X_{(1)} - (n-1)/(n+1)) \equiv 0$, nors pati funkcija nėra tapatingai lygi 0. Statistika \mathbf{T} nėra pilnoji.

I.2.60. a) Tikėtinumo funkcija

$$L(\theta_1, \theta_2) = \frac{1}{(\theta_2 - \theta_1)^n} \mathbf{1}_{(\theta_1, \infty)}(X_{(1)}) \mathbf{1}_{(-\infty, \theta_2)}(X_{(n)}).$$

Remiantis faktorizacijos kriterijumi statistika $\mathbf{T} = (X_{(1)}, X_{(n)})^T$ yra pakankamoji.

Tarkime, kad funkcijos $h(X_{(1)}, X_{(n)})$ vidurkis tapatingai lygus 0:

$$\mathbf{E}_{\theta_1, \theta_2} h(X_{(1)}, X_{(n)}) = \frac{n(n-1)}{(\theta_2 - \theta_1)^n} \int_{\theta_1}^{\theta_2} \int_{\theta_1}^y h(x, y) (y-x)^{n-2} dx dy \equiv 0 \quad \theta_1 < \theta_2.$$

Diferencijuokime tapatybę

$$\int_{\theta_1}^{\theta_2} \int_{\theta_1}^y h(x, y) (y-x)^{n-2} dx dy \equiv 0 \quad \theta_1 < \theta_2$$

pagal θ_2 , po to pagal θ_1 . Gauname $h(\theta_1, \theta_2)(\theta_2 - \theta_1)^{n-2} \equiv 0$ su visais $\theta_1 < \theta_2$, t. y. funkcija $h(X_{(1)}, X_{(n)}) \equiv 0$ b. v. Statistika \mathbf{T} yra pilnoji.

b) Kadangi $\hat{\gamma}_1$ ir $\hat{\gamma}_2$ yra pilnosios ir pakankamosios statistikos \mathbf{T} funkcijos, tai pakanka patikrinti jų nepaslinktumą. Dėl paprastumo atlikime keitimą $Y_i = (X_i - \theta_1)/(\theta_2 - \theta_1) \sim U(0, 1)$. Tada

$$\mathbf{E}_{\theta_1, \theta_2}((X_{(n)} + X_{(1)})/2) = \mathbf{E}((Y_{(n)} + Y_{(1)})/2)(\theta_2 - \theta_1) + \theta_1,$$

$$\mathbf{V}_{\theta_1, \theta_2}((X_{(n)} + X_{(1)})/2) = \mathbf{V}((Y_{(n)} + Y_{(1)})/2)(\theta_2 - \theta_1)^2;$$

$$\mathbf{E}_{\theta_1, \theta_2}((X_{(n)} - X_{(1)}) \frac{n+1}{n-1}) = \mathbf{E}((Y_{(n)} - Y_{(1)}) \frac{n+1}{n-1})(\theta_2 - \theta_1),$$

$$\mathbf{V}_{\theta_1, \theta_2}((X_{(n)} - X_{(1)}) \frac{n+1}{n-1}) = \mathbf{V}((Y_{(n)} - Y_{(1)}) \frac{n+1}{n-1})(\theta_2 - \theta_1)^2.$$

Randame (žr. I.2.10 ir I.2.18 pratimus)

$$\mathbf{E}((Y_{(n)} + Y_{(1)})/2) = 1/2, \quad \mathbf{E}_{\theta_1, \theta_2}((X_{(n)} + X_{(1)})/2) = \gamma_1;$$

$$\mathbf{V}((Y_{(n)} + Y_{(1)})/2) = \frac{1}{2(n+1)(n+2)}, \quad \mathbf{V}_{\theta_1, \theta_2}((X_{(n)} + X_{(1)})/2) = \frac{\gamma_2^2}{2(n+1)(n+2)};$$

$$\mathbf{E}((Y_{(n)} - Y_{(1)})) = \frac{n-1}{n+1}, \quad \mathbf{E}_{\theta_1, \theta_2} \hat{\gamma}_2 = \theta_2 - \theta_1 = \gamma_2;$$

$$\mathbf{V}((Y_{(n)} - Y_{(1)})) = \frac{2(n-1)}{(n+1)^2(n+2)}, \quad \mathbf{V}_{\theta_1, \theta_2} \hat{\gamma}_2 = \frac{2\gamma_2^2}{(n+2)(n-1)}.$$

I.2.61. Tikėtinumo funkcija

$$L(\theta) = \frac{1}{(2\theta)^n} \mathbf{1}_{(-\theta, \infty)}(X_{(1)}) \mathbf{1}_{(-\infty, \theta)}(X_{(n)}) = \frac{1}{(2\theta)^n} \mathbf{1}_{(-\infty, \theta)}(\max(-X_{(1)}, X_{(n)})).$$

Remiantis faktorizacijos kriterijumi $T = \max(-X_{(1)}, X_{(n)})$ yra pakankamoji statistika. Tegu $Y_i = |X_i| \sim U(0, \theta)$, $T = Y_{(n)}$. Statistikos T pilnumas įrodytas **I.2.57** pratime. Ten pat įrodyta, kad $\hat{\theta} = (n+1)T/n$ yra parametru θ NMD įvertinys.

I.2.62. a) A. d. X tankio funkcija

$$f(x|\mu, \sigma) = (2\pi)^{-1/2} \exp\left\{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x - \frac{\mu^2}{2\sigma^2} - \frac{1}{2}\ln\sigma^2\right\}$$

priklauso dviparametrei eksponentinio tipo skirstinių šeimai. Iš tankio pavidalo išplaukia, kad $\mathbf{U}(\mathbf{X}) = (\sum_i X_i, \sum_i X_i^2)^T$ yra pakankamoji statistika. Tada statistika $\mathbf{T} = \mathbf{T}(\mathbf{U}(\mathbf{X})) = (\bar{X}, s^2)^T$ irgi pakankama. Parametru $(-\mu/\sigma^2, \mu/\sigma^2)^T$ kitimo sritis yra pusplokštumė, todėl jai priklauso vidiniai taškai. Statistika \mathbf{T} ne tik pakankamoji, bet ir pilnoji.

b) Kadangi $\mathbf{E}_{\mu, \sigma} \bar{X} = \mu$, $\mathbf{E}_{\mu, \sigma} s^2 = \sigma^2$, tai \bar{X} ir s^2 yra parametrų μ ir σ^2 NMD įvertiniai.

I.2.63. (**I.2.62** pratimo tēsinys). Žinome, kad $s^2(n-1)/\sigma^2 \sim \chi^2(n-1)$ (žr. [2], 2.5.1 teoremą). Tada

$$\begin{aligned} \mathbf{E}_{\mu, \sigma} s &= \frac{\sigma}{\sqrt{n-1}} \mathbf{E} \sqrt{\chi_{n-1}^2} = \frac{\sigma}{\sqrt{n-1}} \frac{1}{2^{(n-1)/2} \Gamma((n-1)/2)} \int_0^\infty x^{n/2-1} e^{-x/2} dx = \\ &= \frac{\sigma}{\sqrt{n-1}} \frac{\sqrt{2} \Gamma(n/2)}{\Gamma((n-1)/2)} = \sigma M_{n-1}; \quad \mathbf{E}_{\mu, \sigma}(s/M_{n-1}) = \sigma. \end{aligned}$$

I.2.64. (**I.2.62** pratimo tēsinys). a) Tikėtinumo funkcija

$$L(\sigma^2) = (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_i (X_i - \mu)^2 - \frac{n}{2} \ln \sigma^2\right\}.$$

Matome, kad pilnoji ir pakankamoji statistika yra s_0^2 . Be to, $s_0^2 n / \sigma^2 \sim \chi^2(n)$; t. y. $\mathbf{E}_\sigma s_0^2 = \sigma^2$, $\mathbf{E}_\sigma(s_0/M_n) = \sigma$.

b) Tikėtinumo funkcija

$$L(\mu) = (2\pi\sigma)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_i X_i^2\right\} \exp\left\{\frac{\mu n \bar{X}}{\sigma^2} - \frac{n\mu^2}{2\sigma^2}\right\}.$$

Pilnoji ir pakankamoji statistika \bar{X} ; $\mathbf{E}_\mu \bar{X} = \mu$.

I.2.65. a) Tikėtinumo funkcija

$$L(\mu, \lambda) = \lambda^n e^{n\mu\lambda} e^{-\lambda \sum_i X_i} \mathbf{1}_{(\mu, \infty)}(X_{(1)}).$$

Remiantis faktorizacijos kriterijumi $(X_{(1)}, \sum_i X_i)^T$ yra pakankamoji. Pakankamoji yra ir jai ekvivalenti statistika $(X_{(1)}, T_2(\mathbf{X}))^T$.

b) Kadangi $X_{(1)}$ ir T_2 yra nepriklausomi (žr. I.1.27 pratimą), tai jos pilnumą galima irodyti nagrinėjant šias statistikas atskirai.

c) Kadangi $\hat{\gamma}_1$ ir $\hat{\gamma}_2$ yra pilnos ir pakankamos statistikos funkcijos, tai pakanka patikrinti juų nepaslinktumą. Randame

$$\mathbf{E}_{\mu, \lambda} \hat{\gamma}_2 = \frac{1}{\lambda^m \Gamma(n+m-1)} \int_0^\infty x^m x^{n-2} e^{-x} dx = \frac{1}{\lambda^m}.$$

Statistikos $X_{(1)}$ tankio funkcija (žr. I.1.25 pratimą)

$$f(x|\mu, \lambda) = n\lambda e^{-n\lambda(x-\mu)}, \quad \mu < x < \infty.$$

Skaičiuojame vidurkį

$$\mathbf{E}_{\mu, \lambda} X_{(1)}^l = n\lambda \int_\mu^\infty x^l e^{-n\lambda(x-\mu)} dx = n\lambda \int_0^\infty (t+\mu)^l e^{-n\lambda t} dt.$$

Integruodami dalimis gauname

$$\mathbf{E}_{\mu, \lambda} X_{(1)}^l = \mu^l + l \int_0^\infty (t+\mu)^{l-1} e^{-n\lambda t} dt = \mu^l + l/(n\lambda) \mathbf{E}_{\mu, \lambda} X_{(1)}.$$

Kadangi $\mathbf{E}_{\mu, \lambda} T_2/(n-1) = 1/\lambda$, o $X_{(1)}^{l-1}$ ir T_2 nepriklausomi a. d., tai antrasis dėmuo yra vidurkis a. d. $lX_{(1)}^{l-1}T_2/(n(n-1))$. Atėmę šį a. d. iš $X_{(1)}^l$ gausime statistiką, kurios vidurkis lygus μ^l .

I.2.66. (I.2.65 pratimo tēsinys). a) Tikėtinumo funkcija

$$L(\lambda) = \lambda^n e^{-\lambda \sum_i (X_i - \mu)},$$

taigi $T = \sum_i (X_i - \mu)$ yra pilnoji ir pakankamoji statistika; $X_i - \mu \sim \mathcal{E}(\lambda)$; $\mathbf{E}_\lambda (\bar{X} - \mu) = 1/\lambda$.

b) Tikėtinumo funkcija

$$L(\mu) = \lambda^n e^{-\lambda \sum_i X_i} e^{n\lambda\mu} \mathbf{1}_{(\mu, \infty)}(X_{(1)}),$$

taigi $X_{(1)}$ yra pilnoji ir pakankamoji statistika. I.2.64 pratime parodėme (imkime $l = 1$), kad $\mathbf{E}_\mu X_{(1)} = \mu + 1/(n\lambda)$. Taigi $\mathbf{E}_\mu (X_{(1)} - 1/(n\lambda)) = \mu$.

I.2.67. Tikėtinumo funkcija

$$L(\lambda, \eta) = \exp\{-\lambda \sum_i X_i + (\eta - 1) \sum_i \ln X_i + n\eta \ln \lambda - n \ln(\Gamma(\eta))\}.$$

Skirstinys priklauso dviparametrei eksponentinio tipo skirstinių šeimai; pakankamoji statistika $\mathbf{T} = (\sum_i X_i, \sum_i \ln X_i)^T$. Kadangi parametro kitimo sričiai priklauso vidiniai taškai, tai statistika \mathbf{T} pilnoji. A. d. \bar{X} yra pilnosios ir pakankamosios statistikos \mathbf{T} funkcija ir $\mathbf{E}(\bar{X}|\lambda, \eta) = \eta/\lambda$, todėl \bar{X} yra parametru η/λ NMD įvertinys.

I.2.68. (I.2.67 pratimo tēsinys). Kai η žinomas, tikėtinumo funkcija yra

$$L(\lambda) = \frac{1}{(\Gamma(\eta))^n} \left(\prod_i X_i \right)^{\eta-1} e^{-\lambda \sum_i X_i + n\eta \ln \lambda}.$$

Pilnoji ir pakankamoji statistika $T = \sum_i X_i \sim G(\lambda, n\eta)$. Randame (atlikę kintamųjų keitimą $\lambda x = y$)

$$\mathbf{E}_\lambda \hat{\gamma} = \frac{\lambda^{n\eta}}{\Gamma(n\eta - k)} \int_0^\infty x^{-k} x^{n\eta-1} e^{-\lambda x} dx = \lambda^k.$$

I.2.69. (I.2.67 pratimo tēsinys). Kai λ žinomas, tikėtinumo funkcija yra

$$L(\eta) = e^{-\lambda \sum_i X_i} e^{(\eta-1) \sum_i \ln X_i + n\eta \ln \lambda - n \ln \Gamma(\eta)}.$$

Pilnoji ir pakankamoji statistika $T = \sum_i \ln X_i$. Randame

$$\mathbf{E}_\eta (\ln X_i) = \frac{\lambda^\eta}{\Gamma(\eta)} \int_0^\infty \ln x x^{\eta-1} e^{-\lambda x} dx = \frac{1}{\Gamma(\eta)} \int_0^\infty (\ln t - \ln \lambda) t^{\eta-1} e^{-t} dt = \frac{\Gamma'(\eta)}{\Gamma(\eta)} - \ln \lambda.$$

I.2.70. Reikia suvidurkinti nepaslinktajį įvertinį $h(X_1)$ pakankamosios statistikos $\mathbf{T}(\mathbf{X})$ atžvilgiu (žr. [2], 3.3.5 skyrelį). Gauname

$$\begin{aligned} \hat{\tau}(\mathbf{T}) &= \mathbf{E}(h(X_1)|\mathbf{T}) = \mathbf{E}\left(h\left(\frac{X_1 - \hat{\theta}_1}{\hat{\theta}_2} \hat{\theta}_2 + \hat{\theta}_1\right) |\mathbf{T}\right) = \\ &= \mathbf{E}(h(U(\mathbf{X})\hat{\theta}_2 + \hat{\theta}_1)|\mathbf{T}). \end{aligned}$$

Remiantis Basu teorema [9] statistikos $U(\mathbf{X})$ ir $\mathbf{T} = \mathbf{T}(\mathbf{X})$ yra nepriklausomos. Taigi

$$\hat{\tau}(\mathbf{T}) = \int_{-\infty}^\infty h(u\hat{\theta}_2 + \hat{\theta}_1)g(u)du.$$

I.2.71. Nepaslinktasis parametras γ_1 įvertinys yra $h(X_1) = \mathbf{1}_{(-\infty, y)}(X_1)$, nes

$$\mathbf{E}_\mu h(X_1) = \mathbf{P}_\mu \{X_1 \leq y\} = \Phi(y - \mu).$$

Parametras μ pilnoji ir pakankamoji statistika yra \bar{X} . I.2.70 pratime imkime

$$U = U(\mathbf{X}) = X_1 - \bar{X}, \quad \hat{\theta}_1 = \bar{X}, \quad \hat{\theta}_2 = 1.$$

Gauname

$$\begin{aligned} \hat{\gamma}_1 &= \mathbf{E}(h(X_1)|T) = \mathbf{E}(h(U + \bar{X})|T) = \int_{-\infty}^\infty h(u + \bar{X}|T)g(u)du = \\ &\int_{-\infty}^{y - \bar{X}} g(u)du = \Phi((y - \bar{X})/\sqrt{1 - 1/n}), \end{aligned}$$

nes $U \sim N(0, 1 - 1/n)$. Diferencijuodami tapatybės

$$\mathbf{E}_\mu \hat{\gamma}_1 = \int_{-\infty}^\infty \Phi((y - \bar{X})/\sqrt{1 - 1/n}) \sqrt{n} \varphi(\sqrt{n}(x - \mu))dx \equiv \Phi(y - \mu)$$

abi puses pagal y įsitikiname, kad paramетro γ_2 NMD jvertinys yra

$$\hat{\gamma}_2 = \varphi((y - \bar{X})/\sqrt{1 - 1/n})/\sqrt{1 - 1/n}.$$

I.2.72. Nepaslinktasis paramетro γ_1 jvertinys yra $h(X_1) = \mathbf{1}_{(-\infty, y)}(X_1)$, nes

$$\mathbf{E}_\sigma h(X_1) = \mathbf{P}_\sigma\{X_1 < y\} = \Phi(y/\sigma).$$

Paramетro σ pilnoji ir pakankamoji statistika yra $S^2 = X_1^2 + \dots + X_n^2$. **I.2.70** pratime imkime $U = U(\mathbf{X}) = X_1/S$, $\hat{\theta}_1 = 0$, $\hat{\theta}_2 = S$. Gauname

$$\hat{\gamma}_1 = \mathbf{E}(h(X_1)|T) = \mathbf{E}(h(U S)|T) = \int_{-\infty}^{y/S} g(u)du.$$

Reikia rasti statistikos $U(\mathbf{X})$ tankio funkciją $g(u)$. Kadangi $X_i^2/\sigma^2 \sim \chi_1^2$, $X_2^2 + \dots + X_n^2 \sim \chi_{n-1}^2$, tai $U^2(\mathbf{X}) = X_1^2/(X_1^2 + \dots + X_n^2) \sim Be(1/2, (n-1)/2)$. Statistika $U(\mathbf{X})$ simetriška. Kai $u > 0$, pasiskirstymo funkcija

$$\begin{aligned} G(u) &= \mathbf{P}\{U < u\} = \frac{1}{2} + \frac{1}{2}\mathbf{P}\{U^2 < u^2\} = \\ &\frac{1}{2} + \frac{\Gamma(n/2)}{2\Gamma(1/2)\Gamma((n-1)/2)} \int_0^{u^2} v^{-1/2}(1-v)^{(n-3)/2}dv. \end{aligned}$$

Diferencijuodami pagal u gausime tankio funkciją

$$g(u) = G'(u) = \frac{\Gamma(n/2)}{\Gamma(1/2)\Gamma((n-1)/2)}(1-u^2)^{(n-3)/2}, \quad |u| < 1.$$

Gauname NMD jvertinį

$$\hat{\gamma}_1 = \int_{-1}^{y/S} g(u)du = \frac{\Gamma(n/2)}{\Gamma(1/2)\Gamma((n-1)/2)} \int_{-1}^{y/S} (1-u^2)^{(n-3)/2}du, \quad |y/S| < 1.$$

Tankio funkcijos jvertinys $\hat{\gamma}_2 = g(y/S)/S$.

I.2.73. Nepaslinktasis paramетro γ jvertinys yra $h(X_1) = \mathbf{1}_{(-\infty, y)}(X_1)$, nes

$$\mathbf{E}_{(\mu, \sigma)} h(X_1) = \mathbf{P}_{(\mu, \sigma)}\{X_1 < y\} = \Phi((y - \mu)/\sigma).$$

Paramетro $(\mu, \sigma)^T$ pilnoji ir pakankamoji statistika yra $\mathbf{T} = (\bar{X}, S^2)^T$, $S^2 = \sum_i (X_i - \bar{X})^2$. **I.2.70** pratime imkime $U = U(\mathbf{X}) = (X_1 - \bar{X})/S$, $\hat{\theta}_1 = \bar{X}$, $\hat{\theta}_2 = S$. Statistikos $U(\mathbf{X})$ skirstinys nuo nežinomų parametru nepriklauso, todėl statistikos $U(\mathbf{X})$ ir \mathbf{T} nepriklausomos. Gauname

$$\hat{\gamma}_1 = \mathbf{E}(h(X_1)|\mathbf{T}) = \mathbf{E}(h(U S + \bar{X})|\mathbf{T}) = \int_{-\infty}^{(y - \bar{X})/S} g(u)du.$$

Lieka rasti statistikos $U(\mathbf{X}) = (X_1 - \bar{X})/S$ tankio funkciją $g(u)$.

Atlikime ortonormuotą transformaciją $\mathbf{Y} = \mathbf{C}\mathbf{X}$, parinkę matricos \mathbf{C} pirmąsias dvi eilutes tokio pavidalo:

$$(1/\sqrt{n}, 1/\sqrt{n}, \dots, 1/\sqrt{n});$$

$$(\sqrt{1 - 1/n}, -1/\sqrt{n(n-1)}, \dots, -1/\sqrt{n(n-1)}).$$

Tada $Y_1 = \sqrt{n}\bar{X}$, $Y_2 = \sqrt{n/(n-1)}(X_1 - \bar{X})$, $S^2 = \sum_i X_i^2 - n\bar{X}^2 = \sum_i Y_i^2 - Y_1^2 = Y_2^2 + Y_3^2 + \dots + Y_n^2$. Statistika $U(\mathbf{X}) = \sqrt{(n-1)/n}Y_2/\sqrt{Y_2^2 + \dots + Y_n^2}$. Kadangi $U(\mathbf{X})$ skirstinys nepriklauso nuo nežinomų parametrų, tai galime imti $\mu = 0, \sigma = 1$. Tada $Y_i^2 \sim \chi_1^2$ ir $U^2(\mathbf{X})/(1 - 1/n) \sim Be(1/2, n-2)$. Remiantis $U(\mathbf{X})$ simetrija pasiskirstymo funkcija, kai $u > 0$, yra

$$G(u) = \mathbf{P}\{U(\mathbf{X}) < u\} = \frac{1}{2} + \frac{1}{2}\mathbf{P}\{U^2(\mathbf{X}) < u^2\} = \frac{1}{2} + \frac{\Gamma((n-1)/2)}{2\Gamma(1/2)\Gamma((n-2)/2)} \int_0^{u^2 n/(n-1)} v^{-1/2} (1-v)^{(n-4)/2} dv.$$

Diferencijuodami pagal u gauname tankio funkciją

$$g(u) = \frac{\Gamma((n-1)/2)}{\Gamma(1/2)\Gamma((n-2)/2)} \sqrt{n/(n-1)} (1 - nu^2/(n-1))^{(n-4)/2}, \quad |u| < \sqrt{1 - 1/n}.$$

I.2.74. Kadangi $X_{(1)}$ yra pilnoji ir pakankamoji statistika, tai pakanka patikrinti jvertinio $\hat{\gamma}$ nepaslinktumą. A. d. $X_{(1)}$ tankio funkcija $ne^{-n(x-\theta)}$, $x > \theta$. Gauname

$$\mathbf{E}_\theta \hat{\gamma} = \frac{n-1}{n} e^{-y} \int_\theta^\infty n e^x e^{-n(x-\theta)} dx = e^{-(y-\theta)}.$$

I.2.75. Tikėtinumo funkcija

$$L(\lambda) = \lambda^n e^{-\lambda \sum_i (X_i - a)} \mathbf{1}_{(a, \infty)}(X_{(1)}).$$

Pilnoji ir pakankamoji statistika $T = \sum_i (X_i - a) \sim G(\lambda, n)$. Nepaslinktasis parametras γ jvertinys

$$h(X_1) = \mathbf{1}_{(y, \infty)}(X_1), \quad \mathbf{E}_\lambda h(X_1) = \mathbf{P}_\lambda\{X_1 > y\} = e^{-\lambda(y-a)}.$$

I.2.70 pratime imkime $\hat{\theta}_1 = a, \hat{\theta}_2 = T$. Kadangi $\lambda(X_i - a) \sim \mathcal{E}(1)$, tai $2\lambda(X_i - a) \sim \chi_2^2$ ir statistika $U(\mathbf{X}) = (X_1 - a)/T \sim Be(1, n-1)$ nepriklauso nuo T. Gauname

$$\hat{\gamma} = \int_{-\infty}^\infty h(uT + a)g(u)du = (n-1) \int_{(y-a)/T}^1 (1-x)^{n-2} dx = (1 - (y-a)/T)^{n-1},$$

kai $0 < (y-a)/T < 1$.

I.2.76. A. d. $Y = \ln X \sim \mathcal{E}(\ln \alpha, \sigma)$. Statistika $Y_{(1)} = \ln X_{(1)}$ yra pilnoji ir pakankamoji parametras $\ln \alpha$ statistika. Pakanka patikrinti jvertinio $\hat{\gamma}$ nepaslinktumą.

$$\mathbf{E}_\alpha \hat{\gamma} = \frac{n\sigma - m}{n\sigma} \mathbf{E}_\alpha (\ln X_{(1)})^m = \frac{n\sigma - m}{n\sigma} \int_{\ln \alpha}^\infty n\sigma x^m e^{-n\sigma(x - \ln \alpha)} dx = \alpha^m.$$

I.2.77. A. d. $Y = e^{-X} \sim \mathcal{E}(e^\theta)$. Pasinaudoję **I.2.75** pratimu gauname

$$\hat{f}(z|\theta) = (n-1)e^{-z}(1 - e^{-z}/T)^{n-2}/T, \quad z > -\ln T,$$

čia $T = \sum_i e^{-X_i}$.

I.2.78. Tikėtinumo funkcija

$$L(M) = \frac{M^{[T]}(N-M)^{[n-T]}}{N^{[n]}} = \frac{C_M^T C_{N-M}^{n-T}}{C_N^n};$$

čia $K^{[m]} = K(K-1)\dots(K-m+1)$, o $T = \sum_{i=1}^n X_i$. Remiantis faktorizacijos kriterijumi T yra paramетro M pakankamoji statistika. Statistika T įgyja reikšmes iš aibės $D = \{t : \max(0, n - (N - M)) \leq t \leq \min(n, M)\}$.

Remiantis statistikos pilnumo apibrėžimu reikia įrodyti, kad iš sąlygos

$$\mathbf{E}(h(T)|M) = \sum_D h(t) \frac{C_M^t C_{N-M}^{n-t}}{C_N^n} \equiv 0, \quad \forall M = 0, 1, \dots, N,$$

išplaukia, kad $h(t) = 0$ su visais $t \in D$.

Imkime paeiliui $M = 0, 1, \dots, N$. Kai $M = 0$, tai aibei D priklauso vienintelis taškas $t = 0$. Taigi

$$\mathbf{E}(h(T)|0) = h(0) \cdot 1 = 0 \Rightarrow h(0) = 0.$$

Kai $M = 1$ ir $1 \leq n \leq N-1$, tai aibė D susideda iš dviejų taškų $t = 0$ ir $t = 1$. Gauname

$$\mathbf{E}(h(T)|1) = h(0) \frac{C_{N-1}^n}{C_N^n} + h(1) \frac{C_{N-1}^{n-1}}{C_N^n} = 0 \Rightarrow h(1) = 0.$$

Tęsdami šią procedūrą įsitiksime, kad $h(t) = 0$ su visais $t \in D$. Taigi pakankamoji statistika T yra pilnoji parametru M statistika.

I.2.79. a) Randame

$$\mathbf{E}_\theta X = -\theta + \theta(1-\theta)^2 \sum_{k=1}^{\infty} k\theta^{k-1} = -\theta + \theta(1-\theta)^2 \frac{1}{(1-\theta)^2} \equiv 0,$$

nors X nėra tapačiai lygi nuliui. Statistika X nėra pilnoji.

b) Parametru $\gamma = (1-\theta)^2$ nepaslinktasis įvertinys turi tokį pavidalą $\hat{\gamma} = T(X) + cX$, kai c bet kokia konstanta, nes

$$\mathbf{E}_\theta \hat{\gamma} = \mathbf{E}_\theta T(X) + c\mathbf{E}_\theta X = (1-\theta)^2.$$

Kadangi $\mathbf{Cov}(T(X), X) = \mathbf{E}_\theta(XT(X)) = 0$, tai dispersijos $\mathbf{V}_\theta \hat{\gamma} = \mathbf{V}_\theta(T(X)) + c^2 \mathbf{V}_\theta X$ minimumas gaunamas, kai $c = 0$. Taigi $T(X)$ yra parametru γ NMD įvertinys.

c) Įvertinys $\hat{\theta}$ yra nepaslinktasis

$$\mathbf{E}_\theta \hat{\theta} = \mathbf{P}\{X < 1|\theta\} + c\mathbf{E}_\theta X = \theta, \quad c \in \mathbf{R}.$$

Randame

$$\mathbf{E}_\theta \hat{\theta}^2 = \mathbf{E}_\theta \mathbf{1}_{\{-1\}}(X) + 2c\mathbf{E}_\theta(X\mathbf{1}_{\{-1\}}(X)) + c^2\mathbf{E}_\theta X^2;$$

$$\mathbf{V}_\theta \hat{\theta} = \theta(1-\theta) - 2c\theta + c^2\mathbf{E}_\theta X^2.$$

Gauname

$$\mathbf{E}_\theta X^2 = \theta + \theta(1-\theta)^2 \sum_{k=1}^{\infty} k^2 \theta^{k-1} = \theta + \theta(1-\theta)^2 \frac{1-\theta}{(1-\theta)^3} = \frac{2\theta}{1-\theta}.$$

Tada dispersija

$$\mathbf{V}_\theta \hat{\theta} = \theta(1-\theta) - 2c\theta + 2c^2 \frac{\theta}{1-\theta}$$

igyja minimalią reikšmę, kai $c = (1-\theta)/2$. Tačiau c jeina į įvertinio išraišką, todėl negali priklausyti nuo nežinomo parametru θ . NMD įvertinys neegzistuoja.

I.2.80. Kadangi X yra pilnoji ir pakankamoji statistika, tai pakanka patikrinti įvertinio $\hat{\gamma}$ nepaslinktumą, t. y. patikrinti tapatybę

$$\frac{2e^{-\lambda}}{1-e^{-\lambda}} \sum_{k=1}^{\infty} \frac{\lambda^{2k}}{(2k)!} \equiv 1 - e^{-\lambda}, \quad 0 < \lambda < \infty.$$

Gauname ekvivalenčią tapatybę

$$\sum_{k=1}^{\infty} \frac{\lambda^{2k}}{(2k)!} = (e^\lambda + e^{-\lambda} - 2)/2.$$

Skleisdami eksponentes eilute įsitikiname, kad dešinėje tapatybės pusėje gauname kairėje pusėje parašytą sumą.

I.2.81. a) Tikėtinumo funkcija

$$\begin{aligned} L(\boldsymbol{\theta}) = & \frac{1}{(\sqrt{2\pi}\sigma_1)^n} \frac{1}{(\sqrt{2\pi}\sigma_2)^m} \exp\left\{-\frac{1}{2\sigma_1^2} \sum_i X_i^2 + \frac{\mu_1}{\sigma_1^2} \sum_i X_i - \right. \\ & \left. \frac{1}{2\sigma_2^2} \sum_i Y_i^2 + \frac{\mu_2}{\sigma_2^2} \sum_i Y_i - \frac{n\mu_1^2}{2\sigma_1^2} - \frac{m\mu_2^2}{2\sigma_2^2}\right\} \end{aligned}$$

priklauso keturparametrei eksponentinio tipo skirstinių šeimai. Parametro kitimo sritis turi vidinių taškų. Statistika \mathbf{T} yra pilnoji ir pakankamoji.

b) $\mathbf{E}_\theta(\bar{X} - \bar{Y}) \equiv 0$, tačiau statistika $\bar{X} - \bar{Y} \neq 0$ b. v.

c) $\mathbf{E}_{(\theta)}(s_1^2 - s_2^2) \equiv 0$, tačiau statistika $s_1^2 - s_2^2 \neq 0$ b. v., čia $s_1^2 = \sum_i (X_i - \bar{X})^2 / (n-1)$, $s_2^2 = \sum_i (Y_i - \bar{Y})^2 / (m-1)$. Imdami statistiką \mathbf{T}^* , gauname triparametrė eksponentinio tipo skirstinių šeimą, kai parametru kitimo sritis turi vidinių taškų. Statistika \mathbf{T}^* yra pilnoji ir pakankamoji.

I.2.82. Tikėtinumo funkcija

$$\begin{aligned} L(\boldsymbol{\theta}) = & \frac{1}{(\sqrt{2\pi(1-\rho^2)}\sigma^1\sigma^2)^n} \exp\left\{-\frac{1}{2(1-\rho^2)} \left[\frac{1}{\sigma_1^2} \sum_i X_i^2 - \frac{2\mu_1}{\sigma_1^2} \sum_i X_i + \right. \right. \\ & \left. \left. \frac{1}{\sigma_2^2} \sum_i Y_i^2 - \frac{2\mu_2}{\sigma_2^2} \sum_i Y_i + \frac{4\rho}{\sigma_1\sigma_2} (\mu_1 \sum_i Y_i + \mu_2 \sum_i X_i) + b(\boldsymbol{\theta}) \right] \right\} \end{aligned}$$

priklauso penkiaparametrei eksponentinio tipo skirstinių šeimai. Parametro kitimo sritis turi vidinių taškų. Statistika \mathbf{T} yra pilnoji ir pakankamoji parametru $\boldsymbol{\theta}$ statistika.

I.2.83. Parametro $\theta = (\mu_1, \mu_2)^T$ pilnoji ir pakankamoji statistika yra $\mathbf{T} = (\bar{X}, \bar{Y})^T$. Gauname

$$\hat{\gamma} = \mathbf{E}[\mathbf{1}_{(-\infty, 0)}(Y_1 - X_1) | \bar{X}, \bar{Y}] = \mathbf{P}\{Y_1 < X_1 | \bar{X}, \bar{Y}\} = \mathbf{P}\{Y_1 - \bar{Y} < X_1 - \bar{X} + \bar{X} - \bar{Y} | \bar{X}, \bar{Y}\}.$$

Statistikos $X_1 - \bar{X}, Y_1 - \bar{Y}, \bar{X}, \bar{Y}$ nepriklausomos; $X_1 - \bar{X} \sim N(0, 1 - 1/n)$, $Y_1 - \bar{Y} \sim N(0, 1 - 1/m)$. Gauname

$$\hat{\gamma} = \Phi((\bar{X} - \bar{Y}) / \sqrt{2 - 1/n - 1/m}).$$

I.2.84. Parametro $\theta = (\lambda_1, \lambda_2)^T$ pilnoji ir pakankamoji statistika yra

$$\mathbf{T} = (\sum_i X_i, \sum_i Y_i)^T = (T_1, T_2)^T.$$

Gauname

$$\hat{\gamma} = \mathbf{P}\{Y_1 < X_1 | T_1, T_2\} = \mathbf{P}\left\{\frac{Y_1}{T_2} < \frac{X_1}{T_1} \frac{T_1}{T_2} | T_1, T_2\right\}.$$

Statistikos $X_1/T_1, Y_1/T_2, T_1, T_2$ nepriklausomos;

$$X_1/T_1 \sim Be(1, m-1), \quad Y_1/T_2 \sim Be(1, n-1).$$

Pažymėkime $Z = T_1/T_2$. Tarkime, $Z \leq 1$. Tada

$$\begin{aligned} \hat{\gamma} &= (m-1)(n-1) \int_0^1 (1-u)^{n-2} \int_0^{uZ} (1-v)^{m-2} dv du = \\ &= (n-1) \int_0^1 (1-u)^{n-2} (1 - (1-uZ)^{m-1}) du = \\ &= 1 - (n-1) \int_0^1 (1-u)^{n-2} (1-uZ)^{m-1} du. \end{aligned}$$

Kai $Z > 1$, gauname

$$\begin{aligned} \hat{\gamma} &= 1 - (m-1)(n-1) \int_0^1 (1-v)^{m-2} \int_0^{v/Z} (1-u)^{n-2} du dv = \\ &= 1 - (m-1) \int_0^1 (1-v)^{m-2} (1 - (1-v/Z)^{n-1}) dv = \\ &= (m-1) \int_0^1 (1-v)^{m-2} (1-v/Z)^{n-1} dv. \end{aligned}$$

I.2.85. Parametro θ pilnoji ir pakankamoji statistika yra $X_{(n)}$, kurios tankis

$$f_n(x|\theta) = nx^{n-1}/\theta^n, \quad 0 < x < \theta.$$

Reikia funkcijos h atžvilgiu išspręsti funkcinę lygtį (žr. [2], 3.3 skyrelį)

$$\mathbf{E}_\theta h(X_{(n)}) \equiv \gamma(\theta).$$

Išbandome funkciją $\gamma(X_{(n)})$

$$\begin{aligned}\mathbf{E}_\theta \gamma(X_{(n)}) &= \frac{n}{\theta^n} \int_0^\theta \gamma(x) x^{n-1} dx = \frac{\gamma(x)x^n}{\theta^n} \Big|_0^\theta - \\ &\quad \frac{1}{\theta^n} \int_0^\theta \gamma'(x) x^n dx = \gamma(\theta) - \mathbf{E}_\theta(X_{(n)}\gamma'(X_{(n)}))/n.\end{aligned}$$

Parametro $\gamma(\theta)$ NMD įvertinys

$$\hat{\gamma} = \gamma(X_{(n)}) + X_{(n)}\gamma'(X_{(n)})/n, \quad \mathbf{E}_\theta \hat{\gamma} = \gamma(\theta).$$

1.2.86. Tikėtinumo funkcija

$$L(\alpha, \beta, \sigma^2) = \frac{1}{(\sqrt{2\pi}\sigma)^n} \exp\left\{-\frac{1}{2\sigma^2} \sum_i Y_i^2 + \frac{\alpha}{\sigma^2} \sum_i Y_i + \frac{\beta}{\sigma^2} \sum_i Y_i x_i - \frac{1}{2\sigma^2} \sum_i (\alpha + \beta x_i)^2\right\}$$

priklauso triparametrei eksponentinio tipo skirstinių šeimai. Parametro kitimo sritis turi vidinių taškų. Statistika T yra pilnoji ir pakankamoji.

1.2.87. Tegu gautoji imtis $(X_1, \dots, X_n)^T$. Pažymėkime $Y_1 = X_1, Y_i = X_i - X_{i-1}, i = 2, \dots, n$. Tada Y_1, \dots, Y_n yra paprastojo imtis a. d. $Y \sim N(\varphi, \sigma^2)$. Parametru φ ir σ^2 NMD įvertiniai yra $\hat{\varphi} = \bar{Y} = X_n/n; \hat{\sigma}^2 = \sum_{i=1}^n (X_i - X_{i-1} - \hat{\varphi})^2/(n-1), X_0 = 0$.

1.2.88. a) Tikėtinumo funkcija

$$L(\theta) = \left(\prod_{i=1}^n a_{X_i}\right) \exp\left\{\sum_{i=1}^n X_i \ln \theta - n \ln f(\theta)\right\}$$

priklauso vienparametrei eksponentinio tipo skirstinių šeimai. Statistika $T = \sum_i X_i$ yra pilnoji ir pakankamoji. Jos skirstinys yrs tokio paties eksponentinio tipo: kai $k = 2c, 2c+1, \dots$ ir $n = 2, 3, \dots$, gauname

$$\mathbf{P}_\theta\{X_1 + X_2 = k\} = \mathbf{P}_\theta\{X_1 = i, X_2 = k-i\} =$$

$$\sum_{i=c}^{k-c} \frac{a_i \theta^i}{f(\theta)} \frac{a_{k-i} \theta^{k-i}}{f(\theta)} = \frac{\theta^k}{f^2(\theta)} \sum_{i=c}^{k-c} a_i a_{k-i} = \frac{b_k \theta^k}{f^2(\theta)}.$$

Naudodami indukciją gausime, kad tokio tipo skirstinys galioja ir kai $n > 2$.

b) Funkcijos h atžvilgiu sprendžiame funkcinę lygtį

$$\mathbf{E}_\theta h(T) = \sum_{k=nc}^{\infty} b_k \theta^k / (f(\theta))^n \equiv \theta^r, \quad \theta > 0.$$

Padauginę dešiniąją tapatybės pusę iš vieneto, gauname

$$\mathbf{E}_\theta h(T) = \sum_{k=nc}^{\infty} b_k \theta^k / (f(\theta))^n \equiv \theta^r \sum_{j=nc}^{\infty} b_j \theta^j / (f(\theta))^n$$

ir, sulyginę koeficientus prie vienodų laipsnių θ^k , matome, kad parametru θ^r

NMD ivertinys yra $U_r(T)$, kai $U_r(T) = 0$, jei $T < nc+r$, $U_r(T) = b_{T-r}/b_T$, jei $T \geq nc+r$.

c) Dispersija $\mathbf{V}_\theta(U_r(T)) = \mathbf{E}_\theta(U_r(T))^2 - (\mathbf{E}_\theta(U_r(T)))^2 = \mathbf{E}_\theta(U_r(T))^2 - \theta^{2r}$. Nepaslinktasis dispersijos ivertinys yra $(U_r(T))^2 - U_{2r}(T)$.

I.2.89. $\mathbf{E}_{\mu,\sigma}(\bar{X})^2 = \mu^2 + \sigma^2/n$, $\mathbf{V}_{\mu,\sigma}(\bar{X})^2 = (2\sigma^2/n)(2\mu^2 + \sigma^2/n)$; NMD ivertinys $\hat{\vartheta} = \bar{X}^2 - s^2/n$, $\mathbf{V}_{\mu,\sigma}\hat{\vartheta} = (2\sigma^2/n)(2\mu^2 + \sigma^2/(n(n-1)))$.

I.2.90. Tegu $\boldsymbol{\theta} = (\mu_x, \mu_y, \sigma_x^2, \sigma_y^2)$ ir $\bar{X}, \bar{Y}, s_x^2, s_y^2$ – parametru $\mu_x, \mu_y, \sigma_x^2, \sigma_y^2$ NMD ivertinai. Tada

$$\text{a) } \mathbf{E}_\theta(\bar{X} - \bar{Y}) = \mu_x - \mu_y; \quad (m-1)s_x^2/\sigma_x^2 \sim \chi_{m-1}^2, \quad (n-1)s_y^2/\sigma_y^2 \sim \chi_{n-1}^2;$$

$$\frac{\sigma_y^2}{\sigma_x^2} \frac{s_x^2}{s_y^2} \sim F_{m-1, n-1}, \quad \left(\frac{\sigma_y}{\sigma_x} \right)^r \mathbf{E}_\theta \left(\frac{s_x}{s_y} \right)^r = \mathbf{E} \left(F_{m-1, n-1}^{r/2} \right).$$

Parametru $\mu_x - \mu_y$ ir $(\sigma_x/\sigma_y)^r$ NMD ivertiniai yra $\bar{X} - \bar{Y}$ ir $(s_x/s_y)^r / (\mathbf{E}(F_{m-1, n-1}^{r/2}))$;

b) $s^2 = [s_x^2(m-1) + s_y^2(n-1)] \sim \sigma_x^2 \chi_\nu^2, \nu = m+n-2$; $\mathbf{E}_\theta(s^2/\nu) = \sigma_x^2$; statistika $(\bar{X} - \bar{Y}) / (s\sqrt{1/m+1/n})$ turi necentrinę Stjudento skirstinį su ν laisvės laipsniu ir necentriškumo parametru $(\mu_x - \mu_y) / (\sigma_x \sqrt{1/m+1/n})$;

$$\mathbf{E}_\theta \frac{\bar{X} - \bar{Y}}{s} = \frac{\mu_x - \mu_y}{\sigma_x} \sqrt{\nu} \frac{\Gamma((\nu-1)/2)}{\Gamma(\nu/2)}.$$

Parametru σ_x^2 ir $(\mu_x - \mu_y)/\sigma_x$ NMD ivertiniai yra s^2 ir

$$[(\bar{X} - \bar{Y})/s] / (\sqrt{\nu} \Gamma((\nu-1)/2) / \Gamma((\nu)/2));$$

c) $[m\bar{X} + \gamma n\bar{Y}] / (m+n\gamma)$;

d) pakankamoji statistika $(\bar{X}, \bar{Y}, s_x^2, s_y^2)^T$ nėra pilnoji: statistikos $\bar{X} - \bar{Y}$ vidurkis tapačiai lygus 0, tačiau statistika $\bar{X} - \bar{Y}$ nėra lygi nuliui b. v.

e), f) $\mathbf{P}_\theta\{X_1 \leq Y_1\} = \mathbf{P}_\theta\{X_1 - Y_1 \leq 0\} = 1/2$, nes $X_1 - Y_1 \sim N(0, \sigma_x^2 + \sigma_y^2)$; tikimybės NMD ivertinys yra 1/2.

I.2.91. Pažymėkime $S_x = \sum_i (X_{(i)} - X_{(1)})$, $S_y = \sum_i (Y_{(i)} - Y_{(1)})$. Tada:

a) $\theta = a_x - a_y$, $\hat{\theta} = X_{(1)} - Y_{(1)} - S_x/(m(m-1)) + S_y/(n(n-1))$; $\gamma = \theta_x/\theta_y$, $\hat{\gamma} = S_x(n-2)/(S_y(m-1))$;

b) $\hat{\theta}_x = (S_x + S_y)/(m+n-2)$; $\eta = (a_x - a_y)/\theta_x$, $\hat{\eta} = (X_{(1)} - Y_{(1)})(m+n-3)/(S_x + S_y) - (n-m)/(mn)$;

c) pakankamoji statistika $(X_{(1)}, Y_{(1)}, S_x, S_y)^T$ nėra pilnoji.

I.2.3 skyrelis

I.2.92. Pasinaudokite tokiu algebro faktu. Tegu \mathbf{A} ir \mathbf{D} – kvadratinės matricos ir $|\mathbf{D}| \neq 0$. Tada determinantas

$$\begin{vmatrix} \mathbf{A} & \mathbf{B} \\ \mathbf{C} & \mathbf{D} \end{vmatrix}$$

yra lygus $|\mathbf{D}||\mathbf{A} - \mathbf{BD}^{-1}\mathbf{C}|$. Suskaidykime matricą \mathbf{I} į blokus

$$\begin{vmatrix} I_{11} & \mathbf{B}^T \\ \mathbf{B} & \mathbf{D} \end{vmatrix}$$

Tada

$$I^{11} = \frac{|\mathbf{D}|}{|\mathbf{I}|} = \frac{|\mathbf{D}|}{|\mathbf{D}|(I_{11} - \mathbf{B}^T \mathbf{D}^{-1} \mathbf{B})} = \frac{1}{I_{11} - \mathbf{B}^T \mathbf{D}^{-1} \mathbf{B}} \geq \frac{1}{I^{11}}.$$

I.2.93. $\mathbf{V}_p \hat{p} \geq pq/n; \mathbf{V}_p(\hat{pq}) \geq pq(q-p)^2/n; \mathbf{V}_p(\hat{p^2}) \geq 4p^3q/n.$

I.2.94. Tikėtinumo funkcija

$$L = L(p) = C_n^S e^{S \ln(p/(1-p)) + n \ln(1-p)}, \quad S = X_1 + \dots + X_n \sim B(n, p).$$

Tegu

$$Y_1 = \frac{L'}{L} = \frac{S - np}{pq}, \quad Y_2 = \frac{L''}{L} = \frac{(S - np)^2}{p^2 q^2} - \frac{(S - np)(1 - 2p)}{p^2 q^2} - \frac{n}{pq}.$$

Randame a. v. $\mathbf{Y} = (Y_1, Y_2)^T$ kovariacijų matricą $\mathbf{J} = [J_{ij}]_{2 \times 2}$.

$$J_{11} = \mathbf{E}_p Y_1^2 = n/(pq), \quad J_{12} = \mu_3/(p^3 q^3) - n(1 - 2p)/(p^2 q^2) = 0,$$

$$\text{nes } \mu_3 = \mathbf{E}_p(S - \mathbf{E}_p S)^3 = n\mathbf{E}_p(X_i - \mathbf{E}_p X_i)^3 = npq(1 - 2p).$$

$$J_{22} = \frac{\mu_4}{p^4 q^4} + \frac{\mu_2(1 - 2p)^2}{p^4 q^4} + \frac{n^2}{p^2 q^2} - 2 \frac{\mu_3(1 - 2p)}{p^4 q^4} - 2 \frac{n\mu_2}{p^3 q^3} = \frac{2n(n - 1)}{p^2 q^2},$$

$$\text{nes } \mu_4 = \mathbf{E}_p(S - \mathbf{E}_p S)^4 = n\mathbf{E}_p(X_i - \mathbf{E}_p X_i)^4 + 3n(n - 1)(\mathbf{V}_p X_i)^2 = npq(1 - 3pq) + 3n(n - 1)p^2 q^2.$$

Atvirkštinės matricos $\mathbf{J}^{-1} = [J^{ij}]_{2 \times 2}$ elementai $J^{11} = pq/n, J^{12} = J^{21} = 0, J^{22} = p^2 q^2/(2n(n - 1)).$ Funkcijų $\gamma_1(p) = p^2$ ir $\gamma_2(p) = pq$ išvestinių vektoriai $\Gamma_1 = (2p, 2)^T$ ir $\Gamma_2 = (1 - 2p, -2)^T.$ Gauname patikslintas Rao ir Kramerio nelygybes

$$\mathbf{V}_p \hat{\gamma}_1 \geq \Gamma_1^T \mathbf{J}^{-1} \Gamma_1 = \frac{4p^3 q}{n} + \frac{2p^2 q^2}{n(n - 1)},$$

$$\mathbf{V}_p \hat{\gamma}_2 \geq \Gamma_2^T \mathbf{J}^{-1} \Gamma_2 = \frac{(1 - 2p)^2 pq}{n} + \frac{2p^2 q^2}{n(n - 1)}.$$

I.2.95. Parametru NMD įvertiniai (žr. **I.2.53** pratimą) yra $\hat{p} = S/n, \hat{p^2} = S(S - 1)/[n(n - 1)], \hat{pq} = S(n - S)/[n(n - 1)].$ $\mathbf{V}_p \hat{p} = pq/n$ (Rao ir Kramerio nelygybė virsta lygybe).

$$\mathbf{V}_p(\hat{p^2}) = \mathbf{E}_p(S(S - 1))^2 / (n(n - 1))^2 - p^4.$$

Faktorialiniai momentai $\nu_k = \mathbf{E}_p S^{[k]} = p^k n^{[k]}, k = 1, 2, \dots.$ Pertvarkome $(S(S - 1))^2 = S^{[4]} + 4S^{[3]} + 2S^{[2]}.$ Tada

$$\mathbf{V}_p(\hat{p^2}) = \frac{\nu_4 + 4\nu_3 + 2\nu_2}{(n(n - 1))^2} - p^4 = \frac{4p^3 q}{n} + \frac{2p^2 q^2}{n(n - 1)}.$$

Analogiškai $S^2(n - S)^2 = S^{[2]}(n - S)^{[2]} + S^{[2]}(n - S) + S(n - S)^{[2]} + S(n - S),$ $\nu_{kl} = \mathbf{E}(S^{[k]}(n - S)^{[l]}) = p^k q^l n^{[k+l]}, k, l = 1, 2, \dots$

Randame

$$\mathbf{V}_p(\hat{p}q) = \frac{\nu_{22} + \nu_{21} + \nu_{12} + \nu_{11}}{(n(n-1))^2} - p^2q^2 = \frac{(1-2p)^2pq}{n} + \frac{2p^2q^2}{n(n-1)}.$$

Abiem atvejais patikslinta Rao ir Kramerio nelygybė virsta lygybe.

I.2.96. Dispersijos ribos Rao ir Kramerio nelygybėje $\mathbf{V}_\lambda \hat{\lambda} \geq \lambda/n$; $\mathbf{V}_\lambda(\hat{\lambda}^2) \geq 4\lambda^3/n$; $\gamma = e^{-\lambda}$, $\mathbf{V}_\lambda(\hat{\gamma}) \geq \lambda e^{-2\lambda}/n$.

I.2.97. Tikėtinumo funkcija

$$L = L(\lambda) = (1/\prod_i X_i!) e^{S \ln(\lambda) - n \ln(\lambda)}, \quad S = X_1 + \dots + X_n \sim \mathcal{P}(\lambda).$$

Tegu

$$Y_1 = \frac{L'}{L} = \frac{S - n\lambda}{\lambda}, \quad Y_2 = \frac{L''}{L} = \frac{(S - n\lambda)^2}{\lambda^2} - \frac{(S - n\lambda)}{\lambda^2} - \frac{n}{\lambda}.$$

Randame a. v. $\mathbf{Y} = (Y_1, Y_2)^T$ kovariacijų matrica $\mathbf{J} = [J_{ij}]_{2 \times 2}$.

$$J_{11} = \mathbf{E}_\lambda Y_1^2 = n/\lambda, \quad J_{12} = \mu_3/\lambda^3 - \mu_2/\lambda^3 = 0,$$

nes $\mu_3 = \mathbf{E}_\lambda(S - \mathbf{E}_\lambda S)^3 = n\lambda$, $\mu_2 = \mathbf{E}_\lambda(S - \mathbf{E}_\lambda S)^2 = n\lambda$.

Skaičiuojant centrinus momentus μ_k patogu juos išreikšti faktorialiniai momentai $\nu_k = \mathbf{E}_\lambda S^{[k]} = n^k \lambda^k$, $k = 1, 2, \dots$;

$$\mu_3 = \nu_3 - 3\nu_2\nu_1 + 3\nu_2 + 2\nu_1^3 - 3\nu_1^2 + \nu_1 = n\lambda.$$

$$J_{22} = \frac{\mu_4}{\lambda^4} + \frac{\mu_2}{\lambda^4} + \frac{n^2}{\lambda^2} - 2\frac{\mu_3}{\lambda^4} - 2\frac{n\mu_2}{\lambda^3} = \frac{2n^2}{\lambda^2},$$

nes $\mu_4 = \nu_4 - 4\nu_3\nu_1 + 6\nu_3 + 6\nu_2\nu_1^2 - 12\nu_2\nu_1 + 7\nu_2 - 3\nu_1^4 + 6\nu_1^3 - 4\nu_1^2 + \nu_1 = 3n^2\lambda^2 + n\lambda$.

Atvirkštinės matricos $\mathbf{J}^{-1} = [J^{ij}]_{2 \times 2}$ elementai $J^{11} = \lambda/n$, $J^{12} = J^{21} = 0$, $J^{22} = \lambda^2/(2n^2)$. Funkcijų $\gamma_1 = \lambda^2$ ir $\gamma_2 = e^{-\lambda}$ išvestinių vektoriai $\Gamma_1 = (2\lambda, 2)^T$ ir $\Gamma_2 = (-e^{-\lambda}, e^{-\lambda})^T$. Gauname patikslintas Rao ir Kramerio nelygybes

$$\mathbf{V}_\lambda \hat{\gamma}_1 \geq \Gamma_1^T \mathbf{J}^{-1} \Gamma_1 = \frac{4\lambda^3}{n} + \frac{2\lambda^2}{n^2},$$

$$\mathbf{V}_\lambda \hat{\gamma}_2 \geq \Gamma_2^T \mathbf{J}^{-1} \Gamma_2 = \frac{\lambda e^{-2\lambda}}{n} + \frac{\lambda^2 e^{-2\lambda}}{2n^2}.$$

I.2.98. Parametru NMD įvertinai (žr. **I.2.49**, **I.2.50** pratimus) yra $\hat{\lambda} = S/n$, $\hat{\lambda}^2 = S(S-1)/n^2$, $\gamma = e^{-\lambda}$, $\hat{\gamma} = (1-1/n)^S$.

$\mathbf{V}_\lambda \hat{\lambda} = \lambda/n$ (Rao ir Kramerio nelygybė virsta lygybe).

$$\mathbf{V}_\lambda \hat{\lambda}^2 = \mathbf{E}(S(S-1))^2/n^4 - \lambda^4.$$

Pertvarkę analogiškai **I.2.95** pratimui, gauname

$$\mathbf{V}_\lambda \hat{\lambda}^2 = (\nu_4 + 4\nu_3 + 2\nu_2 - n^4\lambda^4)/n^4 = \frac{4\lambda^3}{n} + \frac{2\lambda^2}{n^2}.$$

Dispersija sutampa su patikslintos Rao ir Kramerio nelygybės riba.

$$\mathbf{E}_\lambda \hat{\gamma} = \sum_{k=0}^{\infty} (1 - 1/n) 2k \frac{(n\lambda)^k}{k!} e^{-n\lambda} = e^{-\lambda(1/n-2)},$$

$$\mathbf{V}_\lambda \hat{\gamma} = e^{-2\lambda} (e^{\lambda/n} - 1) = \frac{e^{-2\lambda}\lambda}{n} + \frac{e^{-2\lambda}\lambda^2}{n^2} + O(\frac{1}{n^3}).$$

Įvertinio $\hat{\gamma}$ dispersija skiriasi nuo klasikinės Rao ir Kramerio nurodytos ribos eilės $O(1/n^2)$ nariu; patikslinus nelygybę panaudojant antrają L išvestinę, skirtumas yra $O(1/n^3)$. Matyt, nelygybę galima dar patikslinti panaudojant aukštesnių eilių išvestines.

- I.2.99.** a) Kadangi $\sqrt{n}(\bar{X} - \lambda) \xrightarrow{d} Y \sim N(0, \lambda)$, tai remiantis delta metodu $\sqrt{n}(\tilde{\gamma} - \gamma) \xrightarrow{d} Z \sim N(0, \lambda e^{-2\lambda})$ ir $\lambda[\gamma'(\lambda)]^2/(i(\gamma)) = 1$; $\tilde{\gamma} = \hat{\gamma} + O_P(1/n)$.
 b) Reikia rasti tokią funkciją $B(\lambda)$, kad

$$\sqrt{n}(e^{-\bar{X}} - e^{-\lambda} - B(\lambda)\dot{\ell}(\lambda)/n) \xrightarrow{P} 0.$$

Kadangi $\dot{\ell}(\lambda)/n = (\bar{X} - \lambda)/\lambda$, tai, imdami $B(\lambda) = -\lambda e^{-\lambda}$, gausime

$$\sqrt{n}(e^{-\bar{X}} - e^{-\lambda} + e^{-\lambda}(\bar{X} - \lambda)) = e^{-\lambda}\sqrt{n}(\bar{X} - \lambda)[(e^{-(\bar{X}-\lambda)} - 1)/(\bar{X} - \lambda) + 1].$$

Kadangi $\bar{X} \xrightarrow{P} \lambda$, tai laužtiniuose skliaustuose parašytas pagal tikimybę artėja į 0. Ivertinys $e^{-\bar{X}}$ asimptotiškai efektyvus pagal Rao.

- I.2.100.** a) $\hat{\mu} = \bar{X}$, $\hat{\mu}^2 = \bar{X}^2 - \sigma^2/n$; $\mathbf{V}_\mu \hat{\mu} = \sigma^2/n$, $\mathbf{V}_\mu \hat{\mu}^2 = \mathbf{E}_\mu((\bar{X} - \mu)^2 + 2\mu(\bar{X} - \mu) - \sigma^2/n)^2 = 4\mu^2\sigma^2/n + 2\sigma^4/n^2$.
 b) $\mathbf{V}_\mu \hat{\mu} \geq \sigma^2/n$, $\mathbf{V}_\mu \hat{\mu}^2 \geq 4\mu^2\sigma^2/n$. Ivertinys $\hat{\mu} = \bar{X}$ yra efektyvusis. Ivertinys $\hat{\mu}^2 = \bar{X}^2 - \sigma^2/n$ asimptotiškai efektyvus pagal Rao, nes

$$\sqrt{n}(\bar{X}^2 - \mu^2 - B(\mu)(\bar{X} - \mu)/\sigma^2) = \sqrt{n}(\bar{X} - \mu)(\bar{X} + \mu - B(\mu)/\sigma^2) \xrightarrow{P} 0,$$

kai $B(\mu) = 2\mu\sigma^2$.

c) Tikėtinumo funkcija

$$L = L(\mu) = (\sqrt{2\pi}\sigma)^{-n} \exp\left\{-\sum_{i=1}^n X_i^2/(2\sigma^2)\right\} \exp\{n\mu\bar{X}/\sigma^2 - n\mu^2/(2\sigma^2)\}.$$

Tegu

$$Y_1 = \frac{L'}{L} = \frac{n}{\sigma^2}(\bar{X} - \mu), \quad Y_2 = \frac{L''}{L} = \frac{n^2}{\sigma^4}(\bar{X} - \mu)^2 - \frac{n}{\sigma^2}.$$

Randame a. v. $\mathbf{Y} = (Y_1, Y_2)^T$ kovariacijų matricą $\mathbf{J} = [J_{ij}]_{2 \times 2}$.

$$J_{11} = \frac{n^2}{\sigma^4} \mathbf{E}_\mu(\bar{X} - \mu)^2 = \frac{n}{\sigma^2}, \quad J_{12} = J_{21} = 0,$$

$$J_{22} = \frac{n^4}{\sigma^8} \mathbf{E}_\mu(\bar{X} - \mu)^4 - 2\frac{n^3}{\sigma^6} \mathbf{E}_\mu(\bar{X} - \mu)^2 + \frac{n^2}{\sigma^4} = \frac{2n^2}{\sigma^4}.$$

Atvirkštinės matricos \mathbf{J}^{-1} elementai $J^{11} = \sigma^2/n, J^{12} = J^{21} = 0, J^{22} = \sigma^4/(2n^2)$. Funkcijos μ^2 išvestinių vektorius $\Gamma = (2\mu, 2)^T$. Gauname patikslintą Rao ir Kramerio nelygybę

$$\mathbf{V}_\mu \hat{\mu}^2 \geq \Gamma^T \mathbf{J}^{-1} \Gamma = \frac{4\mu^2 \sigma^2}{n} + \frac{2\sigma^4}{n^2}.$$

NMD jvertinio $\hat{\mu}^2$ dispersija sutampa su patikslinta dispersijos riba.

I.2.101. a) $\hat{\sigma}^2 = s_0^2 = \sum_i (X_i - \mu)^2/n, \mathbf{V}_\sigma s_0^2 = 2\sigma^4/n; \hat{\sigma} = s_0/M_n, M_n = \sqrt{2/\pi} \Gamma((n+1)/2)/\Gamma(n/2)$ (žr. I.2.63 pratimą), $\mathbf{V}_\sigma \hat{\sigma} = \sigma^2(1/M_n^2 - 1) \approx \sigma^2(1/(2n) + 1/(4n^2))$.

b) $\mathbf{V}_\sigma \hat{\sigma}^2 \geq 2\sigma^4/n, \mathbf{V}_\sigma \hat{\sigma} \geq \sigma^2/(2n)$. Ivertinys s_0^2 efektyvus, o $\hat{\sigma}$ asimptotiškai efektyvus.

I.2.102. $\mathbf{V}_{\mu,\sigma}(\hat{\mu}, \hat{\sigma}^2)^T \geq \mathbf{I}^{-1} = [I^{kl}]_{2 \times 2}; I^{11} = \sigma^2/n, I^{12} = I^{21} = 0, I^{22} = 2\sigma^4/n$.

I.2.103. a) $\hat{x}_P = \bar{X} + z_{PS}/M_{n-1}, \mathbf{V}_{\mu,\sigma} \hat{x}_P = \sigma^2/n + z_P^2 \sigma^2(1/M_{n-1}^2 - 1)$.

b) $\mathbf{V}_{\mu,\sigma} \hat{x}_P \geq \sigma^2/n + z_P^2 \sigma^2/(2n)$.

I.2.104.

$$\begin{aligned} i(\theta) &= -\mathbf{E}_\theta \left(\frac{\partial^2 \ln f(X|\theta)}{\partial \theta^2} \right) = \mathbf{E} e^{-(X-\theta)} = \int_\theta^{+\infty} e^{-2(x-\theta)} \exp(-e^{-(x-\theta)}) = \\ &= |e^{-(x-\theta)}| = y; dx = dy/y \\ &= - \int_1^0 y^2 e^{-y} dy/y = \int_0^1 y e^{-y} dy = - \int_0^1 y d(e^{-y}) = -y e^{-y}|_0^1 + \int_0^1 e^{-y} dy = \\ &= 1/e - 1/e + 1 = 1; \quad I(\theta) = ni(\theta) = n. \end{aligned}$$

Nagrinėkime parametrą $\alpha = \exp\{-\theta\}$. Gauname $\theta = -\ln \alpha$

$$\begin{aligned} i(\alpha) &= -\mathbf{E} \left(\left(\dot{\ell}_\theta \dot{\theta}_\alpha \right)'_\alpha \right) = -\mathbf{E} \left(\ddot{\ell}_{\theta\theta} \dot{\theta}_\alpha \dot{\theta}_\alpha + \dot{\ell}_\theta \ddot{\theta}_{\alpha\alpha} \right) = \\ &= \left(\dot{\theta}_\alpha \right)^2 \left(-\mathbf{E} \left(\ddot{\ell}_{\theta\theta} \right) \right) + \ddot{\theta}_{\alpha\alpha} \left(-\mathbf{E} \left(\dot{\ell}_\theta \right) \right) = \left(\dot{\theta}_\alpha \right)^2 i(\theta) \\ &\quad \dot{\theta}_\alpha = -\frac{1}{\alpha} \\ I(e^{-\theta}) &= n \left(-\frac{1}{\alpha} \right)^2 = n/e^{-2\theta}. \end{aligned}$$

I.2.105. a) $\mathbf{E}_\beta \hat{\beta} = \beta$; b) $\mathbf{V}_\beta \hat{\beta} = \beta^2/n$; kadangi $I(\beta) = n/\beta^2$, tai jvertinio $\hat{\beta}$ dispersija lygi Rao ir Kramerio nelygybėje nurodytai ribai.

I.2.106. a) n/σ^2 ; b) $n/(2\sigma^4)$; c) $2n/\sigma^2$; d) $3n/\sigma^2$; e) $\mathbf{I}(\theta) = [I_{kl}]_{2 \times 2}, I_{11} = n/\sigma^2, I_{22} = n/(2\sigma^4), I_{12} = I_{21} = 0$; f) $nk/(qp^2)$; g) $\mathbf{I}(\alpha, \gamma) = [I_{ij}]_{2 \times 2}; I_{11} = n\lambda/\alpha^2, I_{12} = I_{21} = -n/\alpha, I_{22} = n[\ln \Gamma(\lambda)]''$; h) $\mathbf{I}(\alpha, \beta) = [I_{ij}]_{2 \times 2}; I_{11} = n[\ln B(\alpha, \beta)]''_{\alpha^2}, I_{12} = I_{21} = n[\ln B(\alpha, \beta)]''_{\alpha\beta}, I_{22} = n[\ln B(\alpha, \beta)]''_{\beta^2}$.

I.2.107. a) $2\sqrt{\lambda}$; b) $\arcsin(2p-1)$; c) $\sqrt{\gamma} \ln \theta$.

- I.2.108.** a) $\mathbf{I}(\mu, \sigma) = [I_{kl}]_{2 \times 2}; I_{11} = I_{22} = 2\sigma^2; I_{12} = I_{21} = 0;$ b) $\mathbf{I}(\mu, \theta) = [I_{kl}]_{2 \times 2}; I_{11} = 1/\theta^2, I_{12} = I_{21} = (1 + \Gamma'(1))/\theta^2; I_{22} = (1 + 2\Gamma'(1) + \Gamma''(1))/\theta^2;$ c) $I_{11} = n/(3\theta^2), I_{12} = I_{21} = -\mu/(3\theta^3), I_{22} = 1/\theta^2 + 2\mu/\theta^3 + \mu^2/(3\theta^4);$ d) $I_{11} = (r+1)\sqrt{r+4}/(\sigma^2(r+3)\sqrt{r}), I_{22} = (1 + I_{11}/\sigma^2)/\sigma^2, I_{12} = I_{21} = I_{11}/\sigma.$

I.2.109. a) Aibė $\{x : f(x|\theta) > 0\}$ priklauso nuo $\theta.$ b) Parametru θ NMD įvertinys (žr. I.2.55 pratimą) yra $\hat{\theta} = (n+1)X_{(n)}/n, \mathbf{V}\hat{\theta} = \theta^2/((n+1)(n+2)).$

I.2.110. a) $\hat{\vartheta} = -X/\Gamma'(1); \mathbf{V}\hat{\vartheta} = \theta^2(\Gamma''(1) - \Gamma'^2(1))/\Gamma'^2(1) \geq I^{-1}(\theta) = \theta^2(2 + 2\Gamma'(1) + \Gamma''(1));$ b) $\hat{\vartheta} = (-1)^r X^r / \Gamma^{(r)}(1); \mathbf{V}(\hat{\vartheta}) = \theta^{2r}(\Gamma^{(2r)}(1) - [\Gamma^{(r)}(1)]^2) / [\Gamma^{(r)}(1)]^2 > I^{-1}(\theta^r) = \theta^{2r} r^2 / (1 + 2\Gamma'(1) + \Gamma''(1)).$

I.2.111. a) $\hat{\vartheta} = \exp\{t\bar{X} - t^2\sigma^2/2n\};$ b) $\mathbf{V}\hat{\vartheta} = \exp\{2t\mu\}(\exp\{t^2\sigma^2/n\} - 1) > I^{-1}(\vartheta) = \exp\{2t\mu\}\sigma^2 t^2/n.$ Rao ir Kramerio nelygybėje nurodyta riba nepasiekiamai. $\mathbf{V}\hat{\vartheta} - I^{-1}(\vartheta) = O(1/n^2).$ c) Įvertinys $\hat{\vartheta}$ asimptotiškai efektyvus.

I.2.112. Tikėtinumo funkcija

$$L(\lambda) = \left(\prod_i X_i\right)^{\eta-1} / [\Gamma(\eta)]^n \exp\left\{-\frac{1}{\lambda} \sum_{i=1}^n X_i - n\eta \ln \lambda\right\}, \quad \lambda > 0$$

priklauso vienparametrei eksponentinio tipo skirstinių šeimai. Statistika $T = \sum_i X_i \sim G(1/\lambda, n\eta)$ yra pilnoji ir pakankamoji statistika.

a) Parametru λ ir λ^2 NMD įvertiniai $\hat{\lambda} = T/(n\eta), \hat{\lambda}^2 = T^2/(n\eta(n\eta+1)).$ A. d. T pradiniai momentai $\alpha_k = \mathbf{E}_\lambda T^k = \lambda^k \Gamma(n\eta+k)/\Gamma(n\eta), k = 1, 2, \dots$ Gauname

$$\mathbf{E}_\lambda \hat{\lambda} = \lambda, \quad \mathbf{V}_\lambda \hat{\lambda} = \frac{\lambda^2}{n\eta}; \quad \mathbf{E}_\lambda \hat{\lambda}^2 = \lambda^2, \quad \mathbf{V}_\lambda \hat{\lambda}^2 = \frac{4\lambda^4}{n\eta} + \frac{2\lambda^4}{n\eta(n\eta+1)}.$$

b) Randame Fišerio informaciją

$$I(\lambda) = -\mathbf{E}_\lambda (\ln L(\lambda))'' = \mathbf{E}_\lambda (2T/\lambda^3 - n\eta/\lambda^2) = n\eta/\lambda^2.$$

Parametru λ ir λ^2 nepaslinktujų įvertinių dispersijų ribos Rao ir Kramerio nelygybėje yra

$$\mathbf{V}_\lambda(\hat{\lambda}) \geq \lambda^2/(n\eta), \quad \mathbf{V}_\lambda \hat{\lambda}^2 \geq 4\lambda^4/(n\eta).$$

c) Tegu

$$Y_1 = \frac{L'}{L} = \frac{T}{\lambda^2} - \frac{n\eta}{\lambda}, \quad Y_2 = \frac{L''}{L} = \frac{T^2}{\lambda^4} - 2\frac{T(n\eta+1)}{\lambda^3} + \frac{n\eta(n\eta+1)}{\lambda^2}.$$

Randame a. v. $\mathbf{Y} = (Y_1, Y_2)^T$ kovariacinę matricą

$$J_{11} = \mathbf{E}_\lambda \left(\frac{T^2}{\lambda^4} - 2\frac{Tn\eta}{\lambda^3} + \frac{(n\eta)^2}{\lambda^2} \right) = \frac{\alpha_2}{\lambda^4} - 2\frac{\alpha_1 n\eta}{\lambda^3} + \frac{(n\eta)^2}{\lambda^2} = \frac{n\eta}{\lambda^2},$$

$$J_{12} = \frac{\alpha_3}{\lambda^6} - 2\frac{\alpha_2(n\eta+1)}{\lambda^5} - \frac{\alpha_2 n\eta}{\lambda^5} + 3\frac{\alpha_1 n\eta(n\eta+1)}{\lambda^4} - \frac{(n\eta)^2(n\eta+1)}{\lambda^3} = 0;$$

$$J_{22} = \frac{\alpha_4}{\lambda^8} - 4\frac{\alpha_3(n\eta+1)}{\lambda^7} + 2\frac{\alpha_2(3n\eta+2)(n\eta+1)}{\lambda^6} -$$

$$4 \frac{\alpha_1 n \eta (n \eta + 1)^2}{\lambda^5} + \frac{(n \eta)^2 (n \eta + 1)^2}{\lambda^4} = \frac{2 n \eta (n \eta + 1)}{\lambda^4}.$$

Atvirkštinės matricos $\mathbf{J}^{-1} = [J^{ij}]_{2 \times 2}$ elementai $J^{11} = \lambda^2/(n \eta)$, $J^{12} = J^{21} = 0$, $J^{22} = \lambda^4/(2 n \eta (n \eta + 1))$. Funkcijos λ^2 išvestinių vektorius $\Gamma = (2\lambda, 2)^T$. Gauname patikslintą Rao ir Kramerio nelygybę

$$\mathbf{V}_\lambda \hat{\lambda}^2 \geq \Gamma^T \mathbf{J}^{-1} \Gamma = \frac{4\lambda^4}{n\eta} + \frac{2\lambda^4}{n\eta(n\eta+1)}.$$

Ivertinio $\hat{\lambda}^2$ dispersija lygi patikslintai Rao ir Kramerio nelygybės ribai.

I.2.113. Tikétinumo funkcija

$$L(\lambda) = \left(\prod_i X_i \right)^{\eta-1} / [\Gamma(\eta)]^n \exp\left\{ -\lambda \sum_{i=1}^n X_i + n\eta \ln \lambda \right\}, \quad \lambda > 0$$

priklauso vienparametrei eksponentinio tipo skirtinių šeimai. Statistika $T = \sum_i X_i \sim G(\lambda, n\eta)$ yra pilnoji ir pakankamoji statistika.

a) Parametru λ ir λ^2 NMD ivertiniai $\hat{\lambda} = (n\eta - 1)/T$, $\hat{\lambda}^2 = (n\eta - 1)(n\eta - 2)/T^2$. A. d. T pradiniai momentai $\alpha_k = \mathbf{E}_\lambda T^k = \lambda^{-k} \Gamma(n\eta - k)/\Gamma(n\eta)$, $k = 1, 2, \dots$ Gauname

$$\mathbf{E}_\lambda \hat{\lambda} = \lambda, \quad \mathbf{V}_\lambda \hat{\lambda} = \frac{\lambda^2}{n\eta - 2}; \quad \mathbf{E}_\lambda \hat{\lambda}^2 = \lambda^2, \quad \mathbf{V}_\lambda \hat{\lambda}^2 = 2\lambda^4 \frac{2n\eta - 5}{(n\eta - 3)(n\eta - 4)}, \quad n\eta > 4.$$

b) Randame Fišerio informaciją

$$I(\lambda) = -\mathbf{E}_\lambda (\ln L(\lambda))'' = n\eta/\lambda^2.$$

Parametru λ ir λ^2 nepaslinktujų ivertinių dispersijų ribos Rao ir Kramerio nelygybėje yra

$$\mathbf{V}_\lambda(\hat{\lambda}) \geq \lambda^2/(n\eta), \quad \mathbf{V}_\lambda \hat{\lambda}^2 \geq 4\lambda^4/(n\eta).$$

Ivertiniai néra efektyvūs, tačiau yra asymptotiskai efektyvūs.

I.2.114. $\mathbf{V}_\mu(T_{1n}) = \Phi(c - \mu)(1 - \Phi(c - \mu))/n$; $\mathbf{V}_\mu(T_{2n}) = [\Phi'(c - \mu)]^2/n + O(1/n\sqrt{n})$; $ASE = [\Phi'(c - \mu)]^2/(\Phi(c - \mu)(1 - \Phi(c - \mu)))$.

I.2.115. Gauname ivertinių dispersijas

$$\mathbf{V}_\sigma \hat{\sigma}_2 = \mathbf{V}_\sigma \left(\sum_i X_i^2 \right)^{1/2} = \sigma^2/(2n) + O(1/(n\sqrt{n})),$$

$$\mathbf{V}_\sigma \hat{\sigma}_1 = \mathbf{V}_\sigma (\sqrt{\pi/2} |X_i|)/n = \sigma^2(\pi - 2)/(2n).$$

Tada $E_{21} = 1/(\pi - 2)$.

I.2.116. a) $ASE = 4\mu^2/(4\mu^2 + \mu_4 - 1 + 4\mu_3\mu)$; b) $ASE \leq 1$, kai $\mu_3 = 0$; c) pvz., a. d. X tankio funkcija $f(x) = kx^2 \mathbf{I}_{(0, a)}(x)$, $a > 0$.

I.2.117. $ASE = 1$.

I.2.118. $b_{T_{1n}} = 0$, $b_{T_{2n}} = -\theta/(n+1)$; $ASE = 1$.

I.2.119. ASE = 2/3.

I.2.120. Randame

$$\sqrt{n}(\hat{\mu}_1 - \mu) \xrightarrow{d} Z \sim N(0, 1/\lambda^2),$$

$$\sqrt{n}(\hat{\mu}_2 - \mu) \xrightarrow{d} Y \sim N(0, 2/\lambda^2),$$

$$E_{21} = 1/2.$$

I.2.121. $\hat{\mu} = 17, 185$.

I.2.4 skyrelis

I.2.122. Turime lygčių sistemą $\mathbf{E}_{\alpha, \beta} X = (1 - \beta)\alpha = \bar{X}$, $\mathbf{E}_{\alpha, \beta} X^2 = \beta + (1 - \beta)(1 + \alpha^2) = a_2$. Išsprendę randame $\hat{\alpha} = (a_2 - 1)/\bar{X}$, $\hat{\beta} = 1 - \bar{X}^2/(a_2 - 1)$.

I.2.123. a) Parametru μ ir σ NMD įvertiniai (žr. **I.2.60** pratimą) yra $\hat{\mu} = (X_{(1)} + X_{(n)})/2$, $\hat{\sigma} = (n+1)(X_{(n)} - X_{(1)})/(n-1)$; jų dispersijos $\mathbf{V}_{\theta_1, \theta_2} \hat{\mu} = (\theta_2 - \theta_1)^2/(2(n+1)(n+2))$, $\mathbf{V}_{\theta_1, \theta_2} \hat{\sigma} = 2(\theta_2 - \theta_1)^2/((n-1)(n+2))$.

b) Momentų metodu gauname įvertinius $\tilde{\mu} = \bar{X}$, $\tilde{\sigma} = 2\sqrt{3}s$. Dispersijos

$$\mathbf{V}_{\theta_1, \theta_2} \tilde{\mu} = (\theta_2 - \theta_1)^2/(12n); \quad \mathbf{V}_{\theta_1, \theta_2} \tilde{\sigma} = 12 \frac{\mu_4 - \mu_2^2}{4n\mu_2} + O(1/n\sqrt{n}).$$

Tegu $Y = (X - \theta_1)/(\theta_2 - \theta_1) \sim U(0, 1)$; $Y - 1/2 = (X - \mathbf{E}X)/(\theta_2 - \theta_1)$. Tada

$$\mu_4 = (\theta_2 - \theta_1)^4 \mathbf{E}(Y - 1/2)^4 = (\theta_2 - \theta_1)^4 \int_{-1/2}^{1/2} z^4 dz = (\theta_2 - \theta_1)^4 / 80.$$

Gauname

$$\mathbf{V}_{\theta_1, \theta_2} \tilde{\sigma} = 12 \frac{\mu_4 - \mu_2^2}{4n\mu_2} + O(1/n\sqrt{n}) = \frac{(\theta_2 - \theta_1)^2}{5n} + O(\frac{1}{n\sqrt{n}}).$$

Momentų metodu gautų įvertinių dispersijos yra eilės $O(1/n)$, o NMD įvertinių eilės $O(1/n^2)$.

c) Tikėtinumo funkcija

$$L(\theta_1, \theta_2) = \frac{1}{(\theta_2 - \theta_1)^n} \mathbf{1}_{(-\infty, \theta_2)}(X_{(n)}) \mathbf{1}_{(\theta_1, \infty)}(X_{(1)})$$

igyja maksimumą taške $\hat{\theta}_1 = X_{(1)}$, $\hat{\theta}_2 = X_{(n)}$. Remiantis invariantiškumo principu parametru μ ir σ DT įvertiniai yra $(X_{(1)} + X_{(n)})/2$ ir $X_{(n)} - X_{(1)}$. Antrasis įvertinys yra paslinktas. Poslinkį galima atitaisyti (žr. p. a).

I.2.124. a) DT įvertiniai yra \bar{X} ir m_2 , o NMD įvertiniai yra \bar{X} ir s^2 ;

b) DT įvertinys yra $n\eta/S$, $S = X_1 + \dots + X_n$, o NMD įvertinys yra $(n\eta - 1)/S$;

c) DT įvertinys yra $X_{(n)}$, o NMD įvertinys yra $(n+1)X_{(n)}/n$.

I.2.125. Tikėtinumo funkcija

$$L = L(\theta) = \prod_i (a_{X_i}) \exp\left\{\sum_i X_i \ln \theta - n \ln(f(\theta))\right\},$$

$$\ell = \ln L = \ln\left(\prod_i (a_{X_i})\right) + n\bar{X} \ln \theta - n \ln(f(\theta)),$$

$$\dot{\ell} = 0 \Leftrightarrow \theta f'(\theta)/f(\theta) = \bar{X}.$$

Pažymėję $\eta = \ln \theta$, gauname kanoninio pavidalo eksponentinių skirtinių šeimą

$$L = L(\eta) = \prod_i (a_{X_i}) \exp\left\{\sum_i X_i \eta - n \ln(f(e^\eta))\right\}.$$

Tada momentų metodo lygtis

$$\mathbf{E}_\theta \bar{X} = (\ln(f(e^\eta)))' = e^\eta f'(e^\eta)/f(e^\eta) = \theta f'(\theta)/f(\theta) = \bar{X}.$$

I.2.126. $\hat{\lambda} = \bar{X}$; $\hat{p} = \bar{X}$; $-q/(p \ln p) = \bar{X}$; $\hat{\lambda} \exp\{\hat{\lambda}\}/(\exp\{\hat{\lambda}\} - 1) = \bar{X}$.

I.2.127. NMD jvertinius ir jų dispersijas žr. **I.2.95** ir **I.2.98** pratimuose. Remiantis invariantiškumo principu parametru p^2 ir λ^2 DT jvertiniai yra $\hat{p}^2 = S^2/n^2$, $\hat{\lambda}^2 = S^2/n^2$. Kvadratinės rizikos funkcijos

$$\mathbf{E}_p(\hat{p}^2 - p^2) = \frac{4p^3 q}{n} - \frac{p^2 q (11p - 7)}{n^2} + \frac{pq(1 - 6pq)}{n^3},$$

$$\mathbf{E}_\lambda(\hat{\lambda}^2 - \lambda^2) = \frac{4\lambda^3}{n} + \frac{5\lambda^2}{n^2} + \frac{\lambda}{n^3}.$$

I.2.128. a) Tikėtinumo funkcija

$$L(\theta) = \frac{1}{\theta^n}, \quad \theta < X_{(1)} \leq \dots \leq X_{(n)} < 2\theta,$$

igyja maksimalią reikšmę $(2/X_{(n)})^n$, kai $\hat{\theta} = X_{(n)}/2$.

b) Tikėtinumo funkcija

$$L(\theta) = 1, \quad \text{kai } \theta - 1/2 < X_{(1)} \leq X_{(n)} < \theta + 1/2,$$

igyja maksimalią reikšmę 1, kai $X_{(n)} - 1/2 < \theta < X_{(1)} + 1/2$, ir reikšmę 0 kitais atvejais.

I.2.129. a) DT jvertinys $\hat{\theta} = X_{(n)}/2$ yra paslinktasis; $\mathbf{E}_\theta(\hat{\theta}) = \theta(2n+1)/(2n+2)$; imdami nepaslinktajį jvertinį $\tilde{\theta} = X_{(n)}(n+1)/(2n+1)$, gauname $\mathbf{V}_\theta \tilde{\theta} = n\theta^2/((n+2)(2n+1)^2)$; momentų metodo jvertinys $\hat{\theta} = 2\bar{X}/3$, $\mathbf{V}_\theta \hat{\theta} = \theta^2/(27n)$;

b) $\mathbf{V}_\theta((X_{(n)} + X_{(1)})/2) = n\theta^2/((n+1)^2(n+2))$; momentų metodo jvertinys $\hat{\theta} = \bar{X}$ ir $\mathbf{V}_\theta \hat{\theta} = \theta^2/(12n)$.

I.2.130. Tikėtinumo funkcijos

$$L(\theta) = (1/2^n) \exp\left\{-\sum_i |X_i - \theta|\right\}$$

maksimumas gaunamas, kai $\sum_i |X_i - \theta|$ yra minimali. Suma įgyja minimalią reikšmę, kai $\hat{\theta} = X_{k+1}$, jei $n = 2k + 1$ nelyginis, ir kai $\theta \in (X_{(k)}, X_{(k+1)})$, jei $n = 2k$ lyginis, t. y. parametru θ DT jvertinys yra empirinė mediana $\hat{x}_{1/2}$. Remiantis [2], 2.4.2 teorema

$$\sqrt{n}(\hat{x}(0, 5) - x(0, 5)) \xrightarrow{d} Y \sim N(0, 1/(4f^2(x(0, 5)))).$$

Kadangi $x(0, 5) = 0, f^2(0) = 1$, tai

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{d} Y \sim N(0, 1/4).$$

I.2.131. Pažymėkime $\mathbf{S} = (S_1, \dots, S_k)^T = \sum_i (X_{1i}, \dots, X_{ki})^T$. Tada tikėtinumo funkcija

$$\begin{aligned} L(\pi_1, \dots, \pi_{k-1}) &= \prod_{i=1}^n (\pi_1^{X_{1i}} \cdot \dots \cdot \pi_k^{X_{ki}}) = \pi_1^{S_1} \cdot \dots \cdot \pi_k^{S_k} = \\ &\exp\left\{\sum_{i=1}^{k-1} S_i \ln(\pi_i/\pi_k) + n \ln \pi_k\right\}, \end{aligned}$$

čia $\pi_k = 1 - \pi_1 - \dots - \pi_{k-1}$, priklauso $(k-1)$ -parametrai eksponentinio tipo skirstinių šeimai.

Statistika $\mathbf{T} = (S_1, \dots, S_{k-1})^T$ yra pilnoji ir pakankamoji parametro $(\pi_1, \dots, \pi_{k-1})^T$ statistika. Gauname DT lygčių sistemą

$$\frac{\partial \ell}{\partial \pi_i} = \frac{S_i}{\pi_i} - \frac{S_k}{\pi_k} \Leftrightarrow \frac{S_i}{\pi_i} = \frac{S_j}{\pi_j}, \quad i, j = 1, \dots, k.$$

Sumuodami pagal i lygybę $S_i \pi_j = \pi_i S_j$ ir turėdami omenyje, kad $\sum_i S_i = n, \sum_i \pi_i = 1$, gausime DT įvertinius $\hat{\pi}_j = S_j/n, j = 1, \dots, k$;

$$\mathbf{V}(\hat{\pi}_j | \pi_j = \pi_j(1 - \pi_j)/n), \quad \mathbf{Cov}(\hat{\pi}_i, \hat{\pi}_j | \pi_i, \pi_j) = -\pi_i \pi_j / n, \quad i, j = 1, \dots, k.$$

I.2.132. $\hat{\alpha} = (S_1 - S_2 - S_3)/n; S_j = \sum_i X_{ji}, j = 1, 2, 3; \sqrt{n}(\hat{\alpha} - \alpha) \xrightarrow{d} Y \sim N(0, (1 - \alpha^2))$.

I.2.133. $\hat{\alpha} = (S_3/(S_3 + S_4); \hat{p} = (2S_1 + S_3 + S_4)/(2n)$.

I.2.134. $\hat{\alpha} = 0, 1235$.

I.2.135. $\hat{\mu}_1 = \bar{X}, \hat{\mu}_2 = \bar{Y}; \hat{\sigma}_{11} = \sum_i (X_i - \bar{X})^2/n, \hat{\sigma}_{22} = \sum_i (Y_i - \bar{Y})^2/n, \hat{\sigma}_{12} = \hat{\sigma}_{21} = \sum_i (X_i - \bar{X})(Y_i - \bar{Y})/n, \hat{\rho} = \hat{\sigma}_{12}/\sqrt{\hat{\sigma}_{11}\hat{\sigma}_{22}}$. Paramетro $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$ informacinės matricos atvirkštinės $\mathbf{I}^{-1}(\boldsymbol{\theta}) = [I^{kl}]_{5 \times 5}$ elementai yra $I^{11} = \sigma_1^2/n, I^{22} = \sigma_2^2/n, I^{12} = I^{21} = \rho\sigma_1\sigma_2/n; I^{33} = 2\sigma_1^4/n, I^{44} = 2\sigma_2^4/n, I^{34} = I^{43} = 2\rho^2\sigma_1^2\sigma_2^2/n; I^{55} = (1 - \rho^2)^2/n, I^{35} = I^{53} = \rho(1 - \rho^2)\sigma_1^2/n, I^{45} = I^{54} = \rho(1 - \rho^2)\sigma_2^2/n; I^{kl} = 0$, kai $k = 1, 2$, o $l = 3, 4, 5$.

I.2.136. A. d. $Z = (X - \mu)/\sigma$ pradiniai momentai yra

$$\alpha_k = \mathbf{E} Z^k = \int_0^\infty (\ln x)^k e^{-x} dx = \Gamma^{(k)}(1), \quad k = 1, 2, \dots,$$

čia $\Gamma^{(k)}(1)$ yra gama funkcijos k -oji išvestinė taške 1. Turėdami šiuos momentus, jais galime išreikšti ir centrinius a. d. Z momentus $\mu_k = \mathbf{E}(Z - \mathbf{E}Z)^k$:

$$\mu_2 = \alpha_2 - \alpha_1^2 = \Gamma^{(2)}(1) - [\Gamma^{(1)}(1)]^2.$$

$$\mu_3 = \Gamma^{(3)}(1) - 3\Gamma^{(2)}(1)\Gamma^{(1)}(1) + 2(\Gamma^{(1)}(1))^3,$$

$$\mu_4 = \Gamma^{(4)}(1) - 4\Gamma^{(3)}(1)\Gamma^{(1)}(1) + 6\Gamma^{(2)}(1)(\Gamma^{(1)}(1))^2 - 3(\Gamma^{(1)}(1))^4.$$

A. d. X pirmieji momentai yra

$$\mathbf{E}_{\mu,\sigma}X = \mu - \gamma\sigma, \quad \mathbf{E}_{\mu,\sigma}(X - \mu)^2 = \sigma^2 \frac{\pi^2}{6}.$$

Randame parametrų μ ir σ įvertinius momentų metodu:

$$\hat{\mu} = \bar{X} + \gamma\hat{\sigma}, \quad \hat{\sigma} = \frac{\sqrt{6}}{\pi}s.$$

Remdamiesi [2], 2.5.5 skyreliu, gauname, kad šie įvertiniai asimptotiškai nepaslinktieji ir normalieji.

$$\sqrt{n}(\hat{\mu}, \hat{\sigma}) \xrightarrow{d} \mathbf{Y} \sim N_2(\mathbf{0}, \Sigma).$$

Kovariacinės matricos $\Sigma = [\sigma_{ij}]_{2 \times 2}$ elementai yra tokie:

$$\begin{aligned}\sigma_{11} &= \sigma^2 \left(\mu_2 + \frac{3\gamma^2(\mu_4 - \mu_2^2)}{2\pi^2\mu_2} - \frac{\gamma\sqrt{6}\mu_3}{\pi\sqrt{\mu_2}} \right), \\ \sigma_{22} &= \sigma^2 \frac{3(\mu_4 - \mu_2^2)}{2\pi^2\mu_2}, \\ \sigma_{12} &= \sigma_{21} = \sigma^2 \left(-\frac{3\gamma(\mu_4 - \mu_2^2)}{2\pi^2\mu_2} + \frac{\sqrt{6}\mu_3}{2\pi\sqrt{\mu_2}} \right).\end{aligned}$$

Ieškant parametro $\boldsymbol{\theta} = (\mu, \sigma)^T$ DT įvertinio $\tilde{\boldsymbol{\theta}} = (\tilde{\mu}, \tilde{\sigma})^T$, reikia μ ir σ atžvilgiu spresti lygčių sistemą

$$\begin{cases} \frac{1}{n} \sum_i \exp\left\{\frac{X_i - \mu}{\sigma}\right\} = 1, \\ \frac{1}{n} \sum_i \frac{X_i - \mu}{\sigma} \left(1 + \exp\left\{\frac{X_i - \mu}{\sigma}\right\}\right) = 1. \end{cases}$$

DT įvertinių savybes galime gauti pasinaudojė [2], 3.5.3 teorema, kurios sąlygos tenkinamos.

DT įvertinys $\tilde{\boldsymbol{\theta}} = (\tilde{\mu}, \tilde{\sigma})^T$ yra asimptotiškai efektyvusis ir normalusis:

$$\sqrt{n}(\tilde{\boldsymbol{\theta}} - \boldsymbol{\theta}) \xrightarrow{d} \mathbf{Z} \sim N_2(\mathbf{0}, \mathbf{i}^{-1}(\boldsymbol{\theta})).$$

Informacinės matricos $\mathbf{i} = [i_{kl}]_{2 \times 2}$ elementai yra $i_{11} = 1/\sigma^2$, $i_{12} = (1 + \Gamma'(1))/\sigma^2$, $i_{22} = (1 + 2\Gamma'(1) + \Gamma''(1))/\sigma^2$.

I.2.137. Momentų metodu gauname įvertinius

$$\hat{\lambda} = \frac{\bar{X}}{s^2}, \quad \hat{\eta} = \frac{\bar{X}^2}{s^2}.$$

Remiantis [2], 2.5.5 teorema, šie įvertiniai asimptotiškai ($n \rightarrow \infty$) nepaslinktieji ir normalieji

$$\sqrt{n}(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \xrightarrow{d} \mathbf{Z} \sim N_2(\mathbf{0}, \Sigma),$$

čia $\Sigma = [\sigma_{ij}]_{2 \times 2}$; $\sigma_{11} = \lambda^2(3 + 2\eta)/\eta$, $\sigma_{22} = 2\eta(1 + \eta)$, $\sigma_{12} = \sigma_{21} = 2\lambda(1 + \eta)$.

DT metodu taškinius įvertinius randame iš lygčių sistemos

$$\begin{cases} n\tilde{\eta} - \tilde{\lambda}T_1 = 0, \\ n\ln\tilde{\lambda} - n(\ln\Gamma(\tilde{\eta}))' + \ln T_2 = 0. \end{cases}$$

Šie įvertiniai (remiantis [2], 3.5.3 teorema) asimptotiškai ($n \rightarrow \infty$) efektyvieji ir normalieji

$$\sqrt{n}(\tilde{\theta} - \theta) \xrightarrow{d} Y \sim N_2(\mathbf{0}, \mathbf{G});$$

čia $\mathbf{G} = [g_{ij}]_{2 \times 2}$; $g_{11} = a\lambda^2/(a\eta - 1)$, $g_{22} = \eta/(a\eta - 1)$, $g_{12} = g_{21} = \lambda/(a\eta - 1)$, $a = (\ln\Gamma(\eta))''$.

I.2.138. Momentų metodu gauname gana paprastą lygčių sistemą, iš kurios randame įvertinius

$$\hat{p} = \frac{\bar{X}}{s^2}, \quad \hat{k} = \frac{\bar{X}^2}{(s^2 - \bar{X})},$$

čia \bar{X} ir s^2 – empiriniai vidurkio ir dispersijos analogai.

Remiantis [2], 3.5.1 skyreliu, šie įvertiniai asimptotiškai ($n \rightarrow \infty$) nepaslinktieji ir normalieji

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{d} Z \sim N_2(\mathbf{0}, \Sigma), \quad \theta = (p, k)^T,$$

čia $\Sigma = [\sigma_{ij}]_{2 \times 2}$; $\sigma_{11} = [p^2(1-p) + 2(1+k)]/k$, $\sigma_{22} = 2k(1+k)/(1-p)^2$, $\sigma_{12} = \sigma_{21} = 2p(1+k)/(1-p)$.

DT metodu gauname sudėtingesnę lygčių sistemą

$$\begin{cases} \tilde{k} - \tilde{p}(\tilde{k} + \bar{X}) = 0, \\ \ln\tilde{p} + \bar{Z} = 0; \end{cases}$$

čia

$$\bar{Z} = \frac{1}{n} \sum_{i=1}^n Z_i, \quad Z_i = \frac{\partial}{\partial \tilde{k}} \ln \frac{\Gamma(\tilde{k} + X_i)}{\Gamma(\tilde{k})}.$$

DT įvertinio $\tilde{\theta} = (\tilde{k}, \tilde{p})^T$ asimptotinį ($n \rightarrow \infty$) skirstinį gauname remdamiesi [2], 3.5.3 teorema

$$\sqrt{n}(\tilde{\theta} - \theta_0) \xrightarrow{d} Y \sim N_2(\mathbf{0}, \mathbf{i}^{-1}(\theta_0)).$$

Informacinių matricos $\mathbf{i} = [i_{kl}]_{2 \times 2}$ elementai yra $i_{11} = k/(qp^2)$, $i_{12} = -1/p$, $i_{22} = \mathbf{V}_{p,k}(\Gamma'(k+X)/\Gamma(k+X))$.

I.2.139. Net pirmasis šio skirstinio momentas neegzistuoja. Parametras μ yra skirstinio medianos, σ – mastelio parametras.

Parametru μ taškiniu įvertiniu imkime empirinę medianą $\hat{\mu} = \hat{x}_{0,5} = X_{([n/2]+1)}$. Asimptotiškai ($n \rightarrow \infty$) šis įvertinys yra normalusis

$$\sqrt{n}(\hat{x}_{0,5} - \mu) \xrightarrow{d} Y \sim N(0, \pi^2\sigma^2/4).$$

Parametru σ įvertinys

$$\hat{\sigma} = (\hat{x}_{0,25} - \hat{x}_{0,75})/2,$$

asimptotiškai ($n \rightarrow \infty$) yra normalusis:

$$\sqrt{n}(\hat{\sigma} - \sigma) \xrightarrow{d} Y \sim N(0, \pi^2 \sigma^2 / 4).$$

Jeigu parametrus μ ir σ vertintume DT metodu, tai gautieji jvertiniai $\tilde{\mu}$ ir $\tilde{\sigma}$ būtų asimptotiškai normalieji ir efektyvieji. Jvertinių $\tilde{\mu}$ ir $\tilde{\sigma}$ asimptotinės dispersijos lygios $2\sigma^2/n$. Taigi jvertinių $\hat{\mu}$ ir $\hat{\sigma}$ ASE, palyginti su DT jvertiniais $\tilde{\mu}$ ir $\tilde{\sigma}$, yra $8/\pi^2 \approx 0,81$. Tai yra, naudojant DT metodą, reikia apie 19 procentų mažiau stebinių tam pačiam tikslumui pasiekti.

I.2.141. b) $\hat{\sigma} = \sqrt{\pi/2} \sum_i |X_i|/n$, $\sqrt{n}(\hat{\sigma} - \sigma) \xrightarrow{d} Y \sim N(0, (\pi - 2)\sigma^2/2)$;

c) $\sqrt{n}(\hat{\sigma} - \sigma) \xrightarrow{d} Y \sim N(0, \sigma^2/2)$.

I.2.142. a) Tikėtinumo funkcija

$$L(\mu) = e^{-\sum_i X_i} e^{n\mu} \mathbf{1}_{(\mu, \infty)}(X_{(1)}).$$

Remiantis faktorizacijos kriterijumi $X_{(1)}$ yra parametru μ pakankamoji statistika.

b) A. d. $X_{(1)}$ tankio funkcija yra $ne^{-n(x-\mu)}$, $x > \mu$; $\mathbf{E}_\mu X_{(1)} = \mu + 1/n$, $\mathbf{V}_\mu X_{(1)} = \mathbf{E}_\mu(X_{(1)} - \mu - 1/n)^2 = 1/n^2$;

$$\mathbf{P}_\mu\{|X_{(1)} - \mu| > \varepsilon\} = \mathbf{P}_\mu\{|X_{(1)} - \mathbf{E}_\mu X_{(1)} + 1/n| > \varepsilon\} =$$

$$\mathbf{P}_\mu\{X_{(1)} - \mathbf{E}_\mu X_{(1)} > \varepsilon - 1/n, X_{(1)} - \mathbf{E}_\mu X_{(1)} < -\varepsilon - 1/n\} \leq$$

$$\mathbf{P}_\mu\{|X_{(1)} - \mathbf{E}_\mu X_{(1)}| > \varepsilon - 1/n\} \leq \frac{\mathbf{V}_\mu X_{(1)}}{(\varepsilon - 1/n)^2} = \frac{1}{n^2(\varepsilon - 1/n)^2} \rightarrow 0,$$

kai $n \rightarrow \infty$, t. y. $X_{(1)} \xrightarrow{P} \mu$.

I.2.143. Tikėtinumo funkcija

$$L(\theta_1, \theta_2) = [a(\theta_1, \theta_2)]^n \prod_{i=1}^n h(X_i) \mathbf{1}_{(\theta_1, \infty)}(X_{(1)}) \mathbf{1}_{(-\infty, \theta_2)}(X_{(n)})$$

igyja maksimalią reikšmę, kai $\theta_1 = X_{(1)}$, $\theta_2 = X_{(n)}$, nes $a(\theta_1, \theta_2) = 1/\int_{\theta_1}^{\theta_2} h(x)dx$.

Parametru θ_1 ir θ_2 DT jvertiniai yra $\hat{\theta}_1 = X_{(1)}$ ir $\hat{\theta}_2 = X_{(n)}$.

I.2.144. a) $\hat{\mu}_j = (X_j + Y_j)/2$, $j = 1, 2, \dots, n$, $\hat{\sigma}^2 = \sum_i (X_i - Y_i)^2/(4n)$;

b) $\mathbf{E}_\sigma(\hat{\sigma}^2) = \sigma^2/2$. Parametro $(\mu_1, \dots, \mu_n, \sigma)^T$ dimensija $n+1$ priklauso nuo n , todėl teorema apie ribines DT jvertinių savybes netaikytina;

c) $\hat{\sigma}^2 = \sum_i (X_i - Y_i)^2/(2n)$; $\hat{\sigma}^2 \xrightarrow{P} \sigma^2$, nes $\mathbf{E}_\sigma(\hat{\sigma}^2) = \sigma^2$, $\mathbf{V}_\sigma(\hat{\sigma}^2) = \sigma^4/(2n)$.

I.2.145. a) Tikėtinumo funkcija

$$L(\lambda_1, \dots, \lambda_n, \theta) = \exp\{-\theta \sum_i (\lambda_i X_i) + \sum_i \ln(\theta X_i) - \sum_i (\lambda_i Y_i) + \sum_i \ln \lambda_i\}.$$

DT jvertiniams rasti gauname lygčių sistemą

$$\dot{\ell}_{\lambda_i}(\hat{\lambda}_1, \dots, \hat{\lambda}_n, \hat{\theta}) = -\hat{\theta} X_i - Y_i + 2/\hat{\lambda}_i = 0, \quad i = 1, 2, \dots, n,$$

$$\dot{\ell}_{\theta}(\hat{\lambda}_1, \dots, \hat{\lambda}_n, \hat{\theta}) = - \sum_i (\lambda_i X_i) + n/\hat{\theta} = 0.$$

Išsprendę iš pirmųjų lygčių $\hat{\lambda}_i, i = 1, \dots, n$ ir įrašę į paskutiniają, gauname

$$\dot{\ell}_{\theta}(\hat{\lambda}_1, \dots, \hat{\lambda}_n, \hat{\theta}) = - \sum_i \frac{2X_i}{Y_i + \hat{\theta}X_i} + \frac{n}{\hat{\theta}} = 0 \Rightarrow \frac{n}{\hat{\theta}} - 2 \sum_i \frac{R_i}{1 + \hat{\theta}R_i} = 0.$$

b) A. d. R_i pasiskirstymo funkcija

$$F(x|\theta) = \mathbf{P}_{\theta}\{X_i \leq x Y_i\} = \int_0^{\infty} \int_{xv}^{\infty} \lambda^2 \theta e^{-\lambda \theta u} e^{-\lambda v} du dv = \frac{1}{1 + \theta x}$$

ir tankio funkcija

$$f(x|\theta) = F'(x|\theta) = \frac{\theta}{(1 + \theta x)^2}, \quad x > 0.$$

Imties R_1, \dots, R_n tikėtinumo funkcija

$$L(\theta) = \theta^n \prod_i \frac{1}{(1 + \theta R_i)^2} = \exp\{-2 \sum_i \ln(1 + \theta R_i) + n \ln \theta\}.$$

Prilyginę jos logaritmo išvestinę pagal θ nuliui, DT įvertiniui rasti gauname lygtį

$$\dot{\ell}_{\theta}(\hat{\theta}) = \frac{n}{\hat{\theta}} - 2 \sum_i \frac{R_i}{1 + \hat{\theta}R_i} = 0.$$

c) Informacijos kiekis

$$I(\theta) = -\mathbf{E}\ddot{\ell}_{\theta^2} = \frac{n}{\theta^2} - 2n \int_0^{\infty} \frac{\theta x^2 dx}{(1 + \theta x)^4} = \frac{3\theta^2}{n}.$$

Gauname

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{d} Y \sim N(0, 3\theta^2).$$

d) $\hat{\theta} = 2,0102$; kadangi $\mathbf{E}_{\theta}(R_i)$ neegzistuoja, tai pradinį artinį $\hat{\theta}_0$ galima parinkti, pvz., naudojant empirinę medianą $\hat{\theta}_0 = 1/\hat{x}_{0.5}$;

e) $\hat{\sigma}_{\hat{\theta}} = \sqrt{3\theta}/\sqrt{n} = 0,7785$.

I.2.146. $\hat{\lambda}_1 = K/(S_1 + (n - K)x_0)$, $\hat{\lambda}_2 = (n - K)/S_2$; $S_1 = \sum_{i=1}^K X_{(i)}$, $S_2 = \sum_{i=K+1}^n (X_{(i)} - x_0)$; K – gedimų, mažesnių už x_0 , skaičius; $\sqrt{n}(\hat{\lambda}_1 - \lambda_1, \hat{\lambda}_2 - \lambda_2) \xrightarrow{d} \mathbf{Y} \sim N_2(\mathbf{0}, \Sigma)$; $\Sigma = [\sigma_{ij}]_{2 \times 2}$; $\sigma_{11} = \lambda_1^2/(1 - p)$, $\sigma_{12} = \sigma_{21} = 0$; $\sigma_{22} = \lambda_2^2/p$, $p = e^{-\lambda_1 x_0}$.

I.2.147. a) $\hat{\alpha} = \bar{X}/m_2$, $\hat{\gamma} = \bar{X}^2/m_2$;

b) $\hat{\theta} = 1/\sqrt{m_2}$, $\hat{a} = \bar{X} + \sqrt{m_2}$;

c) $\hat{\alpha} = \bar{X}(1 - \bar{X}(1 - \bar{X})/m_2)$, $\hat{\beta} = (1 - \bar{X})(1 - \bar{X}(1 - \bar{X})/m_2)$;

d) $\hat{\mu} = \bar{Y}$, $\hat{\sigma} = \sqrt{m_2}$, $m_2 = (1/n) \sum_i (Y_i - \bar{Y})^2$, $Y_i = \ln X_i$, $i = 1, \dots, n$;

e) $\hat{\theta} = \bar{X}$; f) $\hat{p} = \bar{X}/m_2$, $\hat{n} = \bar{X}^2/(m_2 - \bar{X})$;

g) $-\hat{q}/\hat{p} \ln \hat{p} = \bar{X}$; h) $\hat{k} = \bar{X}$.

I.2.148. Pagal faktorizacijos kriterijų T yra pakankamoji parametru θ statistika tada ir tik tada, kai tikėtinumo funkcija $L(\theta) = q(T; \theta)W(\mathbf{X})$ ir $W(\mathbf{X})$ nuo parametru θ

nepriklauso. Funkcijos L maksimizavimas pagal θ ekvivalentus funkcijos q maksimizavimui.

- I.2.149.** a) $\hat{\theta} = X_{(1)}$; b) $\hat{\theta} = \bar{X}$;
 c) $\hat{\theta} = n / \sum_j \ln(1 - X_j)$;
 d) $\hat{\theta} = n / (n - \sum_j \ln X_j)$, $1/2 < \hat{\theta} < 1$;
 e) $\hat{\theta} = \hat{x}_{1/2}$;
 f) $\hat{\theta} = X_{(1)}$;
 g) $\hat{\theta} = (\sqrt{\bar{X}^2 + 4a_2} - \bar{X})/2$;
 h) $\hat{\mu} = X_{(1)}$, $\hat{\sigma} = n / \sum_i (X_i - X_{(1)})$;
 i) $\hat{\mu} = (1/n) \sum_j \ln X_j = \bar{Y}$, $\hat{\sigma} = [\sum_j (\ln X_j - \bar{Y})^2 / n]^{1/2}$;
 j) $\hat{\theta} = 0$, kai $2^n \prod_j \sqrt{X_j} > 1$, ir $\hat{\theta} = 1$ priešingu atveju;
 k) $\hat{\beta} = X_{(n)}$, $\hat{\alpha} = n / (n \ln \hat{\beta} - \sum_j \ln X_j)$;
 l) $\hat{\theta} = X_{(n)}$, $n > 1$.

- I.2.150.** a) $\hat{\lambda} = \bar{Y}$, $\hat{\mu} = \bar{Z}$;
 b) Atsitiktinio vektoriaus $(X_i, \Delta_i)^T$ pasiskirstymo funkcija

$$F(x, k) = \int_0^x f_1^k(u, \lambda) [1 - F_1(u, \lambda)]^{1-k} f_2^{1-k}(u, \mu) [1 - F_2(u, \mu)]^k du.$$

Tikėtinumo funkcija

$$L(\lambda, \mu) = \prod_i \left\{ \left(\frac{1}{\lambda} e^{-X_i/\lambda} \right)^{\Delta_i} \left(e^{-X_i/\lambda} \right)^{1-\Delta_i} \left(\frac{1}{\mu} e^{-X_i/\mu} \right)^{1-\Delta_i} \left(e^{-X_i/\mu} \right)^{\Delta_i} \right\}.$$

Randame parametrų λ ir μ DT ivertinius

$$\hat{\lambda} = \sum_i X_i / \sum_i \Delta_i, \quad \hat{\mu} = \sum_i X_i / (n - \sum_i \Delta_i).$$

- I.2.151.** Tikėtinumo funkcija

$$L(\theta) = \frac{1}{(1 - e^{-\theta})^n} \theta^{\sum_i X_i} e^{-n\theta},$$

įš kurios parametruo θ DT ivertiniui rasti gauname lygtį

$$-\frac{1}{e^\theta - 1} + \frac{\bar{X}}{\theta} - 1 = 0 \quad \Leftrightarrow \quad \bar{X} = \frac{\theta}{1 - e^{-\theta}}.$$

Nagrinėkime funkciją $g(\theta) = \theta / (1 - e^{-\theta})$;

$$g'(\theta) = \frac{1 - e^{-\theta} - \theta e^{-\theta}}{(1 - e^{-\theta})^2}.$$

Skaitiklis yra didėjanti funkcija, nes $(1 - e^{-\theta} - \theta e^{-\theta})' = \theta e^{-\theta} > 0$. Skaitiklis lygus 0, kai $\theta = 0$. Taigi skaitiklis teigiamas su visais $\theta > 0$. Taške $\theta = 0$ funkcija $g(\theta) = 1$. Funkcija $g(\theta)$ didėja nuo 1 iki ∞ , kai θ kinta nuo 0 iki ∞ .

Lygtis $\bar{X} = \theta / (1 - e^{-\theta})$ turi vienintelį sprendinį, kai $\bar{X} > 1$.

I.2.152. $ASE = 1$.

I.2.153. $\hat{\alpha} = X_{(1)}$, $\hat{\theta} = n/S$, $S = \sum_j (\ln X_j - \ln X_{(1)})$; NMD įvertiniai $\hat{\alpha} = X_{(1)}(1 - S/n)$, $\hat{\theta} = (n - 1)/S$; $ASE = 1$.

I.2.154. $\hat{\mu} = \bar{\mathbf{X}} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma}/n)$, $\hat{\boldsymbol{\Sigma}} = \sum_j (\mathbf{X}_j - \bar{\mathbf{X}})(\mathbf{X}_j - \bar{\mathbf{X}})^T/n = \mathbf{S}/n$; pažymėkime $\boldsymbol{\theta} = (\sigma_{ij}, i \leq j)$ vektorių, sudarytą iš skirtinių kovariacinės matricos $\boldsymbol{\Sigma}$ elementų, o $\hat{\boldsymbol{\theta}}$ DT įvertinių (t. y. atitinkamų matricos \mathbf{S}/n elementų) vektorių. Tada $\sqrt{n}(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \xrightarrow{d} \mathbf{Z} \sim N_{k(k-1)/2}(\mathbf{0}, \boldsymbol{\Gamma})$; čia kovariacinės matricos $\boldsymbol{\Gamma} = [\gamma_{ijrs}]_{k(k-1)/2 \times k(k-1)/2}$ elementai yra $\gamma_{iiii} = 2\sigma_{ii}^2$, $\gamma_{iiji} = 2\sigma_{ii}\sigma_{ij}$, $i \neq j$, $\gamma_{ijrs} = (\sigma_{ir}\sigma_{js} + \sigma_{is}\sigma_{jr})$, $i \neq j \neq r \neq s$.

I.2.155. $\hat{\sigma}^2 = \sum_j (X_j - \hat{\mu})^2/n$, $\hat{\tau}^2 = \sum_j (Y_j - \hat{\mu})^2/n$, o įvertinys $\hat{\mu}$ randamas iš lygties $\hat{\mu} = [\bar{X} \sum_j (Y_j - \hat{\mu})^2 + \bar{Y} \sum_j (X_j - \hat{\mu})^2] / [\sum_j (Y_j - \hat{\mu})^2 + \sum_j (X_j - \hat{\mu})^2]$; šie įverčiai asimptotiškai nekoreliuoti ir normalieji: $\sqrt{n}(\hat{\sigma}^2 - \sigma^2) \xrightarrow{d} Z \sim N(0, 2\sigma^4)$, $\sqrt{n}(\hat{\tau}^2 - \tau^2) \xrightarrow{d} Y \sim N(0, 2\tau^4)$, $\sqrt{n}(\hat{\mu} - \mu) \xrightarrow{d} V \sim N(0, \sigma^2\tau^2/(\sigma^2 + \tau^2))$.

I.2.156. Palyginę tikimybes $b(X|n, p) = C_n^X p^X (1-p)^{n-X}$ ir $b(X|n+1, p)$ gausime, kad maksimumas pasiekiamas, kai $\hat{n} = [X/p]$, jei X/p nėra sveikasis skaičius, ir $\hat{n} = X/p - 1$, jei X/p – sveikasis skaičius.

I.2.157. Palyginę tikimybes $h(X|N, M, n) = C_M^X C_{N-M}^{n-X} / C_N^n$ ir $h(X|N, M+1, n)$ gausime, kad maksimumas pasiekiamas, kai $\hat{M} = [X(N+1)/n]$, jei $X(N+1)/n$ nėra sveikasis skaičius, ir $\hat{M} = X(N+1)/n - 1$, jei $X(N+1)/n$ – sveikasis skaičius.

I.2.5 skyrelis

I.2.158. Parametru μ pilnoji ir pakankamoji statistika \bar{X} ir funkcijos $T(\bar{X}; \mu) = \sqrt{n}(\bar{X} - \mu)/\sigma \sim N(0, 1)$ skirstinys nepriklauso nuo nežinomo parametru μ . Parinkime tokius skaičius $k_1 < k_2$, kad

$$\mathbf{P}_\mu \{k_1 < \sqrt{n}(\bar{X} - \mu)/\sigma < k_2\} = Q = 1 - 2\alpha.$$

Išsprendę nelygybes μ atžvilgiu, gausime parametru μ pasiklivimo intervalą. Intervalo ilgis bus tuo mažesnis, kuo mažesnis $k_2 - k_1$, t. y. taškai k_1, k_2 turėtų būti simetriški 0 atžvilgiu. Gauname $k_1 = -z_\alpha$, $k_2 = z_\alpha$. Pasiklivimo intervalas

$$(\underline{\mu}; \bar{\mu}) = (\bar{X} - z_\alpha\sigma/\sqrt{n}; \bar{X} + z_\alpha\sigma/\sqrt{n}).$$

I.2.159. Parametru σ^2 pilnoji ir pakankamoji statistika $s_0^2 = \sum_i (X_i - \mu)^2/n$ ir funkcijos $T(s_0^2; \sigma^2) = s_0^2 n / \sigma^2 \sim \chi^2(n)$ skirstinys nepriklauso nuo nežinomo parametru σ^2 . Parinkime konstantas $k_1 < k_2$, kad

$$\mathbf{P}_\sigma \{k_1 < s_0^2 n / \sigma^2 < k_2\} = Q = 1 - 2\alpha.$$

Imdami simetriškus rėžius $k_1 = \chi_{1-\alpha}^2(n)$, $k_2 = \chi_\alpha^2(n)$, gauname pasiklivimo intervalą

$$(\underline{\sigma^2}; \bar{\sigma^2}) = \left(\frac{s_0^2 n}{\chi_\alpha^2(n)}, \frac{s_0^2 n}{\chi_{1-\alpha}^2(n)} \right).$$

Kadangi $\sigma = h(\sigma^2) = \sqrt{\sigma^2}$ yra monotonė funkcija, tai gauname

$$(\underline{\sigma}; \bar{\sigma}) = (\sqrt{\underline{\sigma^2}}; \sqrt{\bar{\sigma^2}}).$$

I.2.160. Parametro $(\mu, \sigma^2)^T$ pilnoji ir pakankamoji statistika $(\bar{X}, s^2)^T$. Remiantis [2], 2.4.1 teorema funkcijų $s^2(n-1)/\sigma^2 \sim \chi^2(n-1)$, $\sqrt{n}(\bar{X} - \mu)/s \sim S(n-1)$ skirstiniai nepriklauso nuo nežinomų parametrų. Analogiškai I.2.158 ir I.2.159 pratimams gauname lygmenį $Q = 1 - 2\alpha$ pasikliovimo intervalus

$$(\underline{\mu}; \bar{\mu}) = (\bar{X} - t_\alpha(n-1)s/\sqrt{n}; \bar{X} + t_\alpha(n-1)s/\sqrt{n}),$$

$$(\underline{\sigma^2}; \bar{\sigma^2}) = \left(\frac{s^2(n-1)}{\chi^2_\alpha(n-1)}, \frac{s^2(n-1)}{\chi^2_{1-\alpha}(n-1)} \right).$$

I.2.161. Mažiausio vidutinio santykinio ilgio intervalą gauname, kai $\alpha_1 = \alpha_1^*$, $\alpha_2 = 1 - Q - \alpha_1^*$, o α_1^* randamas iš sąlygos

$$\min_{0 \leq \alpha_1 \leq 1-Q} b(\alpha_1) = b(\alpha_1^*), \quad b(\alpha_1) = (1/\chi^2_{1-\alpha_1}(n-1) - 1/\chi^2_{1-Q-\alpha_1}(n-1)).$$

Simetrišku atveju $\alpha_1 = \alpha_2 = (1 - Q)/2$.

Mažiausio vidutinio santykinio ilgio pasikliovimo intervalo ilgio santykis su simetriško intervalo vidutiniu santykiniu ilgiu, kai $Q = 0, 95$ ir $n = 10; 20; 50; 100$, yra 0,8378; 0,9156; 0,9652; 0,9826.

I.2.162. *Nurodymas.* Pasiremkite tuo, kad a. d. \bar{X} ir s^2 yra nepriklausomi.

I.2.163. Randame

$$\bar{\mu} - \underline{\mu} = 0,4, \quad z_\alpha = 0,8, \quad z_\alpha = 2, \quad Q = 1 - 2\alpha = 2\Phi(2) - 1 \approx 0,9544.$$

I.2.164. Gauname

$$\bar{\mu} - \underline{\mu} = 2z_{0,025}/\sqrt{n} \leq 0,1 \Leftrightarrow n \geq (20z_{0,025})^2 = 1537.$$

I.2.165. Tegu $\alpha = (1 - Q)/2 = 0,025$. Gauname

$$(\underline{\mu}; \bar{\mu}) = (\bar{X} - t_\alpha(24)s/5; \bar{X} + t_\alpha(24)s/5) = (6,289; 6,379);$$

$$(\underline{\sigma}; \bar{\sigma}) = (\sqrt{\underline{\sigma^2}}; \sqrt{\bar{\sigma^2}}) = (0,0855; 0,1524).$$

I.2.166. a) Funkcija $T = \beta s_2^2/s_1^2 \sim F(n-1, m-1)$ yra monotonė pagal β , o jos skirstinys nuo nežinomų parametrų nepriklauso. Remdamiesi [2], 3.6.4 pastaba gauname lygmenį $Q = 1 - 2\alpha$ pasikliovimo intervalą

$$(\underline{\beta}; \bar{\beta}) = \left(\frac{s_1^2}{s_2^2} F_{1-\alpha}(n-1, m-1), \frac{s_1^2}{s_2^2} F_\alpha(n-1, m-1) \right).$$

b) Paramетro σ^2 NMD įvertinys $s^2 = (s_1^2(m-1)/k + s_2^2(n-1))/(m+n-2)$, $s^2(m+n-2)/\sigma^2 \sim \chi^2(m+n-2)$. Analogiškai I.2.159 pratimui gauname

$$(\underline{\sigma^2}; \bar{\sigma^2}) = \left(\frac{s^2(m+n-2)}{\chi^2_\alpha(m+n-2)}, \frac{s^2(m+n-2)}{\chi^2_{1-\alpha}(m+n-2)} \right).$$

Parametro $\theta = \mu_1 - \mu_2$ NMD įvertinys $\hat{\theta} = \bar{X} - \bar{Y} \sim N(\theta, k\sigma_2^2/m + \sigma_2^2/n)$. Tada

$$\frac{\bar{X} - \bar{Y} - \theta}{\sigma_{\hat{\theta}}} \sim S(m+n-2), \quad \sigma_{\hat{\theta}}^2 = s^2 \frac{kn+m}{mn};$$

$$(\underline{\theta}; \bar{\theta}) = (\bar{X} - \bar{Y} - t_{\alpha}(m+n-2)\sigma_{\hat{\theta}}, \bar{X} - \bar{Y} + t_{\alpha}(m+n-2)\sigma_{\hat{\theta}}).$$

I.2.167. Parametro θ NMD įvertinys $\hat{\theta} = \bar{X} - \bar{Y} \sim N(\theta, \sigma_1^2/m + \sigma_2^2/n)$. Kadangi $s_1^2 \xrightarrow{P} \sigma_1^2$ ir $s_2^2 \xrightarrow{P} \sigma_2^2$, tai

$$\frac{\bar{X} - \bar{Y} - \theta}{\sqrt{s_1^2/m + s_2^2/n}} \xrightarrow{P} Z \sim N(0, 1), \quad m, n \rightarrow \infty.$$

Gauname lygmens $Q = 1 - 2\alpha$ asimptotinių pasikliovimo intervalą

$$(\underline{\theta}; \bar{\theta}) = (\bar{X} - \bar{Y} - z_{\alpha}\sqrt{s_1^2/m + s_2^2/n}, \bar{X} - \bar{Y} + z_{\alpha}\sqrt{s_1^2/m + s_2^2/n}).$$

I.2.168. A. v. $(X, Y)^T$ skirstinys priklauso penkių parametrų eksponentinio tipo skirstinių šeimai. Pilnoji ir pakankamoji statistika

$$\mathbf{T} = \left(\sum_i X_i, \sum_i Y_i, \sum_i X_i^2, \sum_i Y_i^2, \sum_i X_i Y_i \right)^T.$$

Parametro θ NMD įvertinys $\hat{\theta} = \bar{X} - \bar{Y} \sim N(\theta, \sigma^2)$, $\sigma^2 = \sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2$. Tegu $Z_i = X_i - Y_i$, tada Z_1, \dots, Z_n yra paprastoji imtis a. d. $Z \sim N(\theta, \sigma^2)$. Parametro θ lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalas randamas analogiškai **2.160** pratimui

$$(\underline{\theta}; \bar{\theta}) = (\bar{X} - \bar{Y} - t_{\alpha}(n-1)s/\sqrt{n}; \bar{X} - \bar{Y} + t_{\alpha}(n-1)s/\sqrt{n}),$$

čia $s^2 = \sum_i (Z_i - \bar{Z})^2/(n-1)$.

I.2.169. Parametro ρ DT įvertinys $\hat{\rho}$ yra empirinis koreliacijos koeficientas

$$\hat{\rho} = r = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i (X_i - \bar{X})^2 \sum_i (Y_i - \bar{Y})^2}}.$$

Statistikos r tankio funkcija $f(r|\rho)$ pateikta [5], 4.1 skyrelyje

$$f(r|\rho) = \frac{2^{n-3}(1-\rho^2)^{(n-1)/2}(1-r^2)^{(n-4)/2}}{\pi(n-3)!} \sum_{j=0}^{\infty} \frac{(2r\rho)^j}{j!} \Gamma^2\left(\frac{n-1+j}{2}\right).$$

Pasiskirstymo funkcija $F(r|\rho) = \int_{-1}^r f(u|\rho)du$ yra monotoniskai didėjanti pagal ρ . Rečiantis Bolševo teorema (žr. [2], 3.6.1 teorema) lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalo rėžiai randami iš lygčių

$$F(r|\underline{\rho}) = 1 - \alpha, \quad F(r|\bar{\rho}) = \alpha.$$

I.2.170. Statistikos r skirstinio aproksimacija

$$\sqrt{n} \frac{r - \rho}{1 - \rho^2} \xrightarrow{d} Z \sim N(0, 1)$$

gali būti netiksli, ypač kai ρ artimas ± 1 ir r skirstinys yra labai asimetriškas.

Rekomenduojama taikyti Fišerio pasiūlytą dispersiją stabilizuojančią transformaciją

$$V = V(r) = \frac{1}{2} \ln \frac{1+r}{1-r}, \quad \sqrt{n-3}(V(r) - V(\rho)) \xrightarrow{d} Z \sim N(0, 1).$$

Pritaikę šią aproksimaciją ir remdamiesi tuo, kad $V(\rho)$ monotonė funkcija, gauname lygmenį $Q = 1 - 2\alpha$ aproksimacinį intervalą

$$\underline{\rho} = \frac{e^{2V_1-1}}{e^{2V_1+1}}, \quad \bar{\rho} = \frac{e^{2V_2-1}}{e^{2V_2+1}},$$

$$V_1 = \frac{1}{2} \ln \frac{1+r}{1-r} - z_\alpha \frac{1}{\sqrt{n-3}}, \quad V_2 = \frac{1}{2} \ln \frac{1+r}{1-r} + z_\alpha \frac{1}{\sqrt{n-3}}.$$

I.2.171. Parametro σ^2 NMD jvertinys

$$\hat{\sigma}^2 = \sum_{i=1}^n X_i^2 / (2n), \quad 2n\hat{\sigma}^2/\sigma^2 \sim \chi^2(2n).$$

Analogiškai **I.2.159** pratimui gauname pasiklivimo intervalą $\alpha = (1-Q)/2$

$$(\underline{\sigma}; \bar{\sigma}) = (\sqrt{2n\hat{\sigma}^2/\chi_\alpha^2(2n)}, \sqrt{2n\hat{\sigma}^2/\chi_{1-\alpha}^2(2n)}).$$

I.2.172. Parametro σ^2 NMD jvertinys

$$\hat{\sigma}^2 = \sum_{i=1}^n X_i^2 / (3n), \quad 3n\hat{\sigma}^2/\sigma^2 \sim \chi^2(3n).$$

Analogiškai **I.2.159** pratimui gaume pasiklivimo lygmenį $Q = 1 - 2\alpha$ intervalą

$$(\underline{\sigma^2}; \bar{\sigma^2}) = (3n\hat{\sigma}^2/\chi_\alpha^2(3n), 3n\hat{\sigma}^2/\chi_{1-\alpha}^2(3n)).$$

I.2.173. Parametro λ pilnoji ir pakankamoji statistika yra $T = X_1 + \dots + X_n \sim G(\lambda, \eta)$, $\eta = \eta_1 + \dots + \eta_n$. Funkcija $Y = 2\lambda T \sim \chi^2(2\eta)$ yra monotonė pagal λ , o jos skirstinys nuo nežinomo parametru nepriklauso. Remdamiesi [2], 3.6.4 pastaba gaume pasiklivimo intervalą

$$\underline{\lambda} = \chi_{1-\alpha}^2(2\eta)/(2T), \quad \bar{\lambda} = \chi_\alpha^2(2\eta)/(2T).$$

I.2.174. A.d. $Y = e^X$ turi eksponentinį skirstinį su parametru $\lambda = e^{-\mu}$. Sudare parametru λ pasiklivimo intervalą (žr. **I.2.173** pratimą)

$$\underline{\lambda} = \chi_{1-\alpha}^2(2n)/(2T), \quad \bar{\lambda} = \chi_\alpha^2(2n)/(2T), \quad T = Y_1 + \dots + Y_n,$$

gaume ir parametru μ pasiklivimo intervalą

$$\underline{\mu} = \ln(1/\bar{\lambda}), \quad \bar{\mu} = \ln(1/\underline{\lambda}).$$

I.2.175. Pilnosios ir pakankamosios statistikos $T = X_1 + \dots + X_n \sim \mathcal{P}(n\lambda)$ pa-siskirstymo funkcija

$$F(t; \lambda) = \sum_{k=0}^t \frac{(n\lambda)^k}{k!} e^{-n\lambda} = \mathbf{P}\{\chi_{2t+2}^2 > 2n\lambda\}$$

yra mažėjanti pagal λ , kai $t > 0$. Remiantis Bolševo teorema (žr. [2], 3.6.1 teorema) pasiklivimo intervalo rėžiai randami iš lygčių

$$F(T; \bar{\lambda}) = \mathbf{P}\{\chi^2_{2T+2} > 2n\bar{\lambda}\} = \alpha,$$

$$F(T; \underline{\lambda}) = \mathbf{P}\{\chi^2_{2T} > 2n\underline{\lambda}\} = 1 - \alpha$$

ir $\underline{\lambda} = 0$, kai $T = 0$. Išsprendę gauname

$$\underline{\lambda} = \frac{1}{2n}\chi^2_{1-\alpha}(2T), \quad \bar{\lambda} = \frac{1}{2n}\chi^2_{\alpha}(2T + 2).$$

I.2.176. Pilnosios ir pakankamosios statistikos $T = X_1 + \dots + X_n \sim B(n, p)$ pa-

siskirstymo funkcija

$$F(t; p) = \sum_{m=0}^t C_n^m p^t (1-p)^{n-t} = I_{1-p}(m-t, t+1)$$

yra mažėjanti pagal p , kai $0 < t < n$, čia $I_x(\gamma, \eta) = \mathbf{P}\{U < x\}$, $U \sim Be(\gamma, \eta)$. Remiantis Bolševo teorema pasiklivimo intervalo rėžiai randami iš lygčių

$$F(T; \bar{p}) = I_{1-\bar{p}}(m-T, T+1) = \alpha,$$

$$F(T-0; \underline{p}) = I_{1-\underline{p}}(m-T+1, T) = 1 - \alpha$$

ir $\underline{p} = 0$, kai $T = 0$, $\bar{p} = 1$, kai $T = n$. Pažymėję $\beta_\alpha(\gamma, \eta)$ beta skirstinio su parametrais γ ir η lygmens α kritinę reikšmę, gauname

$$\underline{p} = 1 - \beta_\alpha(m-T+1, T), \quad \text{kai } T > 0,$$

$$\bar{p} = 1 - \beta_{1-\alpha}(m-T, T+1), \quad \text{kai } T < n.$$

I.2.177. Paramетro $(\lambda_1, \lambda_2)^T$ pilnoji ir pakankamoji statistika yra $\mathbf{T} = (T_1, T_2)^T$, $T_1 = X_1 + \dots + X_m \sim \mathcal{P}(m\lambda_1)$, $T_2 = Y_1 + \dots + Y_n \sim \mathcal{P}(n\lambda_2)$. A. d. T_1 sąlyginis skirstinys, kai $T_1 + T_2$ fiksuotas, yra binominis

$$(T_1 | T_1 + T_2 = N) \sim B(N, p), \quad p = m\lambda_1 / (m\lambda_1 + n\lambda_2).$$

Suradę tikimybės p pasiklivimo intervalą (\underline{p}, \bar{p}) , gauname ir parametro β pasiklivimo intervalą

$$\underline{\beta} = \frac{n}{m} \frac{\underline{p}}{1-\underline{p}}, \quad \bar{\beta} = \frac{n}{m} \frac{\bar{p}}{1-\bar{p}}.$$

I.2.178. Pilnosios ir pakankamosios statistikos $T = X_1 + \dots + X_n \sim B^-(m, p)$, $m = m_1 + \dots + m_n$, pasiskirstymo funkcija

$$F(t; p) = \sum_{i=0}^t C_{m+i-1}^{m-1} p^m (1-p)^i = I_p(m, t+1)$$

yra didėjanti pagal p , kai $0 < T$. Remiantis Bolševo teorema (žr. [2], 3.6.1 teorema) pasiklivimo intervalo rėžiai randami iš lygčių

$$F(T-0; \bar{p}) = I_{\bar{p}}(m, T) = \alpha,$$

$$F(T; \underline{p}) = I_{\underline{p}}(m, T+1) = 1 - \alpha$$

ir $\bar{p} = 0$, kai $T = 0$. Pažymėjė $\beta_\alpha(\gamma, \eta)$ beta skirstinio su parametrais γ ir η lygmens α kritinę reikšmę, gauname

$$\underline{p} = \beta_{1-\alpha}(m, T+1), \quad \bar{p} = \beta_\alpha(m, T).$$

I.2.179. Parametro M pilnoji ir pakankamoji statistika $T = X_1 + \dots + X_n \sim H(N, M, n)$. Pasiskirstymo funkcija

$$F(t; M) = \sum_{m=0}^t \frac{C_M^m C_{N-M}^{n-m}}{C_N^n} = H(t|N, M, n)$$

yra monotoniskai mažėjanti pagal M . Remiantis Bolšovo teorema parametru M apatinis lygmens $(1 - \alpha)$ pasikliovimo rėžis \underline{M} yra didžiausias sveikasis skaičius, tenkinantis nelygybę

$$F(T-1, \underline{M}) = H(T-1|N, \underline{M}, n) \geq 1 - \alpha,$$

o viršutinis lygmens $(1 - \alpha)$ pasikliovimo rėžis \bar{M} yra mažiausias sveikasis skaičius, tenkinantis nelygybę

$$F(T, \bar{M}) = H(T|N, \bar{M}, n) \leq \alpha.$$

I.2.180. Parametro M NMD įvertinys yra $\hat{M} = NT/n$; jo realizacija $\hat{M} = 300 \times 6/50 = 36$. Pasikliovimo rėžius gauname spręsdami **I.2.179** pratime pateiktas nelygybes

$$H(5|300, \underline{M}, 50) \geq 0,95 \Leftrightarrow \underline{M} \geq 13, \quad H(6|300, \bar{M}, 50) \leq 0,05 \Leftrightarrow \bar{M} \leq 58.$$

Pasikliovimo rėžiai $\underline{M} = 13$, $\bar{M} = 58$.

I.2.181. Parametru $\beta_0, \beta_1, \sigma^2$ NMD įvertiniai (žr. **I.1.69** pratimą) $\hat{\beta}_0 = \bar{Y} \sim N(\beta_0, \sigma^2/n)$, $\hat{\beta}_1 = \sum_i Y_i(x_i - \bar{x}) / \sum_i (x_i - \bar{x})^2 \sim N(\beta_1, \sigma^2 / \sum_i (x_i - \bar{x})^2)$;

$$\hat{\sigma}^2 = s^2 = SS_E/(n-2), \quad SS_E = \sum_i (Y_i - \hat{\beta}_0 - \hat{\beta}_1(x_i - \bar{x}))^2, \quad s^2(n-2)/\sigma^2 \sim \chi^2(n-2).$$

a) Analogiškai **I.2.160** pratimui gauname lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalą

$$(\underline{\sigma^2}, \bar{\sigma^2}) = (s^2(n-2)/\chi^2_\alpha(n-2), s^2(n-2)/\chi^2_{1-\alpha}(n-2)).$$

b) Įvertiniai $\hat{\beta}_0, \hat{\beta}_1, s^2$ nepriklausomi (žr. **I.1.69** pratimą). Tada

$$\hat{\theta} = a\hat{\beta}_0 + b\hat{\beta}_1 \sim N(\theta, \sigma_\theta^2), \quad \sigma_\theta^2 = \sigma^2(a^2/n + b^2 / \sum_i (x_i - \bar{x})^2)$$

ir $(\hat{\theta} - \theta)/\sigma_\theta \sim S(n-2)$, $\sigma_\theta^2 = s^2(a^2/n + b^2 / \sum_i (x_i - \bar{x})^2)$. Gauname pasikliovimo intervalą

$$(\underline{\theta}, \bar{\theta}) = (\hat{\theta} - t_\alpha(n-2)\sigma_\theta, \hat{\theta} + t_\alpha(n-2)\sigma_\theta).$$

Imdami $a = 1, b = 0$; $a = 0, b = 1$; $a = 1, b = x - \bar{x}$ gausime parametru $\beta_0, \beta_1, \beta_0 + \beta_1(x - \bar{x})$ pasikliovimo intervalus.

I.2.182. Pasikliovimo intervalą gauname **I.2.181** pratimo p. b) imdami $a = 4, b = 4\bar{x}$.

I.2.183. Parametro θ pilnoji ir pakankamoji statistika yra $T = X_{(n)}$. A. d. $T = X_{(n)}$ pasiskirstymo funkcija yra $F(t|\theta) = (t/\theta)^n, 0 < t < \theta$. Fiksuo tam $t > 0$ funkcija $t/\theta^n, \theta > t$ yra mažėjanti θ atžvilgiu. Pagal Bolševo teoremą lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalo réžiai gaunami iš lygčių

$$(X_{(n)}/\theta)^n = 1 - \alpha, \quad (X_{(n)}/\bar{\theta})^n = \alpha.$$

Gauname pasikliovimo intervalą

$$(\underline{\theta}; \bar{\theta}) = (X_{(n)}/(1 - \alpha)^{1/n}; \bar{\theta} = X_{(n)}/\alpha^{1/n}).$$

I.2.184. Pilnoji ir pakankamoji statistika yra $T = |X|_{(n)}$ ir $|X| \sim U(0, \theta)$. Gauname analogišką intervalą, kaip ir **I.2.183** pratime.

I.2.185. Kadangi $P_\theta\{X_{(n)} - 1/2 < \theta < X_{(1)} + 1/2\} = 1$, tai intervalas $(\underline{\theta}; \bar{\theta}) = (X_{(n)} - 1/2; X_{(1)} + 1/2)$ uždengia nežinomą parametrą θ su tikimybe 1. Šio intervalo ilgis $X_{(1)} + 1/2 - (X_{(n)} - 1/2) = 1 - (X_{(n)} - X_{(1)}) = Y_{(1)} + 1 - Y_{(n)}$, kai $Y_i \sim U(0, 1)$. Taigi intervalo ilgis turi beta skirstinį $Be(2, n - 1)$ ir jo vidurkis $2/(n + 1) = O(1/n)$.

I.2.186. Pažymėkime $Y_i = (X_i - \theta_1)/\theta_2 \sim U(0, 1)$. Tada funkcijos $T = (X_{(n)} - X_{(1)})/\theta = Y_{(n)} - Y_{(1)} \sim Be(n - 1, 2)$ tankio funkcija $f(x; n) = n(n - 1)x^{n-2}(1 - x)$ ir pasiskirstymo funkcija $F(x; n) = nx^{n-1} - (n - 1)x^n$. Pažymėkime $T_{1-\alpha}$ ir T_α šios pasiskirstymo funkcijos eilės $1 - \alpha$ ir α kritines reikšmes. Jos randamos iš lygčių

$$nT_{1-\alpha}^{n-1} - (n - 1)T_{1-\alpha}^n = \alpha, \quad nT_\alpha^{n-1} - (n - 1)T_\alpha^n = 1 - \alpha.$$

Gauname lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalą

$$(\underline{\theta}_2; \bar{\theta}_2) = ((X_{(n)} - X_{(1)})/T_\alpha; (X_{(n)} - X_{(1)})/T_{1-\alpha}).$$

I.2.187. Pilnoji ir pakankamoji statistika yra $(T_1, T_2)^T = (X_{(1)}, n(\bar{X} - X_{(1)}))^T$ (žr. **I.1.27** pratimą). a) Funkcija $2T_2/\theta \sim \chi^2(2n - 2)$. Gauname lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalą

$$(\underline{\theta}; \bar{\theta}) = (2T_2/\chi_\alpha^2(2n - 2); 2T_2/\chi_{1-\alpha}^2(2n - 2)).$$

b) Funkcija $T_1 - a = X_{(1)} - a \sim \mathcal{E}(n/\theta)$. Šios funkcijos pasiskirstymo funkcija $F(x) = 1 - e^{-nx/\theta}$. Randame eilės $1 - \alpha$ ir α kritines reikšmes $u_{1-\alpha}$ ir u_α :

$$F(u_{1-\alpha}) = \alpha, \quad F(u_\alpha) = 1 - \alpha \quad \Rightarrow \quad u_{1-\alpha} = -\frac{\theta}{n} \ln(1 - \alpha), \quad u_\alpha = -\frac{\theta}{n} \ln \alpha.$$

Randame parametru a lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalą

$$(\underline{a}; \bar{a}) = (X_{(1)} + (\theta/n) \ln \alpha; X_{(1)} + (\theta/n) \ln(1 - \alpha)).$$

Kai ir parametras θ nežinomas, tai remsimės tuo, kad T_1 ir T_2 nepriklausomi ir

$$(2n/\theta)(X_{(1)} - a) \sim \chi^2(2), \quad 2T_2/\theta \sim \chi^2(2n - 2).$$

Tada funkcija $n(n-2)(X_{(1)}-a)/T_2 \sim F(2, 2n-2)$. Iš čia lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalas yra

$$(\underline{a}; \bar{a}) = (X_{(1)} - (T_2/(n(n - 2)))F_{1-\alpha}(2, 2n - 2), X_{(1)} - (T_2/(n(n - 2)))F_\alpha(2, 2n - 2)).$$

c) Tegu

$$C(T_1, T_2) = \{(a, \theta) : X_{(1)} + (\theta/n) \ln \alpha_1 < a < X_{(1)} + (\theta/n) \ln(1 - \alpha), \underline{\theta} < \theta < \bar{\theta}\}.$$

Tada $\mathbf{P}_{a,\theta}\{(a, \theta) \in C(T_1, T_2)\} = (1 - 2\alpha_1)(1 - 2\alpha)$.

I.2.188. A. d. $X_{n+1} - \bar{X} \sim N(0, \sigma^2(1 + 1/n))$. Tada $(X_{n+1} - \bar{X})/s\sqrt{1 + 1/n} \sim S(n-1)$. Iš čia randame

$$(\underline{X}_{n+1}; \bar{X}_{n+1}) = (\bar{X} - t_\alpha(n-1)s\sqrt{1 + 1/n}; \bar{X} + t_\alpha(n-1)s\sqrt{1 + 1/n}).$$

I.2.189. a) $\sqrt{n}(\tilde{\mu} - \mu) \xrightarrow{d} Z \sim N(0, \pi^2/4)$. Gauname lygmens $Q = 1 - 2\alpha$ aproksimacijų pasikliovimo intervalą

$$(\underline{\mu}; \bar{\mu}) = (\tilde{\mu} - z_\alpha\pi/(2\sqrt{n}); \tilde{\mu} + z_\alpha\pi/(2\sqrt{n})).$$

b) $\sqrt{n}(\hat{\mu} - \mu) \xrightarrow{d} Y \sim N(0, 2)$. Gauname lygmens $Q = 1 - 2\alpha$ aproksimacijų pasikliovimo intervalą

$$(\underline{\mu}; \bar{\mu}) = (\hat{\mu} - z_\alpha\sqrt{2/n}; \hat{\mu} + z_\alpha\sqrt{2/n}).$$

Intervalo a) ilgis yra $\pi/(2\sqrt{2}) \approx 1,11$ kartu didesnis už intervalo b) ilgi.

I.2.190. a) $(\underline{\lambda}; \bar{\lambda}) = (\bar{X} - z_\alpha\sqrt{\bar{X}/n}; \bar{X} + z_\alpha\sqrt{\bar{X}/n})$.

b) Spręsdami antrojo laipsnio nelygybę, gauname

$$(\underline{\lambda}; \bar{\lambda}) = (\bar{X} + z_\alpha^2/(2n) - z_\alpha\sqrt{\bar{X}/n + z_\alpha^2/(4n^2)}; \bar{X} + z_\alpha^2/(2n) - z_\alpha\sqrt{\bar{X}/n + z_\alpha^2/(4n^2)}).$$

c) Randame

$$(\underline{\lambda}; \bar{\lambda}) = ((\sqrt{\bar{X}} - z_\alpha/(2\sqrt{n}))^2; (\sqrt{\bar{X}} + z_\alpha/(2\sqrt{n}))^2).$$

d) Randame a) (1,9706; 2,8294); b) (2,0073; 2,8695); c) (1,9898; 2,8486); remdamiesi **I.2.175** pratimu gauname (1,9898; 2,8698). Intervalas a) mažiau tikslus.

I.2.191. $C(Y_1, \dots, Y_n) \approx \{(\mu_y, \sigma_y^2) : n[(\bar{Y} - \mu_y)^2/s^2 + (s^2 - \sigma_y^2)^2/(m_4 - s^4)] < \chi_\alpha^2(2)\}$.

I.2.192. *Nurodymas.* a) ir c) pasinaudokite vidurkio ir dispersijos apibrėžimu bei faktu, kad $Y = \ln(X) \sim N(\mu, \sigma)$. b) Raskite parametrų μ ir σ DT ivertinius $\hat{\mu}$ ir $\hat{\sigma}$. Tada parametrų θ ir γ DT ivertiniai gaunami išraišius $\hat{\mu}$ ir $\hat{\sigma}$ į θ ir γ išraiškas.

I.2.193. a) $\hat{\theta} = 34,988$, $\hat{\gamma} = 81230,195$. b) Naudodami aproksimaciją $\sqrt{n}(\hat{\theta} - \theta)/(\theta\sqrt{m_2}) \xrightarrow{d} Z \sim N(0, 1)$, gauname pasikliovimo intervalą $(\underline{\theta}; \bar{\theta}) = (\hat{\theta}/(1 + z_\alpha\sqrt{m_2/n}); \hat{\theta}/(1 - z_\alpha\sqrt{m_2/n}))$, $\alpha = (1 - Q)/2$; pagal turimus duomenis randame realizaciją $(\underline{\theta}; \bar{\theta}) = (24,953; 58,524)$.

I.2.194. Kai $N = n$ fiksotas, tai $(Y|N = n) \sim \mathcal{P}(n\theta)$; generuojančioji funkcija $\psi(s|n) = \mathbf{E}_\theta(s^Y|N = n) = e^{n\theta(s-1)}$. Besalyginė a. d. Y generuojančioji funkcija

$$\psi(s) = \mathbf{E}_{\theta, \lambda} s^Y = \sum_{k=0}^{\infty} e^{k\theta(s-1)} \frac{\lambda^k}{k!} e^{-\lambda} = \exp\{\lambda(e^{\theta(s-1)} - 1)\}.$$

Randame momentus

$$\mathbf{E}_{\theta, \lambda} Y = \psi'(1) = \lambda\theta, \quad \mathbf{V}_{\theta, \lambda} Y = \psi''(1) + \psi'(1) - [\psi'(1)]^2 = \lambda\theta(\theta + 1).$$

Prilyginę empiriniam vidurkiui \bar{Y} ir empirinei dispersijai s^2 , gauname momentų metodo įvertinius

$$\hat{\theta} = (s^2 - \bar{Y})/\bar{Y}, \hat{\lambda} = \bar{Y}^2/(s^2 - \bar{Y}).$$

I.2.195. a) $\hat{\theta} = 6, 2$, $\hat{\lambda} = 8, 0645$.

b) Pagal pirmąjį aproksimaciją gauname lygmens $Q = 1 - 2\alpha$ aproksimacinį pasiklivimo intervalą intervalą

$$(\underline{\mu}; \bar{\mu}) = (\hat{\mu} - z_\alpha s / \sqrt{n}; \hat{\mu} + z_\alpha s / \sqrt{n}),$$

o pagal antrają – intervalą $(\underline{\mu}; \bar{\mu})$:

$$\underline{\mu} = (\hat{\mu} + (1 + \hat{\theta})z_\alpha^2)/(2n) - \sqrt{\hat{\mu}(1 + \hat{\theta})z_\alpha^2/n + (1 + \hat{\theta})^2z_\alpha^4/(4n)},$$

$$\bar{\mu} = (\hat{\mu} + (1 + \bar{\theta})z_\alpha^2)/(2n) + \sqrt{\hat{\mu}(1 + \hat{\theta})z_\alpha^2/n + (1 + \hat{\theta})^2z_\alpha^4/(4n)}.$$

c) Pagal turimus duomenis gauname intervalus (41, 685; 58, 315), (42, 347; 59, 036).

I.2.196. Parametrų μ ir σ^2 DT įvertiniai yra empirinis vidurkis \bar{X} ir empirinė dispersija m_2 . Asimptotinis įvertinio (\bar{X}, m_2) skirstinys yra dvimatis normalusis su neko-reliuotomis koordinatėmis

$$\sqrt{n}(\bar{X} - \mu) \xrightarrow{d} Y \sim N(0, \sigma^2), \sqrt{n}(m_2 - \sigma^2) \xrightarrow{d} Z \sim N(0, 2\sigma^4).$$

Nagrinėjamų charakteristikų DT įvertiniai yra

$$\hat{x}_P = \bar{X} + z_P \sqrt{m_2}, \hat{F}(x; \mu, \sigma) = \Phi\left(\frac{x - \bar{X}}{\sqrt{m_2}}\right).$$

Pakeitę dispersijas jų įvertiniai ir pažymėjė, kad

$$\frac{\partial x_P}{\partial \mu} = 1, \frac{\partial x_P}{\partial \sigma^2} = \frac{z_P}{2\sigma},$$

naudodami delta metodą gauname įvertinio \hat{x}_P asymptotinės dispersijos įvertinį

$$\hat{\sigma}_{\hat{x}_P}^2 = \frac{m_2}{n} + \left(\frac{z_P}{2\sqrt{m_2}}\right)^2 \frac{2m_2^2}{n} = \frac{m_2}{n} \left(1 + \frac{z_P^2}{2}\right).$$

Parametru x_P aproksimacinis pasiklivimo intervalas, kai pasiklivimo lygmuo $Q = 1 - 2\alpha$, yra

$$(\hat{x}_P - z_\alpha \hat{\sigma}_{\hat{x}_P}, \hat{x}_P + z_\alpha \hat{\sigma}_{\hat{x}_P}).$$

Analogiškai gauname

$$\frac{\partial F}{\partial \mu} = -\frac{1}{\sigma} \varphi\left(\frac{x - \mu}{\sigma}\right), \frac{\partial F}{\partial \sigma^2} = -\frac{x - \mu}{2\sigma^3} \varphi\left(\frac{x - \mu}{\sigma}\right),$$

$$\hat{\sigma}_{\hat{F}}^2 = \frac{1}{n} \left(1 + \frac{(x - \bar{X})^2}{2m_2}\right) \varphi^2\left(\frac{x - \bar{X}}{\sqrt{m_2}}\right),$$

$$\underline{F} = \hat{F}(x) - z_\alpha \hat{\sigma}_{\hat{F}}, \quad \bar{F} = \hat{F}(x) + z_\alpha \hat{\sigma}_{\hat{F}}.$$

I.2.197. Parametru $x(0, 9)$ ir $F(0)$ taškiniai jverčiai yra

$$\hat{x}(0, 9) = \bar{X} + sz(0, 9) = 3,8432; \quad \hat{F}(0) = \Phi(-1, 28/2) = 0,2611.$$

Asimptotinių dispersijų jverčiai

$$\hat{\sigma}_{\hat{x}(0, 9)}^2 = 4(1 + z^2(0, 9)/2)/n = 0,0728; \quad \hat{\sigma}_{\hat{F}(0)}^2 = (1 + 1,28^2/8)\varphi^2(0, 64)/n = 0,00127.$$

Gauname asimptotinius pasiklivimo intervalus

$$\underline{x}(0, 9) = \hat{x}(0, 9) - z_{0,025} \hat{\sigma}_{\hat{x}(0, 9)} = 3,3144, \quad \bar{x}(0, 9) = \hat{x}(0, 9) + z_{0,025} \hat{\sigma}_{\hat{x}(0, 9)} = 4,3720;$$

$$\underline{F}(0) = \hat{F}(0) - z_{0,025} \hat{\sigma}_{\hat{F}(0)} = 0,1913, \quad \bar{F}(0) = \hat{F}(0) + z_{0,025} \hat{\sigma}_{\hat{F}(0)} = 0,3309.$$

Statistikų g_1 ir g_2 pirmųjų momentų išraiškos pateiktos **I.1.95** pratime. Naudodamis išraiškas gauname asimptotinius pasiklivimo intervalus

$$\underline{\gamma}_1 = g_1 - z_{0,025} \sqrt{\hat{V}g_1} = -0,7184, \quad \bar{\gamma}_1 = g_1 + z_{0,025} \sqrt{\hat{V}g_1} = 0,2184;$$

$$\underline{\gamma}_2 = g_2 - 6/(n+1) - z_{0,025} \sqrt{\hat{V}g_2} = -0,8507, \quad \bar{\gamma}_2 = g_2 - 6/(n+1) + z_{0,025} \sqrt{\hat{V}g_2} = 0,9319.$$

I.2.198. Pažymėkime $u_p = -\ln(1-p)$. Išvestinės

$$\frac{\partial t(p)}{\partial \theta} = u_p^{1/\mu}, \quad \frac{\partial t(p)}{\partial \nu} = -\frac{\theta}{\nu^2} u_p^{1/\nu} \ln u_p,$$

taigi

$$\hat{\sigma}_{\hat{t}(p)}^2 = u_p^{2/\hat{\nu}} \left(\hat{I}^{11} - 2\hat{I}^{12} \frac{\hat{\theta}}{\hat{\nu}^2} \ln u_p + \hat{I}^{22} \frac{\hat{\theta}^2}{\hat{\nu}^4} \ln^2 u_p \right);$$

čia \hat{I}^{ij} yra matricos $\hat{\boldsymbol{I}}_n^{-1}$ elementai. Informacinių matricos \boldsymbol{I} pagrįstojo jvertinio $\hat{\boldsymbol{I}}_n = [\hat{I}_{ij}]_{2 \times 2}$ elementai

$$\hat{I}_{11} = n \frac{\hat{\nu}^2}{\hat{\theta}^2}, \quad \hat{I}_{22} = n \frac{1 + \Gamma''(2)}{\hat{\nu}^2}, \quad \hat{I}_{12} = \hat{I}_{21} = n \frac{\Gamma'(2)}{\hat{\sigma}}.$$

Intervalas

$$\left(\hat{t}(p) - \hat{\sigma}_{\hat{t}(p)} z_{1-\alpha/2}, \quad \hat{t}(p) + \hat{\sigma}_{\hat{t}(p)} z_{1-\alpha/2} \right)$$

yra parametru $t(p)$ aproksimacinis pasiklivimo intervalas, kai pasiklivimo lygmuo $Q = 1 - 2\alpha$.

I.2.199. Parametru θ ir ν jvertinių vidutinius kvadratinius nuokrypius jvertinkime taip:

$$\hat{\sigma}_{\hat{\theta}} = 1/\sqrt{\hat{I}^{11}} = \hat{\theta}/(\hat{\nu}\sqrt{n}) = 0,0092, \quad \hat{\sigma}_{\hat{\nu}} = 1/\sqrt{\hat{I}^{22}} = \hat{\nu}/\sqrt{n(1 + \Gamma''(2))} = 0,1592.$$

Gauname asimptotinius pasiklivimo intervalus

$$\underline{\theta} = \hat{\theta} - z_{0,025}\hat{\sigma}_{\hat{\theta}} = 0,0568, \quad \bar{\theta} = \hat{\theta} + z_{0,025}\hat{\sigma}_{\hat{\theta}} = 0,3392;$$

$$\underline{\nu} = \hat{\nu} - z_{0,025}\hat{\sigma}_{\hat{\nu}} = 1,8380, \quad \bar{\nu} = \hat{\nu} + z_{0,025}\hat{\sigma}_{\hat{\nu}} = 2,4620.$$

Parametru $t(0, 9)$ taškinio įvertinio realizacija yra $\hat{t}(0, 9) = \hat{\theta}(-\ln 0, 1)^{1/\hat{\nu}} = 0,2918$. Vertinant dispersiją reikia rasti Fišerio informacinių matricos atvirkštine. Gauname $\hat{I}^{11} = 0,0094/n$, $\hat{I}^{22} = 2,8104/n$, $\hat{I}^{12} = -0,0509/n$. Tada $\hat{\sigma}_{\hat{t}(0,9)} = 0,0172$ ir pasiklivimo intervalas

$$\underline{t}(0, 9) = \hat{t}(0, 9) - z_{0,025}\hat{\sigma}_{\hat{t}(0,9)} = 0,2580, \quad \bar{t}(0, 9) = \hat{t}(0, 9) + z_{0,025}\hat{\sigma}_{\hat{t}(0,9)} = 0,3427.$$

I.2.6 skyrelis

I.2.200. $\hat{\mu} = \bar{X} = 424,933$, $\hat{\sigma} = s = 8,598$; $(\underline{\mu}, \bar{\mu}) = (420,172; 429,695)$, $(\underline{\sigma}, \bar{\sigma}) = (6,295; 13,560)$.

I.2.201. $\hat{\lambda} = \bar{X} = 0,9288$; $(\underline{\lambda}, \bar{\lambda}) = (0,850; 1,009)$.

I.2.202. a) Momentų metodu gauname įverčius $\hat{\lambda} = 1,073$, $\hat{\eta} = 9,928$; DT įverčius galime rasti maksimizuodami tikėtinumo funkcijos $L(\lambda, \eta)$ logaritmą

$$\max_{\lambda, \eta} = \max_{\lambda, \eta} [-\lambda T_1 + (\eta - 1)T_2 + n\eta \ln \lambda - n \ln(\Gamma(\eta))] = \ell(\hat{\lambda}, \tilde{\eta});$$

čia $T_1 = X_1 + \dots + X_n$, $T_2 = \sum_i \ln X - i$.

b) DT įvertinys $\hat{\lambda} = \eta/\bar{X}$ paslinktasis; NMD įvertis $\hat{\lambda} = (n\eta - 1)/(n\bar{X}) = 1,076$; $(\underline{\lambda}, \bar{\lambda}) = (0,936; 1,236)$.

I.2.203. $\hat{p} = 0,277$; $(\underline{p}, \bar{p}) = (0,2495; 0,3059)$.

I.2.204. $(\underline{p}, \bar{p}) = (0,000; 0,206)$, $(0,000; 0,259)$, $(0,000; 0,411)$.

I.2.205. Parametru λ įvertį galime rasti maksimizuodami tikėtinumo funkcijos $L(\lambda)$ logaritmą

$$\max_{\lambda} \ell(\lambda) = \max_{\lambda} \sum_{i=1}^{11} S_i \ln(\pi_i(\lambda)) = \ell(\hat{\lambda}),$$

čia $\pi_i(\lambda) = e^{-\lambda a_{i-1}} - e^{-\lambda a_i}$, $i = 1, \dots, 11$, $a_0 = 0$, $a_{12} = \infty$.

Asimptotinių pasiklivimo intervalų gauname naudodami aproksimaciją

$$\sqrt{n}(\hat{\lambda} - \lambda) \xrightarrow{d} Y \sim N(0, 1/i(\hat{\lambda})),$$

$$i(\lambda) = -\mathbf{E}(\ddot{\ell}_{\lambda^2}(\lambda))/n = \sum_i [(\dot{\pi}_i(\lambda))^2 / \pi_i(\lambda)].$$

Asimptotinis pasiklivimo intervalas

$$(\underline{\lambda}, \bar{\lambda}) = (\hat{\lambda} - z_{0,025}i(\hat{\lambda})/n; \hat{\lambda} + z_{0,025}i(\hat{\lambda})/n).$$

I.2.206. a) $\hat{\sigma}^2 = s^2 = [s_x^2(n_1 - 1) + s_y^2(n_2 - 1) + s_z^2(n_3 - 1)]/\nu$, $\nu = n_1 + n_2 + n_3 - 3$; $s^2\nu/\sigma^2 \sim \chi^2(\nu)$. Remdamiesi turimais duomenimis, gauname realizacijas $s^2 = 3,288$,

$(\underline{\sigma}; \bar{\sigma}) = (\sqrt{s^2\nu/\chi^2_{0,995}(\nu)}; \sqrt{s^2\nu/\chi^2_{0,005}(\nu)}) = (1,528; 2,217)$. b) $\hat{\theta} = \bar{X} + \bar{Y} - \bar{Z} \sim N(\theta, \sigma^2(1/n_1 + 1/n_2 + 1/n_3))$, $(\hat{\theta} - \theta)/\sigma_{\hat{\theta}} \sim S(\nu)$, $\sigma_{\hat{\theta}} = s\sqrt{1/n_1 + 1/n_2 + 1/n_3}$. Remdamiesi turimais duomenimis, gauname realizacijas $\hat{\theta} = 0,070$, $(\underline{\theta}; \bar{\theta}) = (-1,087; 1,227)$.

I.2.207. a) $\hat{\theta} = 0,075$, $s_x^2 = 3,9686$, $s_y^2 = 3,8783$; $(\underline{\theta}; \bar{\theta}) = (-1,355; 1,505)$. Kadangi nulis yra per vidurį šio intervalo, tai darytina išvada, kad a. d. X ir Y vidurkiai nesiskiria.

b) $s_z^2 = \sum_i (X_i - Y_i - (\bar{X} - \bar{Y}))^2/(n-1) = 0,02867$; $(\underline{\theta}; \bar{\theta}) = (-0,015; 0,165)$. Intervalas trumpesnis, o nulis yra šio intervalo krašte. Todėl išvada dėl a. d. X ir Y vidurkių lygybės kelia abejonių.

c) Pagal prasmę a. d. X ir Y turėtų būti priklausomi (jei bulvė turi daugiau krakmolo, tai abu metodai turėtų duoti didesnes reikšmes ir atvirkščiai). Todėl lentelės duomenis reikėtų traktuoti kaip dvimačio a. v. $(X, Y)^T$ realizacijas.

d) Taškinis koreliacijos koeficiente įvertis $\hat{\rho} = r = 0,9964$. Remdamiesi **I.2.171** pratimu gauname pasiklivimo intervalą $(\underline{\rho}; \bar{\rho}) = (0,9894; 0,9988)$. A. d. X ir Y yra stipriai priklausomi.

I.2.208. $(\underline{\theta}; \bar{\theta}) = (0,9966; 1,0497)$.

I.2.209. $\hat{\theta} = 0,0408$; $(\underline{\theta}; \bar{\theta}) = (0,0151; 0,0665)$; yra pagrindo tvirtinti, kad $p_1 > p_2$.

I.2.210. Taikydami normaliąjį aproksimaciją gauname: a) $N \geq 316$; b) $N \geq 1263$.

I.2.211. Randame (žr. [2], 4.7.12 skyrelį) $\bar{C} = -0,0345$, $\bar{S} = 0,3222$, $\bar{R} = 0,3240$; $\hat{\mu} = 96,1605^\circ$, $\hat{\theta} = 0,6854$. Aproksimaciniai pasiklivimo intervalai: $(\underline{\mu}; \bar{\mu}) = (79,6766^\circ; 112,6444^\circ)$; $(\underline{\theta}; \bar{\theta}) = (0,4768; 0,8940)$.

I.2.212. a) $\hat{C} = -0,0954$, $\hat{S} = -0,0316$, $\hat{R} = 0,1005$; $\hat{\mu} = 198,34^\circ$, $\hat{\theta} = 0,2021$.
b) $(\underline{\mu}; \bar{\mu}) = (163,31^\circ; 233,37^\circ)$; $(\underline{\theta}; \bar{\theta}) = (0,0779; 0,3263)$.

I.3. Parametrinių hipotezių tikrinimas

I.3.1. Statistiniai kriterijai

I.3.1. Psichologas nori nustatyti, ar pelės atmintis pasikeičia pašalinus tam tikrą smegenų dalį. Iš pradžių jis įpratino 6 peles neklystamai rasti labirinte vienintelį kelią prie maisto. Paskui pašalino smegenų dalį. Galima tarti, kad neturinti atminties pelė teisingą kelią ras su tikimybe 0,2. Psichologas teigia, kad pelė atminties neturi, jei teisingą kelią randa ne daugiau kaip 2 pelės iš 6 pelių. Suformuluokite uždavinį hipotezių tikrinimo terminais. Kokia psichologo taikomo kriterijaus kritinė sritis? Koks šio kriterijaus reikšmingumo lygmuo? Apskaičiuokite kriterijaus galią, kai $p = 0,4, 0,6, 0,8, 1,0$.

I.3.2. Gaminant tam tikrą chemikalą, pageidautina, kad vartojamo vandens tūrio vienete būtų vidutiniškai ne daugiau kaip m_0 bakterijų. Nuo per didelės jų koncentracijos apsaugoma taip: imama n vienodo tūrio V vandens pavyzdžių, kiekvieno iš tų pavyzdžių vanduo supilamas į kolbą su maitinamaja terpe. Jeigu pavyzdžio vanduo užterštas (t. y. Jame yra nors viena bakterija), tai bakterijų kolonija plėsis ir buvęs skaidrus tirpalas susidrums.

Vanduo laikomas pakankamai švariu ir vartojamas gamyboje, jeigu kolbų su susidrumstusiu vandeniu skaičius X ne didesnis už skaičių t . Priešingu atveju vanduo valomas.

Tegu:

- a) $m_0 = 1, V = 1, n = 10, t = 7;$
- b) $m_0 = 1, V = 2, n = 8, t = 7.$

Suformuluokite uždavinį hipotezės tikrinimo terminais ir apskaičiuokite pirmosios rūšies klaidos tikimybę.

Nurodymas. Vandens tūri, iš kurio imami pavyzdžiai, laikykite daug kartų didesnį už pavyzdžio tūri. Tiksliau kalbant, bakterijų skaičius pasiskirstymą tūryje V aproksimuokite Puasono skirstiniu.

I.3.3. Sėklų pirkėjas ir pardavėjas susitarė, kad sėklų partijos kainą nustatys po bandymo. Iš partijos buvo paimta 250 sėklų ir pasėta. Tegu X yra iš 250 sėklų išaugusių augalų, turinčių tam tikrų savybių, skaičius. Jeigu $X \leq 25$, tai nusprendžiama, kad sėklų partijos kaina bus pripažinta normalia; priešingu atveju sėklų partijos kaina sumažinama. Kiek procentų sėklų turi turėti minėtas savybes, kad tikimybė, jog partijos kaina bus normali, būtų lygi (apytiksliai) 0,95?

I.3.4. Parduodant elektros lempučių partijas ($N = 10\,000$) atliekama atrankinė kontrolė: atsitiktinai negražinančios atrenkama n lempučių ir nustatomas defektinių lempučių skaičius X ; jeigu $X \leq d$, partija pripažįstama gera, priešingu atveju – defektine. Suformuluokite uždavinį hipotezių tikrinimo terminais. Nurodykite kriterijaus kritinę sritį.

I.3.5. (I.3.4 pratimo tēsinys). Tarkime, pirkėjui nepriimtina, jei defektuotų lempučių procentas ne mažesnis už 10; jis reikalauja, kad partija būtų atmesta su tikimybe 0,95, jeigu joje defektuotų lempučių yra 10 procentų. Pardavėjas įsitikinės, kad defektuotų lempučių procentas ne didesnis už 5. Jis nori, kad kiekvieną kartą, kai defektuotų lempučių yra 5 procentai, partija būtų priimama su tikimybe 0,9. Pasiūlykite kriterijų, kuris tenkintų ir pirkėją, ir pardavėją.

I.3.6. Nustatyta, kad gamyklos produkcijoje vidutiniškai yra 5 procentai broko. Per pamainą pagaminama 500 gaminiai. Atliekant kontrolę nustatomas per pamainą pagamintų defektinių gaminiių skaičius X . Jeigu X įgyja didelę reikšmę, tai daroma išvada, kad gamybos procesas sutriko. Suformuluokite uždavinį hipotezių tikrinimo terminais.

I.3.7. (I.3.6 pratimo tēsinys). a) Nurodykite ribą, kurią defektinių gaminiių skaičius viršija su tikimybe, ne didesne už 0,01, kai defektinio gaminio pagaminimo tikimybė lygi 0,05. Apskaičiuokite tikimybę, kad ta riba viršys defektinių gaminiių skaičius, kai defektinio gaminio pagaminimo tikimybė lygi 0,08; 0,10; 0,12. b) Nurodykite kontrolinę ribą ir minėtas tikimybes, jei tikrinama tik 50 atsitiktinai paimtų gaminiai.

I.3.8. Tegu paprastojo imtis $\mathbf{X} = (X_1, \dots, X_n)^T$ gauta stebint a.d. $X \sim N(\mu, \sigma^2)$, σ žinomas. a) Tikriname hipotezę $H : \mu = \mu_0$, kai alternatyva yra $\bar{H}_1 : \mu > \mu_0$ arba $\bar{H}_2 : \mu < \mu_0$. Suformuluokite kriterijus remdamiesi pasikliovimo intervalais (žr. [2], 4.5 skyrelį); suformuluokite kriterijus P reikšmių terminais (žr. [2], 4.1.2 skyrelį).

b) Tikriname hipotezę $H : \mu = \mu_0$, kai alternatyva yra $\bar{H}_1 : \mu \neq \mu_0$. Suformuluokite kriterijų remdamiesi pasikliovimo intervalais; suformuluokite kriterijų P reikšmių terminais.

I.3.2. Neimano ir Pirsono lema

I.3.9. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. X , kurio skirstinys priklauso šeimai $\mathcal{P} = \{f(x; \theta), \theta = \theta_0, \theta = \theta_1\}$; čia tankio funkcija $f(x; \theta) = \theta \exp\{-\theta x\}, x > 0$. Raskite galingiausią hipotezės $H : \theta = \theta_0$, kai alternatyva yra $\bar{H} : \theta = \theta_1$, tikrinimo kriterijų (reikšmingumo lygmuo lygus α). Apskaičiuokite rastojo kriterijaus galią.

I.3.10. Tegu X yra atsitiktinis dydis, kurio skirstinys priklauso Koši skirstinių šeimai $\mathcal{P} = \{f(x; \theta), \theta = 0, \theta = 1\}$; čia

$$f(x; \theta) = \frac{1}{\pi} \frac{1}{1 + (x - \theta)^2}, \quad -\infty < x < \infty.$$

Raskite galingiausią kriterijų hipotezei $H : \theta = 0$, kai alternatyva $\bar{H} : \theta = 1$, tikrinti. Imties didumas $n = 1$.

I.3.11. Raskite galingiausią kriterijų hipotezei H , kad a. d. X yra pasiskirstęs pagal standartinį normalųjį skirstinį $N(0, 1)$, esant alternatyvai \bar{H} , kad a. d. X skirstinys yra:

a) Laplaso, kurio tankis

$$\frac{1}{2} e^{-|x|}, \quad -\infty < x < \infty;$$

b) tolygus intervale $(-\delta, \delta)$, tikrinti. Imties didumas lygus 1.

I.3.12. Paprastosios imties realizacija yra $-0,260; -0,114; -0,325; 0,196; -0,174$. Sudarykite galingiausiąjį kriterijų hipotezei H : stebimo a. d. skirstinys yra normalusis $N(0, 0,025)$, esant alternatyvai \bar{H} : stebimo a. d. skirstinys yra tolygusis $U(-0,5, 0,5)$, tikrinti. Ar atmetama hipotezė H pagal turimą realizaciją, jei reikšmingumo lygmuo $\alpha = 0,1$?

I.3.13. Pagal paprastąją didumo n imtį raskite galingiausiąjį kriterijų hipotezei H : stebimo a. d. skirstinys $N(0, 1)$, esant alternatyvai \bar{H} : stebimo a. d. skirstinys yra $N(1, 1)$, tikrinti. Koks turėtų būti mažiausias imties didumas n , kad abiejų rūšių klaidų tikimybės neviršytų 0,01?

I.3.14. Yra $n = 1$ didumo imtis atsitiktinio dydžio $X \sim \mathcal{P}(\lambda)$, turinčio Puasono skirstinį. Tikrinama hipotezė $H : \lambda = \lambda_0$, kai alternatyva $\bar{H} : \lambda = \lambda_1$. Raskite galingiausiojo kriterijaus galią, kai $\lambda_0 = 0,1, \lambda_1 = 0,2; \lambda_0 = 1, \lambda_1 = 2; \lambda_0 = 10, \lambda_1 = 20; \lambda_0 = 0,1, \lambda_1 = 0,4$, o kriterijaus reikšmingumo lygmuo $\alpha = 0,1$.

I.3.15. Imties \mathbf{X} skirstinys priklauso šeimai $\mathcal{P} = \{\varphi_i(\mathbf{x}), \theta = 1, 2\}$. Tikrinama paprastoji hipotezė $H : \theta = 1$, esant paprastajai alternatyvai $\bar{H} : \theta = 2$. Tegu η įgyja reikšmę 1, jeigu priimta hipotezė H , reikšmę 2, jeigu priimta alternatyva \bar{H} , ir reikšmę 0, jeigu atsisakoma sprendimo, kuri iš hipotezių teisinga. Pažymėkime

$$\varphi_i(\mathbf{x}) = \mathbf{P}\{\eta = i | \mathbf{X} = \mathbf{x}\}, \quad i = 1, 2, 0;$$

$$0 \leq \varphi_i(\mathbf{x}) \leq 1; \quad \varphi_1(\mathbf{x}) + \varphi_2(\mathbf{x}) + \varphi_0(\mathbf{x}) \equiv 1.$$

Pirmosios ir antrosios rūšies klaidų tikimybės yra

$$\alpha_{12} = \mathbf{P}\{\eta = 1 | \theta = 2\} = \mathbf{E}(\varphi_1(\mathbf{X}) | \theta = 2), \quad \alpha_{21} = \mathbf{P}\{\eta = 2 | \theta = 1\} = \mathbf{E}(\varphi_2(\mathbf{X}) | \theta = 1).$$

Raskite kriterijų (t. y. raskite funkcijas $\varphi_i(\mathbf{X})$, $i = 1, 2, 0$), tenkinantį sąlygas $\alpha_{12} \leq \alpha$, $\alpha_{21} \leq \beta$ ir minimizujantį tikimybes

$$\alpha_{02} = \mathbf{P}\{\eta = 0 | \theta = 2\} = \mathbf{E}(\varphi_0(\mathbf{X}) | \theta = 2), \quad \alpha_{01} = \mathbf{P}\{\eta = 0 | \theta = 1\} = \mathbf{E}(\varphi_0(\mathbf{X}) | \theta = 1).$$

I.3.16. (I.3.15 pratimo tēsinys). Tegu apriorinės hipotezių H ir \bar{H} tikimybės yra ω_1 ir ω_2 ($\omega_1 + \omega_2 = 1$) ir β_{21} ir β_{12} – posteriorinės tikimybės:

$$\beta_{21} = \mathbf{P}\{\theta = 2 | \eta = 1\} = \frac{\alpha_{12}\omega_2}{\alpha_{12}\omega_2 + (1 - \alpha_{01} - \alpha_{21})\omega_1},$$

$$\beta_{12} = \mathbf{P}\{\theta = 1 | \eta = 2\} = \frac{\alpha_{21}\omega_1}{\alpha_{21}\omega_1 + (1 - \alpha_{02} - \alpha_{12})\omega_2}.$$

Raskite kriterijų, tenkinantį sąlygas $\beta_{21} \leq b_2$, $\beta_{12} \leq b_1$ ir minimizujantį tikimybes α_{01} , α_{02} .

I.3.17. Tegu H_0 ir H_1 yra paprastosios hipotezės ir reikšmingumo lygmuo $\alpha \in (0, 1)$. Be to, φ_* yra tolygiai galingiausias α lygmens kriterijus hipotezei H_0 , kai alternatyva yra H_1 , tikrinti, o kriterijaus galia $\beta < 1$, kai H_1 teisinga. Irodykite, kad $1 - \varphi_*$ yra tolygiai galingiausias $1 - \beta$ lygmens kriterijus hipotezei H_1 , kai alternatyva yra H_0 , tikrinti.

I.3.18. Tegu X yra vienetinė imtis iš skirstinio, kurio tankio funkcija lygi $f_\theta(x)$. Raskite galingiausią lygmens $\alpha \in (0, 1/2)$ kriterijų hipotezei $H_0 : \theta = \theta_0$, kai alternatyva yra $H_1 : \theta = \theta_1$, tikrinti tokiaisiai atvejais:

- a) $f_\theta(x) = 2\theta^{-2}(\theta - x)$, $0 < x < \theta$, $\theta_0 < \theta_1$;
- b) $f_\theta(x) = 2[\theta x + (1 - \theta)(1 - x)]$, $0 < x < 1$, $0 \leq \theta_1 < \theta_0 \leq 1$;
- c) $f_{\theta_0}(x) = 4xI_{(0, 1/2)}(x) + 4(1 - x)I_{(1/2, 1)}(x)$ ir $f_{\theta_1}(x) = I_{(0, 1)}(x)$.

I.3.19. Tegu X_1, \dots, X_n nepriklausomi vienodai pasiskirstę a. d., kurių tankio funkcija $f_\theta(x)$. Raskite galingiausią lygmens α kriterijų hipotezei $H_0 : \theta = \theta_0$, kai alternatyva yra $H_1 : \theta = \theta_1$, tikrinti tokiaisiai atvejais:

- a) $f_\theta(x) = e^{-(x-\theta)}$, $\theta < x < \infty$, $\theta_0 < \theta_1$;
- b) $f_\theta(x) = \theta x^{-2}$, $\theta < x < \infty$, $\theta_0 > \theta_1$.

I.3.20. Imtis $\mathbf{X} = (X_1, \dots, X_n)^T$ gauta stebint Bernulio a. d. $B(1, p)$. Sudarykite kriterijų hipotezei $H : p = 0$, kai alternatyva yra $\bar{H} : p = 0,01$, tikrinti. Raskite mažiausiajį imties didumą n , kad pirmosios ir antrosios rūšies klaidų tikimybės neviršytų 0,01.

I.3.3. Skirstiniai, priklausantys nuo vieno parametru

I.3.21. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < \infty$, o $0 < \sigma$ – žinomas. a) Raskite reikšmingumo lygmens α hipotezės $H : \mu = \mu_0$, kai alternatyvos yra $\bar{H}_1 : \mu > \mu_0$ arba $\bar{H}_2 : \mu < \mu_0$, tikrinimo TG kriterijus ir jų galios funkcijas. b) Raskite TGN kriterijų, kai alternatyva dvipusė $\bar{H}_3 : \mu \neq \mu_0$, ir jo galios funkciją.

I.3.22. (I.3.21 pratimo tēsinys). Suformuluokite I.3.21 pratime gautus kriterijus pasiklivimo intervalų terminais.

I.3.23. (I.3.21 pratimo tēsinys). Suformuluokite I.3.21 pratime gautus kriterijus P reikšmių terminais.

I.3.24. (I.3.21 pratimo tēsinys). Remiantis tuo, kad kriterijų galios funkcijos priklauso ne tik nuo skirtumo $\mu - \mu_0$, bet ir nuo imties didumo n , išspręskite tokį eksperimento planavimo uždavinį. Tikrinama hipotezė $H : \mu = \mu_0$, kai alternatyva yra $\bar{H}_1 : \mu > \mu_0$. a) Raskite tokį imties didumą n , kad hipotezė H būtų priimama su tikimybe, ne didesne

už α' , kai $\mu \geq \mu' > \mu_0$. b) Raskite imties didumą, kai $\alpha = 0,05; \alpha' = 0,01; \sigma^2 = 4; \mu' = \mu_0 + 0,5$.

I.3.25. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a.d. $X \sim N(\mu, \sigma^2)$, $0 < \sigma$, o vidurkis μ žinomas. a) Raskite reikšmingumo lygmens α hipotezės $H : \sigma^2 = \sigma_0^2$, kai alternatyvos yra $\bar{H}_1 : \sigma^2 > \sigma_0^2$ arba $\bar{H}_2 : \sigma^2 < \sigma_0^2$, tikrinimo TG kriterijus ir jų galios funkcijas. b) Raskite TGN kriterijų, kai alternatyva dvipusė $\bar{H}_3 : \sigma^2 \neq \sigma_0^2$. c) Dvipusės alternatyvos atveju suformuluokite paslinktą, tačiau paprasčiau randamą simetrišką kriterijų.

I.3.26. (I.3.25 pratimo tésinys). Dvipusės alternatyvos atveju palyginkite TGN ir simetriško kriterijaus galią, kai $n = 10; 20; 50$ ir $\lambda = \sigma^2/\sigma_0^2 = 0,5; 0,75; 1; 1,25; 1,5$, o kriterijaus reikšmingumo lygmuo $\alpha = 0,05$.

I.3.27. (I.3.25 pratimo tésinys). Suformuluokite I.3.25 pratime gautus kriterijus a) pasiklivimo intervalų terminais; b) P reikšmių terminais.

I.3.28. (I.3.25 pratimo tésinys). Reikšmingumo lygmens $\alpha = 0,05$ kriterijumi tikrinama hipotezė $H : \sigma^2 = \sigma_0^2$, kai alternatyva yra $\bar{H}_1 : \sigma^2 > \sigma_0^2$. Raskite tokį imties didumą n , kad hipotezė H būtų atmetama su tikimybe, ne mažesne už 0,9, kai tikroji parametru σ^2 tenkina nelygybę $\sigma^2 \geq 1,5\sigma_0^2$.

I.3.29. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a.d. X , turintis Reléjaus skirstinį (žr. 1 priedo 1P1 lentelę) su parametru $\sigma > 0$. Raskite TG arba TGN kriterijus hipotezei $H : \sigma^2 = \sigma_0^2$ tikrinti vienpusių ir dvipusės alternatyvų atvejais.

I.3.30. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a.d. X , turinti Maksvelo skirstinį (žr. 1 priedo 1P1 lentelę) su parametru $\sigma > 0$. Raskite TG arba TGN kriterijus hipotezei $H : \sigma^2 = \sigma_0^2$ tikrinti vienpusių ir dvipusės alternatyvų atvejais.

I.3.31. Tarkime, imties X_1, \dots, X_n elementai yra n. a. d., turintys gama skirstinius $X_i \sim G(\lambda, \eta_i)$, $0 < \lambda$, o η_1, \dots, η_n žinomi, $\eta_1 + \dots + \eta_n = \eta$. a) Raskite reikšmingumo lygmens α hipotezės $H : \lambda = \lambda_0$, kai alternatyvos yra $\bar{H}_1 : \lambda > \lambda_0$ arba $\bar{H}_2 : \lambda < \lambda_0$, TG kriterijus. b) Raskite TGN kriterijų, kai alternatyva dvipusė $\bar{H}_3 : \lambda \neq \lambda_0$. c) Dvipusės alternatyvos atveju suformuluokite paslinktą, tačiau paprasčiau randamą simetrišką kriterijų.

I.3.32. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint a.d. $X \sim \mathcal{P}(\lambda)$, $0 < \lambda$. a) Raskite reikšmingumo lygmens α TG kriterijus hipotezei $H : \lambda = \lambda_0$, kai alternatyvos yra $\bar{H}_1 : \lambda > \lambda_0$ arba $\bar{H}_2 : \lambda < \lambda_0$. b) Remdamiesi [2], 4.1.3 pastaba suformuluokite nerandomizuotus kriterijus.

I.3.33. (I.3.32 pratimo tésinys). a) Raskite TGN kriterijų dvipusės alternatyvos $\bar{H}_3 : \lambda \neq \lambda_0$ atveju. b) Suformuluokite simetrišką kriterijų atsisakius randomizacijos.

I.3.34. (I.3.32 pratimo tésinys). Tarkime, pagal didumo $n = 40$ paprastąją imtį gauta parametru λ NMD įvertinio realizacija $\hat{\lambda} = 2,0$. Reikšmingumo lygmens $\alpha = 0,05$ kriterijumi patikrinkite hipotezę $H : \lambda \geq 2,5$, kai alternatyva yra $\bar{H}_2 : \lambda < 2,5$.

I.3.35. Tarkime, paprastoji imtis X_1, \dots, X_n gauta stebint Bernulio a.d. $X \sim B(1, p)$, $0 < p < 1$. a) Raskite reikšmingumo lygmens α TG kriterijus hipotezei $H : p = p_0$, kai alternatyvos yra $\bar{H}_1 : p > p_0$ arba $\bar{H}_2 : p < p_0$, tikrinti ir TGN kriterijų, kai alternatyva dvipusė. b) Suformuluokite nerandomizuotus ir simetriškus kriterijus.

I.3.36. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a.d. X , kurio skirstinys priklauso Bernulio skirstinių šeimai $\mathcal{P} = \{B(1, p), 0 < p < 1\}$. Reikia patikrinti hipotezę

$H : p \leq p_0$, kai alternatyva yra $\bar{H} : p > p_0$. Raskite TG kriterijaus galios $\beta(p)$ reikšmes taškuose $p = 0,3, 0,4, 0,5, 0,6$, kai $n = 6$, $p_0 = 0,25$ ir kriterijaus reikšmingumo lygmuo $\alpha = 0,05; 0,1; 0,2$. Naudodami nerandomizuotą kriterijų raskite minimalų imties didumą n , kad kriterijaus galia $\beta(p)$ tenkintų nelygybę $\beta(p) \geq 0,9$, kai $p \geq p_1$, ir: a) $p_0 = 0,2$, $p_1 = 0,4$; b) $p_0 = 0,02$, $p_1 = 0,04$, o kriterijaus reikšmingumo lygmuo $\alpha = 0,1$.

I.3.37. Eksperimentais nustatyta, kad gamykla pagamina vidutiniškai 5 procen-tus defektinės produkcijos. Iš 50 atsitiktinai paimtų gaminiių 6 gaminiai buvo defek-tuoti. Patikrinkite prielaidą, kad defektuotų gaminiių procentas padidėjo. Kriterijaus reikšmingumo lygmuo $\alpha = 0,05$.

I.3.38. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę Bernilio a. d. $B(1, p)$. Raskite α lygmens TGN kriterijų hipotezei $H_0 : p = p_0$, kai alternatyva yra $H_1 : p \neq p_0$, tikrinti, kai

- a) $n = 10$, $\alpha = 0,1$ ir $p_0 = 0,2$;
- b) $n = 10$, $\alpha = 0,05$ ir $p_0 = 0,4$.

I.3.39. Tegu X yra a. d., turintis geometrinį skirstinį. Raskite α lygmens TGN kriterijų hipotezei $H_0 : p = p_0$, kai alternatyva yra $H_1 : p \neq p_0$, tikrinti.

I.3.40. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. X , kurio skirstinys priklauso tolygiųjų skirstinių šeimai $\mathcal{P} = \{U(0, \theta), 0 < \theta < \infty\}$. Raskite TG kriterijus hipotezei $H : \theta = \theta_0$, esant vienpusėms ir dvipusei alternatyvoms, tikrinti.

I.3.41. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. X , kurio skirstinys priklauso eksponentinių skirstinių šeimai $\mathcal{P} = \{f(x; \mu, \sigma), -\infty < \mu < \infty, 0 < \sigma < \infty\}$; čia tankis

$$f(x; \mu, \sigma) = \sigma e^{-\sigma(x-\mu)}, \quad \mu < x < \infty.$$

Raskite TG kriterijų hipotezėms

- a) $H : \sigma = \sigma_0$, kai μ žinomas;
 - b) $H : \mu = \mu_0$, kai σ žinomas,
- esant vienpusėms alternatyvoms, tikrinti.

I.3.42. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę a. d., kurių tankio funkcija $f_\theta(x)$, $\theta \in \Theta \subset \mathbf{R}$. Raskite tolygiai galingiausią α lygmens kriterijų hipotezei $H_0 : \theta \leq \theta_0$, kai alternatyva yra $H_1 : \theta > \theta_0$, tikrinti tokiais atvejais:

- a) $f_\theta(x) = \theta^{-1} e^{-x/\theta}, 0 < x < \infty, \theta > 0$;
- b) $f_\theta(x) = \theta x^{\theta-1}, 0 < x < 1, \theta > 0$;
- c) f_θ yra $N(1, \theta)$ skirstinio tankio funkcija;
- d) $f_\theta(x) = \theta^{-c} c x^{c-1} e^{-(x/\theta)^c}, 0 < x < \infty, \theta > 0$; čia $c > 0$ – žinomas.

I.3.43. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę a. d., turintys tolygūjį skirstinį $U(\theta, \theta + 1)$, $\theta \in \mathcal{R}$. Tegu $n \geq 2$.

- a) Raskite bendrą $X_{(1)}$ ir $X_{(n)}$ skirstinį.
- b) Tegu tikrinant hipotezę $H : \theta = \theta_0$ taikomas toks kriterijus: hipotezė H priimama, kai $X_{(n)} - 1 < \theta_0 < X_{(1)}$. Koks šio kriterijaus reikšmingumo lygmuo?
- c) Raskite p. b) pateikto kriterijaus galią, kai $\theta > \theta_0$.
- d) Raskite imties didumą, kad p. b) apibrėžtas kriterijus atmestų hipotezę H su tikimybe, ne mažesne už 0,99, jei tikroji parametru θ reikšmė tenkina nelygybę $\theta \geq \theta_0 + 0,1$.

I.3.44. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji atsitiktinė imtis a. d. X , turinčio diskretųjį tolygųjį skirstinį, sukoncentruotą taškuose $0, 1, \dots, \theta$, kai nežinomas $\theta = 1, 2, \dots$

a) Tegu tikrinama hipotezė $H_0 : \theta \leq \theta_0$, kai alternatyva yra $H_1 : \theta > \theta_0$. Įrodykite, kad

$$\varphi_*(\mathbf{X}) = \begin{cases} 1, & X_{(n)} > \theta_0, \\ \alpha, & X_{(n)} \leq \theta_0 \end{cases}$$

yra α lygmens TG kriterijus.

b) Tegu tikrinama hipotezė $H_0 : \theta = \theta_0$, kai alternatyva yra $H_1 : \theta \neq \theta_0$. Įrodykite, kad

$$\varphi_*(\mathbf{X}) = \begin{cases} 1, & X_{(n)} > \theta_0 \text{ arba } X_{(n)} \leq \theta_0 \alpha^{1/n}, \\ 0, & \text{priesingu atveju} \end{cases}$$

yra α lygmens TG kriterijus.

c) Įrodykite, kad a) ir b) punktai išlieka teisingi, diskretųjį tolygųjį skirstinį pakeitus tolygiuoju skirstiniu $U(0, \theta)$, $\theta > 0$.

I.3.45. Įrodykite, kad šios šeimos turi monotoninį tikėtinumo santykį:

- a) Laplaso skirstinių šeima $\{L(\mu, \theta)\}$, kai θ žinomas;
- b) paslinktujų eksponentinių skirstinių šeima $\{\mathcal{E}(\theta, c)\}$, kai c žinomas;
- c) logistinių skirstinių šeima $\{LG(\theta, c)\}$, kai c žinomas;
- d) tolygiųjų skirstinių šeima $\{U(\theta, \theta + 1)\}$;
- e) hipergeometrinių skirstinių šeima $\{H(N, M, n)\}$, kai n ir N žinomi.

I.3.46. Įrodykite, kad šeima $\{f_\theta : \theta \in \mathbf{R}\}$, kai $f_\theta(x) = c(\theta)h(x)$, $a(\theta) < x < b(\theta)$, turi monotoninį tikėtinumo santykį; čia $h(x)$ yra pagal Lebego matą integruiojama teigiamą funkcija, $a(\theta) < b(\theta)$ yra nemažėjančios θ funkcijos.

I.3.47. Tegu X turi vienparametrij eksponentinio tipo skirstinį. Įrodykite, kad TG kriterijus, kai alternatyvos dvipusės, neegzistuoja.

I.3.48. Paprastoji imtis $\mathbf{X} = (X_1, \dots, X_n)^T$ gauta stebint a. d. $X \sim N(\mu, k\mu)$, $\mu > 0$, k – žinoma teigiamą konstantą. Sudarykite kriterijų hipotezei $H : \mu = \mu_0$, kai alternatyva yra $\bar{H} : \mu > \mu_0$, tikrinti. Tarę, kad n didelis, raskite apytiksles kritinės srities ir galios funkcijos išraiškas.

I.3.49. (I.3.48 pratimo tésinys.) Tarę, kad žinomas tik vidurkis \bar{X} , raskite TG kriterijų hipotezei $H : \mu = \mu_0$, kai alternatyva yra $\bar{H} : \mu > \mu_0$, tikrinti, grindžiamą statistika \bar{X} . Raskite kriterijaus galios funkciją.

I.3.50. Atsitiktinis dydis X įgyja sveikasias neneigiamas reikšmes ir jo pasiskirstymo funkcija

$$F(x|\beta) = \mathbf{P}_\beta\{X \leq x\} = 1 - \beta^x, \quad 0 < \beta < 1, \quad x = 0, 1, 2, \dots$$

Raskite kriterijų hipotezei $H : \beta = \beta_0$, kai alternatyva yra $\bar{H} : \beta > \beta_0$, tikrinti.

I.3.4. Skirstiniai, priklausantys nuo keleto parametrų

I.3.51. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < \infty$, $0 < \sigma$, kai abu parametrai nežinomi. Raskite reikšmingumo lygmens α hipotezės $H : \mu = \mu_0$, kai alternatyvos yra $\bar{H}_1 : \mu > \mu_0$ arba $\bar{H}_2 : \mu < \mu_0$, tikrinimo TGN kriterijus.

I.3.52. (I.3.51 pratimo tésinys). Raskite reikšmingumo lygmens α TGN kriterijų tikrindami hipotezę $H : \mu = \mu_0$, kai alternatyva dvipusė $\bar{H}_3 : \mu \neq \mu_0$.

I.3.53. (I.3.51 pratimo tēsinys). Raskite reikšmingumo lygmens α TGN kriterijų tikrindami hipotezę $H : \sigma^2 = \sigma_0^2$, kai alternatyvos vienpusės

$$\bar{H}_1 : \sigma^2 > \sigma_0^2 \text{ arba } \bar{H}_2 : \sigma^2 < \sigma_0^2.$$

I.3.54. (I.3.51 pratimo tēsinys). Raskite reikšmingumo lygmens α TGN kriterijų tikrindami hipotezę $H : \sigma^2 = \sigma_0^2$, kai alternatyva dvipusė $\bar{H}_3 : \sigma^2 \neq \sigma_0^2$.

I.3.55. Remiantis didumo n imtimi, tikrinama hipotezė $H : \mu = 0$ apie normaliojo skirstinio vidurkio reikšmę, esant alternatyvai $\bar{H}_1 : \mu > 0$ arba alternatyvai $\bar{H}_3 : \mu \neq 0$, kai σ nežinomas. Įrodykite, kad kriterijaus galia yra didėjanti μ/σ funkcija, kai alternatyva yra \bar{H}_1 , ir didėjanti $|\mu|/\sigma$ funkcija, kai alternatyva yra \bar{H}_3 .

I.3.56. (I.3.55 pratimo tēsinys). Įrodykite, kad kriterijus, kurio reikšmingumo lygmuo yra α ir kurio galia, esant visoms alternatyvoms $\{(\mu, \sigma) : \mu > \mu_1 > 0\}$, yra ne mažesnė už β , $\beta > \alpha$, neegzistuoja.

I.3.57. (I.3.55 pratimo tēsinys). Kai alternatyva yra \bar{H}_1 , Stjudento kriterijaus galia palyginkite su atitinkamo kriterijaus, kai σ žinomas, galia, jei $n = 5; 10; 15$ ir $\mu/\sigma = 0,8; 1,0; 1,2$ (kriterijų reikšmingumo lygmuo $\alpha = 0,05$).

I.3.58. Tegu X_1, X_2, \dots, X_n yra nepriklausomi normalieji atsitiktiniai dydžiai $X_i \sim N(\mu_i, \sigma^2)$, $i = 1, \dots, s$ ir $X_i \sim N(0, \sigma^2)$, $i = s+1, \dots, n$; čia $-\infty < \mu_i < \infty$, $i = 1, \dots, s$; $0 < \sigma < \infty$. Raskite TGN kriterijus hipotezei $H : \mu_1 = \mu_1^0$, esant vienpusėmis ir dvipusei alternatyvoms, tikrinti.

- a) $H_0 : \beta_0 \leq \theta_0$, kai alternatyva $H_1 : \beta_0 > \theta_0$;
- b) $H_0 : \beta_0 = \theta_0$, kai alternatyva $H_1 : \beta_0 \neq \theta_0$;
- c) $H_0 : \beta_1 \leq \theta_0$, kai alternatyva $H_1 : \beta_1 > \theta_0$;
- d) $H_0 : \beta_1 = \theta_0$, kai alternatyva $H_1 : \beta_1 \neq \theta_0$.

I.3.60. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę a. d., turintys gama skirstinį $G(\lambda, \eta)$ su nežinomais λ ir η .

a) Įrodykite, kad tikrinant hipotezę $H_0 : \gamma \leq \gamma_0$, kai alternatyva yra $H_1 : \gamma > \gamma_0$, TGN kriterijus atmeta H_0 , kai $\prod_{i=1}^n X_i > g(\bar{X})$; čia g – tam tikra reali funkcija.

b) Įrodykite, kad tikrinant hipotezę $H_0 : \eta \leq \eta_0$, kai alternatyva yra $H_1 : \eta > \eta_0$, TGN kriterijus atmeta H_0 , kai $\bar{X} > h(\prod_{i=1}^n X_i)$; čia h – tam tikra reali funkcija.

I.3.61. Tarkime, $\mathbf{X} = (X_1, \dots, X_n)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ yra nepriklausomos paprasostos imtys, gautos stebint n. a. d. $\mathbf{X} \sim N(\mu_1, \sigma_1^2)$ ir $\mathbf{Y} \sim N(\mu_2, \sigma_2^2)$. Raskite reikšmingumo lygmens α TGN kriterijus tikrindami hipotezę $H : \mu_1 - \mu_2 = \beta_0$ su vienpusėmis ir dvipuse alternatyvomis, kai dispersijos yra žinomos $\sigma_1^2 = \sigma_{10}^2, \sigma_2^2 = \sigma_{20}^2$.

I.3.62. (I.3.61 pratimo tēsinys). Raskite reikšmingumo lygmens α TGN kriterijus tikrindami hipotezę $H : \mu_1 - \mu_2 = \beta_0$ su vienpusėmis ir dvipuse alternatyvomis, kai dispersijos yra lygios $\sigma_1^2 = \sigma_2^2 = \sigma^2$.

I.3.63. (I.3.61 pratimo tēsinys). Raskite reikšmingumo lygmens α TGN kriterijus tikrindami hipotezę $H : \sigma_1^2 = \sigma_2^2$ su vienpusėmis ir dvipuse alternatyvomis.

I.3.64. Tarkime, $(X_i, Y_i)^T, i = 1, \dots, n$, yra paprastoji imtis a. v. $(X, Y)^T \sim N_2(\boldsymbol{\mu}, \Sigma)$, $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, $\Sigma = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = \sigma_1^2$, $\sigma_{22} = \sigma_2^2$, $\sigma_{12} = \rho\sigma_1\sigma_2$. Raskite TGN reikšmingumo lygmens α kriterijus a. d. X ir Y nepriklausomumo hipotezei $H : \rho = 0$ tikrinti vienpusių ir dvipusės alternatyvų atvejais.

I.3.65. (I.3.64 pratimo tēsinys). a) Raskite reikšmingumo lygmens α tikėtinumų santykio kriterijų hipotezei $H : \rho = \rho_0 \neq 0$ tikrinti, kai alternatyva $\bar{H}_3 : \rho \neq \rho_0$, b) Pasiūlykite paprasčiau randamą simetrišką kriterijų. c) Pateikite kriterijus vienpusių alternatyvų atvejais.

I.3.66. (I.3.64 pratimo tēsinys). Raskite reikšmingumo lygmens α apytikslius kriterijus hipotezei $H : \rho = \rho_0 \neq 0$ tikrinti vienpusių ir dvipusės alternatyvų atvejais naudodami Fišerio dispersijų stabilizuojančią transformaciją.

I.3.67. (I.3.64 pratimo tēsinys). Raskite reikšmingumo lygmens α kriterijus hipotezei $H : \mu_1 = \mu_2 = \beta_0$ tikrinti vienpusių ir dvipusės alternatyvų atvejais.

I.3.68. Tarkime, paprastosios imtys $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ gautos stebint n. a. d. $X \sim \mathcal{P}(\lambda_1)$ ir $Y \sim \mathcal{P}(\lambda_2)$. Raskite reikšmingumo lygmens α TGN kriterijus hipotezei $H : \lambda_1/\lambda_2 = c_0$ tikrinti vienpusių ir dvipusės alternatyvų atvejais.

I.3.69. (I.3.68 pratimo tēsinys). Per pirmają ir antrają valandas į komutatorių buvo kreiptasi atitinkamai 15 ir 13 kartų. Kitą dieną per 5 valandas buvo kreiptasi 45 kartus. Tarus, kad iškvietimų skaičiai pasiskirstę pagal Puasono dėsnį su parametru λ (vidutinis iškvietimų skaičius per valandą), reikia patikrinti, ar iškvietimų intensyvumas nepakito (kriterijaus reikšmingumo lygmuo $\alpha = 0,05$).

I.3.70. Tegu X_1 ir X_2 yra nepriklausomi a. d., turintys Puasono skirstinius $\mathcal{P}(\lambda_1)$ ir $\mathcal{P}(\lambda_2)$.

a) Raskite α lygmens TGN kriterijų hipotezei $H_0 : \lambda_1 \geq \lambda_2$, kai alternatyva yra $H_1 : \lambda_1 < \lambda_2$, tikrinti.

b) Apskaičiuokite punkte a) gauto kriterijaus galia, kai $\alpha = 0,1$, $(\lambda_1, \lambda_2) = (0, 1, 0, 2)$; $(1, 2)$; $(10, 20)$; $(0, 1, 0, 4)$.

I.3.71. Tarkime, paprastosios imtys $\mathbf{X} = (X_1, \dots, X_m)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ gautos stebint n. a. d. $X \sim B(1, p_1)$ ir $Y \sim B(1, p_2)$. Raskite reikšmingumo lygmens α TGN kriterijus hipotezei $H : p_1 = p_2$ tikrinti vienpusių ir dvipusės alternatyvų atvejais.

I.3.72. (I.3.71 pratimo tēsinys). Vienos brigados 20 darbininkų buvo paskieptyti nuo gripo, per 6 mėnesius iš jų susirgo 6 darbininkai. Tos pačios brigados 5 darbininkai skiepytis atsisakė, 4 iš jų susirgo per tą patį 6 mėnesių laikotarpį. Ar galima daryti išvadą apie teigiamą priešgripinio serumo poveikį?

I.3.73. Tegu $\mathbf{X}_1 = X_{11}, \dots, X_{1n_1}$ ir $\mathbf{X}_2 = X_{21}, \dots, X_{2n_2}$ yra dvi nepriklausomos imtys vienodai pasiskirsčiusių n. a. d., turinčių atitinkamai gama skirstinius $\Gamma(\theta_1, \gamma_1)$ ir $\Gamma(\theta_2, \gamma_2)$.

Tegu γ_1 ir γ_2 žinomi. Įrodykite, kad, tikrinant hipotezę $H_0 : \theta_1 \leq \theta_2$, kai alternatyva yra $H_1 : \theta_1 > \theta_2$, ir hipotezę $H_0 : \theta_1 = \theta_2$, kai alternatyva $H_1 : \theta_1 \neq \theta_2$, egzistuoja TGN kriterijai, kurių statistiką skirstiniai išreiškiami beta skirstiniai.

I.3.74. Tegu $(X_i, Y_i)^T, i = 1, \dots, n$, yra paprastoji atsitiktinė imtis dvimacojo normaliojo a. v. $(X, Y)^T \sim N_2(\boldsymbol{\mu}, \Sigma)$, $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$, $-\infty < \mu_1, \mu_2 < \infty$, $\Sigma = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = \sigma_1^2$, $\sigma_{22} = \sigma_2^2$, $\sigma_{12} = \sigma_{21} = \rho\sigma_1\sigma_2$, $0 < \sigma_1, \sigma_2 < \infty$, $-1 < \rho < 1$.

Be to, $S_{11} = \sum_i (X_i - \bar{X})^2$, $S_{22} = \sum_i (Y_i - \bar{Y})^2$ ir $S_{12} = \sum_i (X_i - \bar{X})(Y_i - \bar{Y})$.

a) Įrodykite, kad TGN kriterijus hipotezei $H_0 : \sigma_2/\sigma_1 = \Delta_0$, kai alternatyva yra $H_1 : \sigma_2/\sigma_1 \neq \Delta_0$, tikrinti atmeta H_0 , kai

$$R = |\Delta_0^2 S_{11} - S_{22}| / \sqrt{(\Delta_0^2 S_{11} + S_{22})^2 - 4\Delta_0^2 S_{12}^2} > c.$$

- b) Raskite R iš a) punkto skirstinį, kai $\sigma_2/\sigma_1 = \Delta_0$.
c) Tegu $\sigma_1 = \sigma_2$. Įrodykite, kad TGN kriterijus hipotezei $H_0 : \mu_1 = \mu_2$, kai alternatyva yra $H_1 : \mu_1 \neq \mu_2$, tikrinti atmeta H_0 , kai

$$V = |\bar{X}_2 - \bar{X}_1| / \sqrt{S_1^2 + S_2^2 - 2S_{12}} > c.$$

- d) Raskite punkto c) a. d. V skirstinį, kai $\mu_1 = \mu_2$.

I.3.75. Tegu X_1, \dots, X_n yra nepriklausomi vienodai pasiskirstę a. d., turintys pa-

slinktajį eksponentinį skirstinį $\mathcal{E}(a, \theta)$ su nežinomais a ir θ .
a) Įrodykite, kad tikrinant $H_0 : \theta = 1$, kai alternatyva yra $H_1 : \theta \neq 1$, α lygmens TGN kriterijus atmeta H_0 , kai $V < c_1$ arba $V > c_2$; čia $V = 2 \sum_{i=1}^n (X_i - \bar{X}_{(1)}) = 2n(\bar{X} - \bar{X}_{(1)})$, o c_i apibrėžti taip:

$$\int_{c_1}^{c_2} f(x|2n-2)dx = \int_{c_1}^{c_2} f(x|2n)dx = 1 - \alpha,$$

$f(x|\nu)$ yra χ^2 skirstinio su ν laisvės laipsnių tankio funkcija.

b) Įrodykite, kad, tikrinant hipotezę $H_0 : a = 0$, kai alternatyva yra $H_1 : a \neq 0$, lygmens α TGN kriterijus atmeta H_0 , kai $X_{(1)} < 0$ arba $2nX_{(1)}/V > c(n-1)$; čia c randamas iš lygties

$$(n-1) \int_0^c (1+v)^{-n} dv = 1 - \alpha.$$

I.3.5. Hipotezių tikrinimas, kai imtys didelės

I.3.76. Tegu X_{i1}, \dots, X_{in_i} , $i = 1, \dots, k$, $n_i \geq 2$, yra k paprastujų nepriklausomų imčių eksponentinių a. d. X_1, \dots, X_k , kurių tikimybiniai tankiai yra

$$\frac{1}{\sigma_i} \exp\left\{-\frac{x - \theta_i}{\sigma_i}\right\}, \quad \theta_i < x < \infty, \quad i = 1, \dots, k;$$

čia $0 < \sigma_i < \infty$, $-\infty < \theta_i < +\infty$, $i = 1, \dots, k$.

Raskite tikėtinumų santykį, kai tikrinama hipotezė: a) $H_1 : \theta_1 = \theta_2 = \dots = \theta_k$; b) $H_2 : \sigma_1 = \dots = \sigma_k$; c) $H_3 : \theta_1 = \dots = \theta_k$, kai visi σ_i yra lygūs.

I.3.77. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis a. d. $X \sim N(\mu, \sigma^2)$, $-\infty < \mu < +\infty$, $0 < \sigma < +\infty$. Įrodykite, kad: a) tikėtinumų santykio kriterijus hipotezei $H : \mu = \mu_0$ tikrinti yra ekvivalentus Stjudento kriterijui; b) tikėtinumų santykio kriterijus hipotezei $H : \sigma^2 = \sigma_0^2$ tikrinti yra ekvivalentus χ^2 kriterijui.

I.3.78. Tegu $(X_{1i}, \dots, X_{ki})^T$, $i = 1, \dots, n$, yra imtis vektorius $(X_1, \dots, X_k)^T$, kurio skirstinys priklauso polinominių skirstinių šeimai $\{\mathcal{P}_k(1, \boldsymbol{\pi})\}$; čia $\boldsymbol{\pi} = (\pi_1, \dots, \pi_k)^T$ yra

k -matis vektorius, kurio koordinatės tenkina sąlygas $0 < \pi_i < 1$, $\pi_1 + \dots + \pi_k = 1$. Irodykite, kad tikétinumų santykis hipotezei $H : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$ tikrinti yra

$$\Lambda = \left(\prod_{i=1}^k \left(\frac{\pi_i^0}{\hat{\pi}_i} \right)^{\hat{\pi}_i} \right)^n;$$

čia $\hat{\pi}_i = V_i/n$, $V_i = X_{i1} + \dots + X_{in}$, $i = 1, \dots, k$.

I.3.79. (I.3.78 pratimo tēsinys). Irodykite, kad statistikų $-2 \ln \Lambda$ ir $\sum_i (V_i - n\pi_i^0)^2 / n\pi_i^0$ skirstiniai, kai hipotezė H yra teisinga, silpnai konverguoja į χ^2 skirstinį su $k-1$ laisvės laipsniu.

I.3.80. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra nepriklausomos paprastosios a. d. $X \sim N(\mu_1, \sigma_1^2)$ ir $Y \sim N(\mu_2, \sigma_2^2)$ imtys. Irodykite, kad: a) tikétinumų santykio kriterijus hipotezei $H : \mu_1 = \mu_2$, kai alternatyva yra $\bar{H} : \mu_1 \neq \mu_2$, tikrinti, kai $\sigma_1^2 = \sigma_2^2$, yra ekvivalentus Stjudento kriterijui; b) tikétinumų santykio kriterijus hipotezei $H : \sigma_1^2 = \sigma_2^2$, kai alternatyva yra $\bar{H} : \sigma_1^2 \neq \sigma_2^2$, tikrinti ekvivalentus Fišerio kriterijui.

I.3.81. Tegu $(X_{i1}, \dots, X_{in})^T$, $i = 1, \dots, k$, yra k paprastujų nepriklausomų imčių, gautų stebint normaliuosius a. d. $X_i \sim N(\mu_i, \sigma_i^2)$. Irodykite, kad tikétinumų santykio kriterijus hipotezei $H : \mu_1 = \dots = \mu_k$ tikrinti, kai $\sigma_1^2 = \dots = \sigma_k^2$, yra ekvivalentus kriterijui, grindžiamam statistika

$$F = \frac{(n-k) \sum_{i=1}^k n_i (\bar{X}_{i.} - \bar{X})^2}{k \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{i.})^2},$$

kurios skirstinys, kai H teisinga, yra Fišerio $F(k, n-k)$, $n = n_1 + \dots + n_k$,

$$\bar{X}_{i.} = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij}, \quad \bar{X} = \frac{1}{n} \sum_{i=1}^k n_i \bar{X}_{i.}.$$

I.3.82. Tegu $(X_1, \dots, X_{n_1})^T$ ir $(Y_1, \dots, Y_{n_2})^T$ yra paprastosios nepriklausomos imtys a. d. $X \sim B(1, p_1)$, $0 < p_1 < 1$, ir $Y \sim B(1, p_2)$, $0 < p_2 < 1$. Raskite tikétinumų santykį Λ hipotezei $H : p_1 = p_2$ tikrinti ir irodykite, kad $-2 \ln \Lambda \xrightarrow{d} \chi^2(1)$, kai $n_1, n_2 \rightarrow \infty$, ir H yra teisinga.

I.3.83. Apibendrinkite I.3.82 pratimą ir jo sprendimą tuo atveju, kai imčių skaičius didesnis už 2.

I.3.84. Tegu $(X_1, \dots, X_{n_1})^T$ ir $(Y_1, \dots, Y_{n_2})^T$ yra paprastosios nepriklausomos imtys a. d. $X \sim \mathcal{P}(\lambda_1)$, $0 < \lambda_1 < \infty$, ir $Y \sim \mathcal{P}(\lambda_2)$, $0 < \lambda_2 < \infty$. Raskite tikétinumų santykį Λ hipotezei $H : \lambda_1 = \lambda_2$ tikrinti ir irodykite, kad $-2 \ln \Lambda \xrightarrow{d} \chi^2(1)$, kai $n_1, n_2 \rightarrow \infty$, ir H yra teisinga.

I.3.85. Apibendrinkite I.3.84 pratimą tuo atveju, kai imčių skaičius didesnis už 2.

I.3.86. Tegu $(X_1, \dots, X_{n_1})^T$ ir $(Y_1, \dots, Y_{n_2})^T$ yra paprastosios nepriklausomos imtys a. d. X ir Y , turinčių eksponentinius skirstinius $X \sim \mathcal{E}(1/\theta_1)$ ir $Y \sim \mathcal{E}(1/\theta_2)$, $0 < \theta_1, \theta_2 < \infty$. Raskite statistikos \bar{X}/\bar{Y} skirstinį. Irodykite, kad tikétinumų santykio hipotezei $H : \theta_1 = \theta_2$ tikrinti statistikos yra \bar{X}/\bar{Y} funkcijos. Raskite kriterijų galia.

I.3.87. Atlikti 500 nepriklausomų stebėjimų ir jie sugrupuoti į intervalus; m_i – stebėjimų, patekusiu į atitinkamą intervalą, skaičius.

Intervalas	m_i
$(-\infty, -3/2)$	2
$[-3/2, -1/2)$	78
$[-1/2, 1/2)$	339
$(1/2, \infty)$	81

Ar nepriestarauja šie duomenys prielaidai, kad buvo sugrupuota paprastosios atsitiktinio dydžio $X \sim N(0, 1/4)$ imties realizacija?

I.3.88. Lentelėje iš 2 000 atsitiktinių skaičių skaitmuo 0 aptinkamas 160 kartų, skaitmuo 3 – 247 kartus, skaitmuo 6 – 191 kartą, o likusieji skaitmenys – 1 402 kartus. Ar nepriestarauja šie duomenys prielaidai, kad skaitmenys 0,1,...,9 pasitaiko su vienodomis tikimybėmis $1/10$?

I.3.89. Tarp 2 020 šeimų, turinčių du vaikus, užregistruota 527 šeimos, kuriose abu vaikai berniukai; 476 šeimos, kur abu vaikai mergaitės, o likusiose 1 017 šeimų – vienas berniukas ir viena mergaitė. Patikrinkite prielaidą apie berniuko ir mergaitės gimimo tikimybę lygį. Patikrinkite prielaidą, kad berniukų skaičius X šeimose, turinčiose du vaikus, yra binominis $X \sim B(2, p)$.

I.3.90. Atlikus 200 nepriklausomų bandymų, įvykiai A, B ir C pasirodė atitinkamai 49, 93 ir 58 kartus. Patikrinkite hipotezę, pagal kurią $\mathbf{P}\{A\} = \mathbf{P}\{C\} = p$, $\mathbf{P}\{B\} = 1 - 2p$, $0 < p < 1/2$.

I.3.91. Atlikus 8 000 nepriklausomų bandymų, įvykiai A, B ir C įvyko atitinkamai 2 018, 5 012 ir 970 kartų. Patikrinkite hipotezę, pagal kurią $\mathbf{P}\{A\} = 1/2 - 2p$, $\mathbf{P}\{B\} = 1/2 + p$, $\mathbf{P}\{C\} = p$, $0 < p < 1/4$.

I.3.6. Hipotezių tikrinimo pavyzdžiai

I.3.92. Tikrinama hipotezė $H : \mu = 1$, kai alternatyva yra $\bar{H} : \mu \neq 1$, remiantis a. d. $X \sim N(\mu, 4)$ paprastaja imtimi. Kokio didumo turi būti imtis, kad hipotezė H būtų atmetama su tikimybe 0,05, kai ji teisinga, ir priimama, kai tikroji parametru reikšmė tenkina nelygybę $|\mu - 1| \geq 1$ su tikimybe, ne didesne kaip 0,01?

I.3.93. Remiantis $n = 50$ didumo normaliojo skirstinio $N(0, \sigma^2)$ imtimi, tikrinama hipotezė $H : \sigma^2 = \sigma_0^2$, kai alternatyva yra $\bar{H} : \sigma^2 > \sigma_0^2$. Kokia tikimybė, kad ta hipotezė bus atuesta, jei tikroji parametru reikšmė σ^2 tenkina nelygybę $\sigma^2 > 1,5\sigma_0^2$, o kriterijaus reikšmingumo lygmuo $\alpha = 0,05$? Kokio didumo turi būti imtis, kad ta tikimybė būtų ne mažesnė už 0,95?

I.3.94. Tegu hipotezei $H : \sigma^2 = \sigma_0^2$, kai alternatyva yra $\bar{H} : \sigma^2 \neq \sigma_0^2$, tikrinti taikomas TGN kriterijus ir paslinktasis kriterijus. Raskite, kokio didumo turi būti imtys, kad kriterijų galios funkcijos būtų ne mažesnės už 0,9, kai $\sigma^2 \geq 2\sigma_0^2$ ir $\sigma^2 \leq \sigma_0^2/2$, o kriterijų reikšmingumo lygmuo yra 0,05.

I.3.95. Lentelėje pateikti duomenys apie dviejose fermose vienodo amžiaus kiaulių svorio prieaugį per tam tikrą laiką. Pirmoje ferme pamažuota $n_1 = 16$ kiaulių svorio prieaugis $X_i, i = 1, \dots, 16$; antroje ferme pamažuota $n_2 = 15$ kiaulių svorio prieaugis $Y_i, i = 1, \dots, 15$. Reikia patikrinti hipotezę, kad vidutinis svorio priaugis nesiskiria, kai alternatyva yra, jog pirmoje ferme vidutinis svorio priaugis yra didesnis.

I ferma				II ferma			
i	X_i	i	X_i	i	Y_i	i	Y_i
1	109,95	9	108,86	1	81,45	9	85,63
2	103,54	10	98,69	2	94,63	10	90,92
3	104,58	11	97,51	3	73,70	11	95,58
4	114,43	12	100,48	4	87,36	12	71,52
5	90,92	13	96,76	5	89,12	13	108,85
6	104,59	14	102,77	6	96,69	14	87,36
7	103,85	15	100,47	7	83,93	15	99,48
8	88,23	16	99,48	8	86,49		

Nurodymas. Iš lentelės matyti, kad a. d. skirstiniai asimetriški. Todėl reikėtų atlikti stebimojo dydžio transformaciją, kad naujo a. d. skirstinys būtų patenkinamai aprašomas normaliuoju skirstiniu, paskui remtis Stjudento kriterijumi. Nesunku išitikinti, kad nagrinėjamame pavyzdyje stebėjimų logaritmai tiksliau aprašomi normaliuoju skirstiniu. Kitaip sakant, stebimasis a. d. tiksliau aprašomas lognormaliuoju skirstiniu.

I.3.96. Užregistruota 100 metų duomenys apie vidutinę liepos mėnesio temperatūrą. Remiantis šiais duomenimis, gauta $\bar{X} = 16,482$, $s = 1,6145$. Naudojant šio laikotarpio 30 pirmųjų metų duomenis, gauti įverčiai $\bar{X}_1 = 16,893$, $s_1 = 1,5904$, o pagal paskutiniųjų 30 metų duomenis – įverčiai $\bar{X}_2 = 15,963$, $s_2 = 1,6531$. Patikrinkite hipotezes, kad šių dviejų laikotarių vidutinė temperatūra nesiskiria nuo vidurinio laikotarpio vidutinės temperatūros, tare, kad vidutinę temperatūrą galima aprašyti normaliuoju skirstiniu.

I.3.97. Pagal dvi nepriklausomas $n_1 = n_2 = 50$ imtis, gautos stebint n. a. d. $X \sim N(\mu_1, 1)$ ir $Y \sim N(\mu_2, 1)$, gauti įverčiai $\bar{X} = 0,103$ ir $\bar{Y} = 0,368$. Sudarykite TG kriterijų hipotezei $H : \mu_1 = \mu_2$, kai alternatyva yra $\bar{H} : \mu_1 < \mu_2$, tikrinti. Ar ši hipotezė atmetama pagal turimas realizacijas, jeigu kriterijaus reikšmingumo lygmuo $\alpha = 0,05$?

I.3.98. Yra dvi nepriklausomos paprastosios vienodo didumo n imtys, gautos stebint nepriklausomus normaliuosius a. d., ir, remiantis Fišerio kriterijumi, tikrinama hipotezė $H : \sigma_1^2 = \sigma_2^2$, kai alternatyva yra $\bar{H} : \sigma_1^2 / \sigma_2^2 > 1$. Raskite tokį imties didumą n , kad kriterijaus galia būtų ne mažesnė už 0,9, jei kriterijaus reikšmingumo lygmuo yra $\alpha = 0,05$ ir $\sigma_1^2 / \sigma_2^2 = 1,5; 2; 3$.

I.3.99. Dviejose laboratorijose buvo matuojamas sieros dyzeliniame kure kiekis pagal identiškus pavyzdžius, kuriuose sieros kiekis buvo 0,870. Atlikus 8 nepriklausomus matavimus, pirmoje laboratorijoje gauti tokie rezultatai: 0,869; 0,874; 0,867; 0,875; 0,870; 0,869; 0,864; 0,872. Kitoje laboratorijoje atlikus 10 matavimų, gauti tokie rezultatai: 0,865; 0,870; 0,866; 0,871; 0,868; 0,870; 0,871; 0,870; 0,869; 0,874. Tarę, kad matavimo paklaidos turi normaliuosius skirstinius, patikrinkite dispersijų lygybės hipotezę. Tarę, kad dispersijos vienodos, patikrinkite laboratorijų paklaidų vidurkių vienodumo hipotezę.

I.3.100. Tikrinama hipotezė, kad impulso atpažinimo paklaidos dispersija nepriklauso nuo jo intensyvumo. Buvo atlikti du nepriklausomi eksperimentai. Impulsas, kurio intensyvumas 10 salyginių vienetų, buvo įvertintas taip: 9, 9, 8, 10, 12, 12, 13, 10, 10; impulsas, kurio intensyvumas 20 salyginių vienetų, – taip: 15, 16, 17, 23, 22, 20, 21, 24, 27. Ar šie duomenys neprieštarauja iškeltajai hipotezei (tarkite, kad buvo stebimi nepriklausomi normalieji a. d.)?

I.3.101. (I.2.206 pratimo tēsinys). I.2.206 pratimo sąlygomis a) patikrinkite trijų dispersijų lygybės hipotezę $H : \sigma_x^2 = \sigma_y^2 = \sigma_z^2$; b) patikrinkite hipotezę $H : \theta = 0$.

I.3.102. Tirkiriant keturias didumos $n_1 = 20, n_2 = 38, n_3 = 25, n_4 = 50$ lempučių partijas, gautos jų darbo laiko iki gedimo vidutinės reikšmės $\bar{T}_1 = 154,3, \bar{T}_2 = 165,1, \bar{T}_3 = 159,0, \bar{T}_4 = 175,5$. Tardami, kad i -osios partijos lemputės darbo laikas iki gedimo turi eksponentinį skirstinį $\mathcal{E}(1/\lambda)$, patikrinkite hipotezę $H : \lambda_1 = \lambda_2 = \lambda_3 = \lambda_4$.

I.3.103. Tiriant specialios sėjamosios efektyvumą, 10 sklypelių buvo sėjama paprasta sėjamajai ir 10 sklypelių – specialiai sėjamajai, paskui buvo lyginamas derlingumas. Dvidešimt vienodo ploto sklypelių buvo taip sugrupuoti poromis, kad būtų greta vienas kito. Metant monetą buvo pasirenkama, kuriame iš dviejų sklypelių sėti specialiai sėjamajai. Rezultatai pateikti lentelėje.

Eil. Nr.	Speciali	Paprasta	Eil. Nr.	Speciali	Paprasta
1	8,0	5,6	6	7,7	6,1
2	8,4	7,4	7	7,7	6,6
3	8,0	7,3	8	5,6	6,0
4	6,4	6,4	9	5,6	5,5
5	8,6	7,5	10	6,2	5,5

Patikrinkite hipotezę, kad abiejų sėjamųjų efektyvumas vienodas: a) taikydami dviejų imčių Stjudento kriterijų; b) taikydami Stjudento kriterijų atitinkamų sklypelių derlingumų skirtumams; c) paaiškinkite, kodėl gaunamos skirtinio išvados.

I.3.104. (I.3.103 pratimo tēsinys). Ivertinkite koreliacijos koeficientą ir patikrinkite koreliacijos koeficiente lygybės 0 hipotezę.

I.3.105. (I.2.207 pratimo tēsinys). I.2.207 pratimo sąlygomis patikrinkite prielaidą, kad a. d. X ir Y vidurkiai nesiskiria.

I.3.106. Lentelėje nurodyta 10 pacientų, vartoju sių migdomuosius vaistus A ir B, papildomo miego trukmė X ir Y (valandomis).

i	X_i	Y_i	i	X_i	Y_i
1	1,9	0,7	6	4,4	3,4
2	0,8	-1,6	7	5,5	2,7
3	1,1	-0,2	8	1,6	0,8
4	0,1	-1,2	9	4,6	0,0
5	-0,1	-0,1	10	3,4	2,0

Patikrinkite hipotezę, kad vaistų poveikis vienodas, tarę, kad buvo stebimas normalusis atsitiktinis vektorius.

I.3.107. (I.2.202 pratimo tēsinys). I.2.202 pratimo sąlygomis tarę, kad parametras $\eta = 10$, patikrinkite hipotezę $H : \lambda \leq 1$, kai alternatyva yra $\bar{H} : \lambda > 1$.

I.3.108. (I.2.205 pratimo tēsinys). I.2.205 pratimo sąlygomis tarę, kad parametras $\eta = 10$, patikrinkite hipotezę $H : \lambda = \lambda_0 = 0,001$, kai alternatyva yra $\bar{H} : \lambda \neq 0,001$. ($\alpha = 0,01$).

I.3.109. (I.2.201 pratimo tēsinys). I.2.201 pratimo sąlygomis reišmingumo lygmenis $\alpha = 0,05$ kriterijumi patikrinkite hipotezę $H : \lambda = \lambda_0 = 1$, kai alternatyva yra $\bar{H} : \lambda \neq 1$.

I.3.110. Tegu X_1, X_2, \dots, X_7 yra firmoje užregistruotų klientų skambučių skaičiai per 7 savaitės dienas. Tarę, kad a. d. X_1, \dots, X_7 yra nepriklausomi ir turi Puasono skirstinius

$X_i \sim \mathcal{P}(\lambda_i)$, a) patikrinkite hipotezę $H : \lambda_1 = \dots = \lambda_7$ remdamiesi a. d. X_1, \dots, X_7 realizacija: 52; 65; 60; 71; 75; 43; 40. b) Matome, kad savaitgalj skambučių skaičius yra mažesnis. Patikrinkite hipotezę $H : \lambda_1 = \dots = \lambda_5$, kad skambučių intensyvumas darbo dienomis yra vienodas.

I.3.111. (I.2.203 pratimo tēsinys). I.2.203 pratimo sąlygomis patikrinkite hipotezę, kad II rūšies gaminijų dalis neviršija 0,25.

I.3.112. Per pirmą valandą skaitiklis užregistravo 150 tam tikrų kosminių dalelių, per tolesnes dvi valandas – 250 dalelių. Patikrinkite hipotezę, kad dalelių srauto intensyvumas nepakito.

I.3.113. Du nepriklausomi a. d., pasiskirstę pagal Puasono dėsnį, įgijo atitinkamai reikšmes 75 ir 200. Patikrinkite hipotezę $H : \lambda_1 = \lambda_2/2$, kai alternatyva $\bar{H} : \lambda_1 < \lambda_2/2$.

I.3.114. Per pirmąją dieną skaitiklis užregistravo 20 026 puasoninio srauto impulsus, o per antrają dieną – 19 580 impulsų. Ar yra pagrindo teigti, kad impulsų srauto intensyvumas sumažėjo?

I.3.115. Ar galima teigti, kad dviejose nepriklausomose Bernulio bandymų schemose įvykio A tikimybė vienoda, jeigu atlikus $n_1 = n_2 = 5000$ bandymų įvykis A įvyko 2 602 ir 2 398 kartus?

I.3.116. Patikrinus 5 vienodo didumo $n = 200$ gaminijų partijas, jose buvo surasta atitinkamai 15; 10; 6; 12; 4 defektiniai gaminiai. Tegu defektinių gaminių skaičius j -oje partijoje turi binominį skirstinį $B(n, p_i)$, $i = 1, \dots, 5$. Patikrinkite hipotezę $H : p_1 = \dots = p_5$.

I.3.117. (I.2.211 pratimo tēsinys). I.2.211 pratimo sąlygomis patikrinkite hipotezę, kad prapuolimo kampas turi tolygųjį pasiskirstymą.

I.3.118. (I.2.212 pratimo tēsinys). I.2.212 pratimo sąlygomis patikrinkite hipotezę, kad susirgimai leukemija tolygiai pasiskirstę per metus.

I.3.119. Lentelėje pateikta smėlio grūdelių orientacija plokštumoje (žr. [14]).

Kampus	Kiekis	Kampus	Kiekis	Kampus	Kiekis
0°–	244	60°–	326	120°–	322
10°–	262	70°–	340	130°–	295
20°–	246	80°–	371	140°–	230
30°–	290	90°–	401	150°–	256
40°–	284	100°–	382	160°–	263
50°–	314	110°–	332	170°–	281

Kampai sugrupuoti į ilgio 10° intervalus (nurodoma grupavimo intervalo pradžia). Gretimuose stulpeliuose nurodomi smėlio grūdelių, kurių orientacija patenka į atitinkamus intervalus, skaičiai.

Padvigubinę kampus, perveskite duomenis į intervalą $[0^\circ - 360^\circ]$. Patikrinkite kampų skirstinio tolygumo hipotezę.

I.3.7. Sprendimai, nurodymai, atsakymai

I.3.1 skyrelis

I.3.1. Pagal didumo $n = 6$ paprastają imtį $(X_1, \dots, X_6)^T$ gautą stebint a.d. $X \sim B(1, p)$, tikrinama hipotezė $H : p = 0,2$ kai alternatyva yra $\bar{H} : p > 0,2$. Kriterijaus kritinė sritis $K = \{(X_1, \dots, X_6) : S = X_1 + \dots + X_6 \geq 3\}$. Reikšmingumo lygmuo $\alpha = \mathbf{P}\{S \geq 3 | p = 0,2\} = 0,0989$. Kriterijaus galia: 0,4557; 0,8208; 0,9830; 1,000.

I.3.2. Tegu bakterijų skaičius tūrio vienete turi Puasono skirstinį $\mathcal{P}(\lambda)$. Tada bakterijų skaičius N tūrio V kolboje turi Puasono skirstinį $\mathcal{P}(V\lambda)$. Tikimybė, kad vanduo kolboje susidrums, $p = \mathbf{P}\{N > 0\} = 1 - e^{-V\lambda}$. Patikrinus n kolbų susidrumstusių skaičius $X \sim B(n, p)$. Remiantis a.d. X tikrinama hipotezė $H : p \leq p_0 = 1 - e^{-Vm_0}$, kai alternatyva yra $\bar{H} : p > p_0$. Kritinė sritis $K = \{X : X > t\}$.

a) $p_0 = 1 - e^{-1}$, $n = 10$; kritinė sritis $K = \{X : X > 7\}$; pirmosios rūšies klaidos tikimybė

$$\alpha \leq \mathbf{P}\{X > 7 | p_0\} = \sum_{m=8}^{10} C_{10}^m p_0^m (1 - p_0)^{10-m} = 0,2247.$$

b) $p_0 = 1 - e^{-2}$, $n = 8$; kritinė sritis $K = \{X : X > 7\}$; pirmosios rūšies klaidos tikimybė

$$\alpha \leq \mathbf{P}\{X > 7 | p_0\} = p_0^8 = 0,3126.$$

I.3.3. Pagal didumo $n = 250$ paprastają imtį, gautą stebint Bernulio a.d. $X \sim B(1, p)$, tikrinama hipotezė $H : p \leq p_0$, kai alternatyva $\bar{H} : p > p_0$. Kriterijaus priėmimo sritis $S = \sum_i X_i \leq 25$. Reikia rasti tokį p_0 , kad $\mathbf{P}\{S \leq 25 | p = p_0\} = 0,95$. Naudodamini SAS, MS Excel, R arba SPSS programą randame $p_0 \approx 7,39\%$.

I.3.4. Tegu defektinių gaminiių skaičius partijoje yra M . Tikrinama hipotezė $H : M/N \leq p_0$, kai alternatyva yra $\bar{H} : M/N > p_0$ remiantis a.d. $X \sim H(N, M, n)$. Hipotezės priėmimo sritis $A = \{X : X \leq d\}$ ir kritinė sritis $K = \{X : X > d\}$.

I.3.5. Kadangi partijos didelės, o tikrinama, kaip matysime, nedidelė partijos dalis, tai a.d. X skirstinį galima aproksimuoti binominiu $B(n, p)$, $p = M/N$. Tada atrankinės kontrolės plano charakteristikoms n ir d rasti turime nelygybių sistemą

$$\mathbf{P}\{X \leq d | p = p_0 = 0,05\} = \sum_{m=0}^d C_n^m p_0^m (1 - p_0)^{n-m} \geq 0,9;$$

$$\mathbf{P}\{X \leq d | p = p_1 = 0,1\} = \sum_{m=0}^d C_n^m p_1^m (1 - p_1)^{n-m} \leq 0,05.$$

Gauname, kad minimalus imties didumas $n = 251$; partija priimama, kai $X \leq 17$.

I.3.6. Turime didumo $n = 500$ paprastają imtį, gautą stebint Bernulio a.d. $X \sim B(1, p)$. Tada defektinių gaminiių skaičius $S = X_1 + \dots + X_n \sim B(n, p)$. Tikrinama hipotezė $H : p \leq p_0 = 0,05$, kai alternatyva $\bar{H} : p > p_0$. Taikomo kriterijaus kritinė sritis $K = \{S : S \geq k\}$.

I.3.7. a) $k = 37; 0,6527; 0,9726; 0,9995$; b) $k = 7; 0,0438; 0,1221; 0,2467$.

I.3.8. a) Parametro μ pasiklivimo lygmens $Q = 1 - \alpha$ dešininis vienpusis pasiklivimo intervalas yra $(\underline{\mu}, \infty)$, kai $\underline{\mu} = \bar{X} - z_\alpha \sigma / \sqrt{n}$. Taigi hipotezės H priėmimo sritis $A_1 = \{\bar{X} : \underline{\mu} < \mu_0 < \infty\} \Leftrightarrow \{\bar{X} : Z = \sqrt{n}(\bar{X} - \mu_0)/\sigma < z_\alpha\}$ (žr. [2], 4.5 skyrelj). Kritinė sritis $K_1 = \{\bar{X} : Z > z_\alpha\}$. P reikšmių terminais kriterijus formuluojamas taip: hipotezė atmetama, kai $p v = P\{Z > z | \mu = \mu_0\} = 1 - \Phi(z) \leq \alpha$; čia z yra statistikos Z realizacija (žr. [2], 4.1.2 skyrelj).

Analogiškai, kai alternatyva $\bar{H}_2 : \mu \leq \mu_0$, gauname kritinę sritį $K_2 = \{\bar{X} : \mu_0 > \bar{\mu} = \bar{X} + z_\alpha \sigma / \sqrt{n}\} \Leftrightarrow \{\bar{X} : Z < -z_\alpha\}$. P reikšmių terminais hipotezė atmetama, kai $p v = \Phi(z) < \alpha$.

b) Parametro μ pasiklivimo lygmens $Q = 1 - \alpha$ pasiklivimo intervalas yra $(\underline{\mu}, \bar{\mu}) = (\bar{X} - z_{\alpha/2} \sigma / \sqrt{n}, \bar{X} + z_{\alpha/2} \sigma / \sqrt{n})$. Jি atitinkanti hipotezės H priėmimo sritis $A_3 = \{\bar{X} : \underline{\mu} < \mu_0 < \bar{\mu}\}$. Kritinė sritis $K_3 = \{\bar{X} : |Z| > -z_{\alpha/2}\}$. P reikšmių terminais hipotezė atmetama, kai

$$p v = 2 \min(\Phi(z), 1 - \Phi(z)) = 2(1 - \Phi(|z|)) < \alpha.$$

I.3.2 skyrelis

I.3.9. Remiantis Neimano ir Pirsono lema (žr. [2], 4.2.1 skyrelj) hipotezė H atmetama, kai

$$\frac{L(\theta_1; \mathbf{X})}{L(\theta_0; \mathbf{X})} = \frac{\theta_1^n}{\theta_0^n} e^{-(\theta_1 - \theta_0)S_n} > c \Leftrightarrow -(\theta_1 - \theta_0)S_n > d;$$

čia $S_n = X_1 + \dots + X_n \sim G(\theta_0, n)$; $2\theta_0 S_n \sim \chi^2(2n)$, kai hipotezė H teisinga; konstanta d randama iš sąlygos

$$P_{\theta_0}\{-(\theta_1 - \theta_0)S_n > d\} = \alpha.$$

Tarkime, kad $\theta_1 > \theta_0$.

$$\begin{aligned} P_{\theta_0}\{-(\theta_1 - \theta_0)S_n > d\} &= \alpha \Rightarrow P_{\theta_0}\{(\theta_1 - \theta_0)S_n < -d\} = \alpha \Rightarrow \\ P_{\theta_0}\{2\theta_0 S_n < -\frac{d2\theta_0}{\theta_1 - \theta_0}\} &= \alpha \Rightarrow -\frac{d2\theta_0}{\theta_1 - \theta_0} = \chi^2_{1-\alpha}(2n) \Rightarrow \\ d &= -\chi^2_{1-\alpha}(2n) \frac{\theta_1 - \theta_0}{2\theta_0}; \\ -(\theta_1 - \theta_0)S_n > d &\Rightarrow -(\theta_1 - \theta_0)S_n > -\chi^2_{1-\alpha}(2n) \frac{\theta_1 - \theta_0}{2\theta_0} \\ &\Rightarrow S_n < \chi^2_{1-\alpha}(2n)/(2\theta_0). \end{aligned}$$

Jeigu $\theta_1 > \theta_0$, tai H atmetame, kai $S_n < \chi^2_{1-\alpha}(2n)/(2\theta_0)$.

Kriterijaus galia:

$$\begin{aligned} \beta(\theta_1) &= P_{\theta_1}(S_n < \chi^2_{1-\alpha}(2n)/(2\theta_0)) = P_{\theta_1}\left(2\theta_1 S_n < \frac{\chi^2_{1-\alpha}(2n)2\theta_1}{2\theta_0}\right) = \\ &= P\left(\chi^2_{2n} < \frac{\chi^2_{1-\alpha}(2n)\theta_1}{\theta_0}\right) \end{aligned}$$

Analogiškai, jeigu $\theta_1 < \theta_0$, tai H atmetame, kai $S_n > \chi^2_\alpha(2n)/(2\theta_0)$; kriterijaus galia $\beta(\theta_1) = \mathbf{P}\{\chi^2_{2n} > (\theta_1/\theta_0)\chi^2_\alpha(2n)\}$.

I.3.10. Tegu kriterijaus reikšmingumo lygmuo α tenkina nelygybę $\alpha < 1/2 - \text{arctg}(1/2)/\pi \approx 0,352$. Remiantis Neimano ir Pirsono lema hipotezė atmetama, kai

$$\frac{f(X; 1)}{f(X; 0)} = \frac{1 + X^2}{1 + (X - 1)^2} > c \Leftrightarrow (c - 1)X^2 - 2cX + 2c - 1 < 0.$$

Taigi hipotezė atmetama, kai $x_1 < X < x_2$;

$$x_1 = [c - \sqrt{c - (c - 1)^2}]/(c - 1), \quad x_2 = [c + \sqrt{c - (c - 1)^2}]/(c - 1);$$

konstanta c randama iš sąlygos $(\text{arctg}(x_2) - \text{arctg}(x_1))/\pi = \alpha$.

I.3.11. a) Hipotezė atmetama, kai $|X| > z_{\alpha/2}$, jeigu $\alpha < 0,0455$; hipotezės atmetimo sritis: $|X| < x_1$ arba $|X| > x_2$, $x_1 = 1 - \sqrt{1 + c}$, $x_2 = 1 + \sqrt{1 + c}$; konstanta c randama iš sąlygos $\alpha = 2[1 - \Phi(x_2)] + 2\Phi(x_1) - 1$, jeigu $\alpha > 0,0455$.

b) Hipotezė atmetama, kai $\delta - c < |X| < \delta$; konstanta c randama iš sąlygos $2[\Phi(\delta) - \Phi(\delta - c)] = \alpha$; jeigu toks $c < \delta$ neegzistuoja, tai H atmetama, kai $|X| < \delta$.

I.3.12. Imties $\mathbf{X} = (X_1, \dots, X_5)^T$ tankis, kai teisinga hipotezė, yra

$$\varphi(\mathbf{x}) = (1/\sqrt{2\pi\sigma})^5 \exp\{-(x_1^2 + \dots + x_5^2)/(2\sigma^2)\};$$

esant teisingai alternatyvai skirtinys yra tolygus vienetiniame penkiamačiame kubo $-1/2 < x_1, \dots, x_5 < 1/2$. Remiantis Neimano ir Pirsono lema, H priimama, kai

$$\max(|X_1|, \dots, |X_5|) > 1/2,$$

arba kai a. v. \mathbf{X} patenka į penkiamatę sferą su centru koordinacijų pradžioje: $X_1^2 + \dots + X_5^2 < r^2$. Tikimybė $\mathbf{P}\{\max(|X_1|, \dots, |X_5|) > 1/2\} = 1 - (2\Phi(1/0, 316) - 1)^5 = 0,0077$. Iš sąlygos $\mathbf{P}\{X_1^2 + \dots + X_5^2 < r^2\} = \mathbf{P}\{\chi^2_5 < r^2/0,025\} = 0,9 - 0,0077 = 0,8923$ randame $r^2 = 0,2258$, t. y. penkiamatė sfera patenka į kubo vidų. Kadangi $X_1^2 + \dots + X_5^2 = 0,2549$, tai H atmetama.

I.3.13. Remiantis Neimano ir Pirsono lema H atmetama, kai $\bar{X} > c$. Abiejų klaidų tikimybės vienodos, kai $c = 1/2$. Tada imties didumui rasti turime nelygybę

$$\mathbf{P}\{\bar{X} > 1/2 | \mu = 0\} = \mathbf{P}\{\sqrt{n}\bar{X} > \sqrt{n}/2 | \mu = 0\} = 1 - \Phi(\sqrt{n}/2) \leq 0,01.$$

Išsprendę gauname, kad $n \geq 22$.

I.3.14. TG kriterijus atmeta hipotezė, kai $X > m$, ir atmeta su tikimybe γ , kai $X = m$. Konstantos m ir γ randamos iš sąlygos

$$\mathbf{P}\{X > m | \lambda_0\} + \gamma \mathbf{P}\{X = m | \lambda_0\} = 0,1.$$

Pirmuoju atveju gauname $m = 0, \gamma = 0,00535$. Kriterijaus galia

$$\beta(\lambda_1) = \mathbf{P}\{X > 0 | \lambda_1\} + \gamma \mathbf{P}\{X = 0 | \gamma_1\} = 0,1856.$$

Analogiškai kitais atvejais kriterijaus galia 0,3523; 0,9074; 0,3655.

I.3.15. Neatsižvelgiant į randomizaciją, kriterijus yra tokis: $\varphi_1(\mathbf{x}) = 1$, kai $f_1(\mathbf{x}) > c_1 f_2(\mathbf{x})$; $\varphi_2(\mathbf{x}) = 1$, kai $f_2(\mathbf{x}) > c_2 f_1(\mathbf{x})$; $\varphi_0(\mathbf{x}) = 1 - \varphi_1(\mathbf{x}) - \varphi_2(\mathbf{x})$. Konstanta c_1 randama iš sąlygos $\alpha_{12} = \alpha$, o konstanta c_2 – iš sąlygos $\alpha_{21} = \beta$, jeigu sprendiniai c_1 ir c_2 tenkina sąlygą $c_1 c_2 > 1$. Priešingu atveju sprendinys neegzistuoja (tokiu atveju galima minimizuoti, pvz., sumą $\alpha_{01} + \alpha_{10}$).

I.3.16. Sprendinys yra tokio pat pavidalo kaip ir **I.3.15** pratime. Konstantos c_1 , c_2 randamos iš sąlygų $\beta_{12} = b_1$, $\beta_{21} = b_2$, jei tik $c_1 c_2 > 1$ (žr. [4], 6.1.3 skyrelj).

I.3.18. a) H_0 atmetame, kai $X > \theta_0(1 - \sqrt{\alpha})$; b) H_0 atmetame, kai $X < [-(1 - \theta_0) + \sqrt{(1 - \theta_0)^2 + \alpha(2\theta_0 - 1)}]/(\theta_0 - 1/2)$ ir $\theta_0 \neq 1/2$; atmetama, kai $X < \alpha$, jeigu $\theta_0 = 1/2$; c) hipotezę atmetama, kai $X < \sqrt{\alpha}/2$ arba kai $X > 1 - \sqrt{\alpha}/2$.

I.3.19. a) H_0 atmetama, kai $X_{(1)} > \theta_0 - (\ln \alpha)/n$; b) hipotezę atmetame, kai $X_{(1)} > \theta_0 \alpha^{-1/n}$, esant alternatyvai $\theta_1 > \theta_0$; hipotezę atmetame su tikimybe 1, kai $X_{(1)} < \theta_0$, ir atmetame su tikimybe α , kai $X_{(1)} \geq \theta_0$, esant alternatyvai $\theta_1 < \theta_0$.

I.3.20. Remiantis TG kriterijumi H atmetama su tikimybe 1, kai $S = X_1 + \dots + X_n \geq 1$, ir atmetama su tikimybe $\alpha = 0,01$, kai $S = 0$. Abiejų rūšių klaidos neviršija 0,01, kai $n \geq 458$.

I.3.3 skyrelis

I.3.21. a) Kadangi tikėtinumo funkcija

$$L(\mu) = W(\mathbf{X}) e^{\bar{X}\eta(\mu) - b(\mu)}, \quad \eta(\mu) = \frac{n\mu}{\sigma^2}, \quad b(\mu) = \frac{n\mu^2}{2\sigma^2}$$

priklauso vienparametrei eksponentinio tipo skirstinių šeimai, $T = \bar{X}$ yra pakankamoji statistika, tai egzistuoja TG kriterijus (žr. [2], 4.3.2 pastabą), kai alternatyva \bar{H}_1 , kurio kritinė sritis

$$K_1 = \{\mathbf{X} : \bar{X} > c\} \Leftrightarrow \{\mathbf{X} : Z = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma_0} > z_\alpha\}.$$

Kriterijaus galia

$$\beta_1(\mu) = \mathbf{P}_\mu \left\{ \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma_0} > z_\alpha \right\} = \mathbf{P}_\mu \left\{ \sqrt{n} \frac{\bar{X} - \mu}{\sigma_0} > z_\alpha - \lambda \right\} = \Phi(\lambda - z_\alpha),$$

čia $\lambda = \sqrt{n}(\mu - \mu_0)/\sigma_0$, $\beta_1(\mu) \rightarrow 1$, kai $\lambda \rightarrow \infty$.

Analogiškai, kai alternatyva yra \bar{H}_2 , TG kriterijaus kritinė sritis yra

$$K_2 = \{\mathbf{X} : Z = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma_0} < -z_\alpha\}.$$

Šio kriterijaus galia

$$\beta_2(\mu) = \mathbf{P}_\mu \left\{ \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma_0} < -z_\alpha \right\} = \Phi(-\lambda - z_\alpha)$$

monotoniskai artėja prie 1, kai $\mu - \mu_0 \rightarrow -\infty$.

b) Kai alternatyva $\bar{H}_3 : \mu \neq \mu_0$ yra dvipusė, TG kriterijus neegzistuoja. Remiantis [2], 4.3.2 teorema, TGN kriterijaus kritinė sritis

$$K_3 = \{\mathbf{X} : |Z| = \sqrt{n} \frac{|\bar{X} - \mu_0|}{\sigma_0} > z_{\alpha/2}\},$$

o galios funkcija

$$\beta_3(\mu) = \Phi(-\lambda - z_{\alpha/2}) + \Phi(\lambda - z_{\alpha/2})$$

artėja prie 1, kai $|\mu - \mu_0| \rightarrow \infty$ (arba $|\lambda| \rightarrow \infty$).

I.3.22. Patekti į kritinę sritį K_1 yra ekvivalentu nelygybei $\mu_0 < \underline{\mu}$, o patekti į K_2 – nelygybei $\mu_0 > \bar{\mu}$; čia $\underline{\mu}$ ir $\bar{\mu}$ yra parametru μ pasikliovimo intervalo, kai pasikliovimo lygmuo $Q = 1 - 2\alpha$, viršutinis ir apatinis režiai. Patekti į kritinę sritį K_3 ekvivalentu nelygybėms $\mu_0 < \underline{\mu}$ arba $\mu_0 > \bar{\mu}$, kai intervalo pasikliovimo lygmuo $Q = 1 - \alpha$ (žr. [2], 4.5 skyrelj).

I.3.23. Tarkime, z yra statistikos $Z = \sqrt{n}(\bar{X} - \mu_0)/\sigma$ realizacija. Tada P reikšmių terminais kriterijai, kurių kritinės sritys K_1, K_2, K_3 , formuluoja taip: hipotezė H atmetama, kai atitinkamai (žr. [2], 4.1.2 skyrelj)

$$pv = 1 - \Phi(z) < \alpha, \quad pv = \Phi(z) < \alpha, \quad pv = 2(1 - \Phi(|z|)) < \alpha.$$

I.3.24. a) Imties didumui n rasti gauname nelygybę

$$\beta_1(\mu') = \Phi\left(\sqrt{n} \frac{\mu_1 - \mu_0}{\sigma_0} - z_\alpha\right) \geq 1 - \alpha'.$$

Iš čia gauname, kad imties didumas n tenkina nelygybę

$$n \geq \frac{\sigma_0^2}{(\mu_1 - \mu_0)^2} (z_{\alpha'} + z_\alpha)^2.$$

Matome, kad imties didumas tiesiog proporcingas dispersijai ir atvirkščiai proporcingas atstumo $\mu_1 - \mu_0$ kvadratui.

b) Iraše z_α ir $z_{\alpha'}$ iš 2 priedo 2P2 lentelės, gauname

$$n \geq \frac{\sigma^2}{(\mu_1 - \mu_0)^2} (z_\alpha + z_{\alpha'})^2 = \frac{4}{0,5^2} (z_{0,05} + z_{0,01})^2 = 252,33.$$

Taigi imties didumas turi būti ne mažesnis už 253.

I.3.25. a) Imties $\mathbf{X} = (X_1, \dots, X_n)^T$ skirstinys priklauso vienparametrei eksponentinio tipo skirstinių šeimai, o tankis

$$f(\mathbf{x}, \theta) = h(\mathbf{x}) \exp\{\eta(\theta)T(\mathbf{x}) - b(\theta)\};$$

čia

$$\eta(\theta) = -\frac{1}{2\sigma^2}, \quad T = T(\mathbf{x}) = \sum_i (x_i - \mu_0)^2, \quad b(\theta) = n \ln \sigma, \quad h(\mathbf{x}) = (\sqrt{2\pi})^{-n}.$$

Remiantis [2], 4.3.2 pastaba, egzistuoja TG kriterijai vienpusių alternatyvų \bar{H}_1, \bar{H}_2 atvejais. Jų kritinės sritys

$$K_1 = \{\mathbf{X} : \frac{T(\mathbf{X})}{\sigma_0^2} > \chi_{\alpha}^2(n)\}, \quad K_2 = \{\mathbf{X} : \frac{T(\mathbf{X})}{\sigma_0^2} < \chi_{1-\alpha}^2(n)\}.$$

Šių kriterijų galios funkcijos $\beta_1(\sigma^2), \beta_2(\sigma^2)$ ir išreiškiamos χ^2 skirstinio pasiskirstymo funkcija

$$\beta_1(\sigma^2) = \mathbf{P}_{\sigma^2} \left\{ \frac{T(\mathbf{X})}{\sigma_0^2} > \chi_{\alpha}^2(n) \right\} = \mathbf{P} \left\{ \chi_n^2 > \frac{\sigma_0^2}{\sigma^2} \chi_{\alpha}^2(n) \right\},$$

$$\beta_2(\sigma^2) = \mathbf{P} \left\{ \chi_n^2 < \frac{\sigma_0^2}{\sigma^2} \chi_{1-\alpha}^2(n) \right\}.$$

b) Kai alternatyva $\bar{H}_3 : \sigma^2 \neq \sigma_0^2$ yra dvipusė, TG kriterijus neegzistuoja. Tačiau, naudojantis [2], 4.3.2 teorema, galima rasti TGN kriterijų, kurio kritinė sritis

$$K_3 = \{\mathbf{X} : \frac{T(\mathbf{X})}{\sigma_0^2} < c_1 \text{ arba } \frac{T(\mathbf{X})}{\sigma_0^2} > c_2\};$$

čia konstantos c_1 ir c_2 randamos iš lygčių sistemos

$$\mathbf{P}_{\sigma_0^2} \{c_1 < T/\sigma_0^2 < c_2\} = 1 - \alpha,$$

$$\mathbf{E}_{\sigma_0^2} [(T/\sigma_0^2) \mathbf{1}_{(c_1, c_2)}(T/\sigma_0^2)] = (1 - \alpha) \mathbf{E}_{\sigma_0^2}(T/\sigma_0^2) = (1 - \alpha)n.$$

Kadangi $\mathbf{E}_{\sigma_0^2} [(T/\sigma_0^2) \mathbf{1}_{(c_1, c_2)}(T/\sigma_0^2)] = n \mathbf{P}\{c_1 < \chi_{n-2}^2 < c_2\}$, tai konstantoms c_1 ir c_2 rasti gauname lygčių sistemą

$$\begin{cases} \mathbf{P}\{c_1 < \chi_n^2 < c_2\} = 1 - \alpha, \\ \mathbf{P}\{c_1 < \chi_{n+2}^2 < c_2\} = 1 - \alpha. \end{cases}$$

Kriterijaus galios funkcija

$$\beta_3(\sigma^2) = 1 - \mathbf{P} \left\{ \frac{\sigma_0^2}{\sigma^2} c_1 < \chi_n^2 < \frac{\sigma_0^2}{\sigma^2} c_2 \right\}.$$

c) Simetrinio kriterijaus kritinė sritis

$$K_3^* = \{\mathbf{X} : \frac{T(\mathbf{X})}{\sigma_0^2} < \chi_{1-\alpha/2}^2(n), \text{ arba } \frac{T(\mathbf{X})}{\sigma_0^2} > \chi_{\alpha/2}^2(n)\}.$$

I.3.26. Sprendžiame I.3.25 pratime pateiktą lygčių sistemą, kai $n = 10, 20, 50$. TGN kriterijaus galios $\beta_3(\sigma^2)$ ir simetriško kriterijaus galios $\tilde{\beta}_3(\sigma^2)$ išraiškas žr. I.3.25 pratime.

I.3.27. a) Kritines sritis K_1 ir K_2 atitinka kriterijai: hipotezė atmetama, kai atitinkamai $\underline{\sigma}_0^2 < \underline{\sigma}^2$ ir $\overline{\sigma}_0^2 > \overline{\sigma}^2$; čia $\underline{\sigma}^2$ ir $\overline{\sigma}^2$ yra lygmens $Q = 1 - 2\alpha$ pasiklivimo intervalo apatinis ir viršutinis režiai. Kritinę sritį K_3^* atitinka kriterijus: hipotezė atmetama, kai teisingos nelygybės $\underline{\sigma}_0^2 < \underline{\sigma}^2$ arba $\overline{\sigma}_0^2 > \overline{\sigma}^2$; čia $(\underline{\sigma}^2, \overline{\sigma}^2)$ yra lygmens $Q = 1 - \alpha$ pasiklivimo intervalas.

b) Tegu t yra statistikos T/σ_0^2 realizacija, o $F(x|\nu)$ yra a. d. χ_ν^2 pasiskirstymo funkcija. Tada kriterijus K_1, K_2, K_3^* P reikšmių terminais atitinka tokios taisyklės: hipotezė atmetama, kai atitinkamai

$$pv = 1 - F(y|n-1) \leq \alpha, \quad pv = F(y|n-1) \leq \alpha,$$

$$pv = 2 \min(1 - F(y|n-1), F(y|n-1)) \leq \alpha.$$

I.3.28. Remdamiesi **I.3.25** pratime pateikta galios funkcija, imties didumui rasti turime nelygybę

$$\beta_1(1, 5\sigma_0^2) = \mathbf{P}\{\chi_n^2 > \frac{2}{3}\chi_{0,05}^2(n)\} \geq 0,9 \quad \Leftrightarrow \quad n \geq 104.$$

I.3.29. Imties \mathbf{X} tankis

$$f(\mathbf{X}, \sigma) = \left(\prod_i X_i \right) \exp\{\eta(\sigma)T(\mathbf{X}) - B(\sigma)\},$$

čia

$$\eta(\sigma) = -\frac{1}{2\sigma^2}, \quad T(\mathbf{X}) = \sum_i X_i^2, \quad B(\sigma) = 2n \ln \sigma.$$

Kadangi $T(\mathbf{X})/\sigma_0^2 \sim \chi^2(2n)$, kai hipotezė teisinga, tai palyginę su **I.3.25** pratimu darome išvadą, kad kriterijai bus nusakyti kritinėmis sritimis K_1, K_2, K_3, K_3^* , kuriose n reikia pakeisti į $2n$.

I.3.30. Imties \mathbf{X} tankis

$$f(\mathbf{X}, \sigma) = (2/\pi)^{n/2} \left(\prod_i X_i^2 \right) \exp\{\eta(\sigma)T(\mathbf{X}) - B(\sigma)\},$$

čia

$$\eta(\sigma) = -\frac{1}{2\sigma^2}, \quad T(\mathbf{X}) = \sum_i X_i^2, \quad B(\sigma) = 2n \ln \sigma.$$

Kadangi $T(\mathbf{X})/\sigma_0^2 \sim \chi^2(3n)$, kai $\sigma = \sigma_0$, tai palyginę su **I.3.25** pratimu darome išvadą, kad kriterijai bus nusakyti kritinėmis sritimis K_1, K_2, K_3, K_3^* , kuriose n reikia pakeisti į $3n$.

I.3.31. a) Imties \mathbf{X} tankio funkcija

$$f(\mathbf{X}, \lambda) = \exp\{\eta(\lambda)T - B(\lambda)\}h(\mathbf{X}),$$

čia

$$\eta(\lambda) = -\lambda, \quad T = \sum_i X_i, \quad B(\lambda) = -\eta \ln \lambda,$$

priklauso vienparametrei eksponentinio tipo skirtinių šeimai; statistika $V = 2\lambda_0 T \sim \chi^2(2\eta)$, kai $\lambda = \lambda_0$. Remiantis [2], 4.3.2 pastaba, egzistuoja TG kriterijai, esant vienpusėms alternatyvoms \bar{H}_1 ir \bar{H}_2 . Kritinės sritys yra tokios:

$$K_1 = \{\mathbf{X} : 2\lambda_0 T < \chi_{1-\alpha}^2(2\eta)\}, \quad K_2 = \{\mathbf{X} : 2\lambda_0 T > \chi_\alpha^2(2\eta)\}.$$

Pažymėkime t statistikos T realizaciją ir tegu $F(x|\nu)$ yra χ^2 skirstinio su ν laisvės laipsniais pasiskirstymo funkcija. Tada kriterijus galima suformuluoti P reikšmių terminais: hipotezė atmetama, kai atitinkamai teisingos nelygybės

$$pv = F(2\lambda_0 t | 2\eta) \leq \alpha, \quad pv = 1 - F(2\lambda_0 t | 2\eta) \leq \alpha.$$

b) Kai alternatyva $\bar{H}_3 : \lambda \neq \lambda_0$ yra dvipusė, remiantis [2], 4.3.2 teorema egzistuoja TGN kriterijus, kurio kritinė sritis

$$K_3 = \{\mathbf{X} : 2\lambda_0 T < c_1 \text{ arba } 2\lambda_0 T > c_2\}.$$

Analogiškai I.3.25 pratumui konstantos c_1 ir c_2 raudamos iš tokios lygčių sistemos:

$$\begin{cases} \mathbf{P}\{c_1 < \chi_{2\eta}^2 < c_2\} = 1 - \alpha, \\ \mathbf{P}\{c_1 < \chi_{2\eta+2}^2 < c_2\} = 1 - \alpha. \end{cases}$$

c) Simetriško kriterijaus kritinė sritis

$$K_3^* = \{\mathbf{X} : 2\lambda_0 T < \chi_{1-\alpha/2}^2(2\eta) \text{ arba } 2\lambda_0 T > \chi_{\alpha/2}^2(2\eta)\},$$

arba P reikšmių terminais hipotezė H_3 atmetama, kai

$$pv = 2 \min(F(2\lambda_0 t | 2\eta), 1 - F(2\lambda_0 t | 2\eta)) \leq \alpha.$$

I.3.32. Imties tankis (skaičiuojančiojo mato atžvilgiu)

$$f(\mathbf{X}, \lambda) = \exp\{\eta(\lambda)T - B(\lambda)\}h(\mathbf{X}),$$

čia

$$\eta(\lambda) = \ln \lambda, \quad T = \sum_i X_i, \quad B(\lambda) = n\lambda,$$

priklauso vienparametrei eksponentinio tipo skirstinių šeimai.

Remiantis [2], 4.3.2 pastaba, egzistuoja TG kriterijus, kai alternatyva yra \bar{H}_1 , tikrinti. Kriterijus nusakomas taip:

$$\varphi(T) = \begin{cases} 1, & \text{kai } T > k, \\ \gamma, & \text{kai } T = k, \\ 0, & \text{kai } T < k, \end{cases}$$

čia konstantos k ir γ raudamos iš sąlygos

$$\mathbf{E}_{\lambda_0}(\varphi(T)) = \mathbf{P}_{\lambda_0}\{T > k\} + \gamma \mathbf{P}_{\lambda_0}\{T = k\}.$$

Kadangi statistika $T \sim \mathcal{P}(n\lambda_0)$, kai $\lambda = \lambda_0$, tai ši sąlyga reiškia, kad

$$\sum_{m=k+1}^{\infty} \frac{(n\lambda_0)^m}{m!} e^{-n\lambda_0} + \gamma \frac{(n\lambda_0)^k}{k!} e^{-n\lambda_0} = \alpha.$$

Statistikos T skirstinys yra diskretusis, todėl daugumai λ_0 reikšmių TG kriterijus bus randomizuotas, t. y. $\gamma \neq 0$; 1. Norint, kad reikšmingumo lygmuo būtų tiksliai lygus α , tenka įtraukti γ dydžio taško k „dalį“ ir taip papildyti reikšmingumo lygmenį iki α .

Kaip minėjome (žr. [2], 4.2.3 pastabą), paprastai nereikalaujama, kad reikšmingumo lygmuo būtų tiksliai lygus α . Todėl dažniau naudojami nerandomizuoti kriterijai, gau-nami šiek tiek sumažinus reikšmingumo lygmenį. Tiksliau, parenkamas toks mažiausias sveikasis skaičius k' , kad

$$\mathbf{P}_{\lambda_0}(T \geq k') = \sum_{m=k'}^{\infty} \frac{(n\lambda_0)^m}{m!} e^{-n\lambda_0} = 1 - \mathbf{P}\{\chi_{2k'}^2 > 2n\lambda_0\} \leq \alpha.$$

Tada kriterijaus kritinė sritis

$$K_1 = \{\mathbf{X} : T \geq k'\}.$$

Pažymėkime t statistikos T realizaciją ir tegu $F(x|\nu)$ yra χ^2 skirstinio su ν laisvės laipsniais pasiskirstymo funkcija. Tada kriterijus P reikšmių terminais formuluojamas taip: hipotezė atmetama, kai teisinga nelygybė

$$pv = \mathbf{P}_{\lambda_0}\{T \geq t\} = 1 - F(2n\lambda_0|2t) \leq \alpha.$$

Pagaliau kritinę sritį K_1 galima užrašyti parametru λ pasikliovimo intervalo terminais:

$$K_1 = \{\mathbf{X} : \lambda_0 < \underline{\lambda} = \frac{1}{2n}\chi_{1-\alpha}^2(2T)\};$$

čia intervalo pasikliovimo lygmuo $Q = 1 - 2\alpha$.

Analogiškai sudarome TG kriterijų, kai alternatyva yra \bar{H}_2 . Atsižvelgus į ankstesnes pastabas, kriterijaus kritinę sritį galima užrašyti trimis ekvivalenčiais pavidalais. Tegu k'' – didžiausias sveikasis skaičius, kuriam

$$\mathbf{P}_{\lambda_0}(T \leq k'') = \mathbf{P}\{\chi_{2k''+2}^2 > 2n\lambda_0\} \leq \alpha.$$

Tada kriterijaus kritinė sritis

$$\begin{aligned} K_2 = \{\mathbf{X} : T \leq k''\} &\Leftrightarrow pv = F(2n\lambda_0|2t+2) \leq \alpha \Leftrightarrow \\ &\Leftrightarrow \{\mathbf{X} : \lambda_0 > \bar{\lambda} = \frac{1}{2n}\chi_{\alpha}^2(2T+2)\}; \end{aligned}$$

čia intervalo pasikliovimo lygmuo $Q = 1 - 2\alpha$.

I.3.33. a) Kai alternatyva dvipusė $\lambda \neq \lambda_0$, tai, remiantis [2], 4.3.2 teorema, egzistuoja TGN kriterijus

$$\varphi(T) = \begin{cases} 1, & \text{kai } T < c_1, \text{ arba } T > c_2, \\ \gamma, & \text{kai } T = c_i, i = 1, 2, \\ 0, & \text{kai } c_1 < T < c_2. \end{cases}$$

Konstantos $c_1, c_2, \gamma_1, \gamma_2$ randamos iš sąlygų

$$\mathbf{E}_{\lambda_0}(\varphi(T)) = \alpha, \quad \mathbf{E}_{\lambda_0}(T\varphi(T)) = \alpha\mathbf{E}_{\lambda_0}(T).$$

Kadangi

$$\mathbf{E}_{\lambda_0}(T) = n\lambda_0, \quad \mathbf{E}_{\lambda_0}(T\mathbf{1}_{[a, b]}(T)) = n\lambda_0 \mathbf{P}_{\lambda_0}\{a-1 \leq T \leq b-1\},$$

tai lygtis konstantoms rasti galime perrašyti taip:

$$\sum_{k=c_1+1}^{c_2-1} \frac{(n\lambda_0)^k}{k!} e^{-n\lambda_0} + \sum_{i=1}^2 (1-\gamma_i) \frac{(n\lambda_0)^{c_i}}{c_i!} e^{-n\lambda_0} = 1 - \alpha,$$

$$\sum_{k=c_1}^{c_2-2} \frac{(n\lambda_0)^k}{k!} e^{-n\lambda_0} + \sum_{i=1}^2 (1-\gamma_i) \frac{(n\lambda_0)^{c_i-1}}{(c_i-1)!} e^{-n\lambda_0} = 1 - \alpha.$$

b) Atsisakius randomizacijos ir imant simetriškus kriterijus kritinė sritis gali būti užrašyta trimis ekvivalenčiais pavidalais. Tegu k'' ir k' yra tokie didžiausias ir mažiausias sveikieji skaičiai, kad

$$\mathbf{P}_{\lambda_0}\{T \leq k''\} \leq \frac{\alpha}{2}, \quad \mathbf{P}_{\lambda_0}\{T \geq k'\} \leq \frac{\alpha}{2}.$$

Tada kriterijaus kritinė sritis yra

$$\begin{aligned} K_3 &= \{\mathbf{X} : T \leq k'' \text{ arba } T \geq k'\} \Leftrightarrow \\ &\Leftrightarrow pv = 2 \min(1 - F(2n\lambda_0|2t), F(2n\lambda_0|2t+2)) \leq \alpha \Leftrightarrow \\ &\Leftrightarrow \{\mathbf{X} : \lambda_0 < \underline{\lambda} = \frac{1}{2n}\chi_{1-\alpha/2}^2(2T), \text{ arba } \lambda_0 > \bar{\lambda} = \frac{1}{2n}\chi_{\alpha/2}^2(2T+2)\}, \end{aligned}$$

pastarojo intervalo pasiklovimo lygmuo $Q = 1 - \alpha$.

I.3.34. Kai hipotezė H teisinga ir $\lambda = \lambda_0 = 2,5$, tai a. d. $T = \sum_i X_i$ turi Puasono skirstinį su parametru $n\lambda_0 = 100$. Kadangi $\mathbf{P}\{T \leq 83|\lambda = \lambda_0\} = 0,0463 < 0,05$, o $\mathbf{P}\{T \leq 84|\lambda = \lambda_0\} = 0,0575 > 0,05$, tai reikšmingumo lygmens TG kriterijus yra tokis: hipotezė H atmetama, kai $T \leq 83$, atmetama su tikimybė $\gamma = 0,327$, kai $T = 84$, ir priimama kitais atvejais. Kadangi šiame pavyzdyme statistikos T realizacija yra $T = \hat{\lambda}n = 80$, tai hipotezė H atmetama.

Dažniau naudojami nerandomizuoti kriterijai, gaunami šiek tiek sumažinus reikšmingumo lygmenį. Šiame pavyzdyme nerandomizuotu kriterijumi hipotezė H būtų atmetama, kai $T \leq 83$. Kriterijaus reikšmingumo lygmuo $\alpha' = 0,0463 < 0,05$.

Kriterijų galima suformuluoti P reikšmių terminais: hipotezė atmetama, kai P reikšmė $pv = \mathbf{P}\{T \leq 80|\lambda = \lambda_0\} = 0,0226$ yra mažesnė už reikšmingumo lygmenį $\alpha = 0,05$. Hipotezė atmetama.

Pagaliau kriterijų galime suformuluoti pasiklovimo intervalo terminais. Randame parametru λ pasiklovimo lygmens $Q = 1 - 2\alpha = 0,9$ pasiklovimo intervalą

$$\begin{aligned} (\underline{\lambda}; \bar{\lambda}) &= \left(\frac{1}{2n}\chi_{1-\alpha}^2(2T); \frac{1}{2n}\chi_{\alpha}^2(2T+2) \right) = \\ &= \left(\frac{1}{80}\chi_{0,95}^2(160); \frac{1}{80}\chi_{0,05}^2(162) \right) = (1,6470; 2,4088). \end{aligned}$$

Kadangi $\bar{\lambda} < 2,5$, t. y. pasiklovimo intervalas pasislankęs į kairę nuo hipotetinės reikšmės $\lambda_0 = 2,5$, tai hipotezė atmetame.

I.3.35. a) Imties tankis (skaičiuojančiojo mato atžvilgiu) yra

$$f(\mathbf{X}, p) = \exp\{\theta T(\mathbf{X}) - B(\theta)\},$$

čia

$$\theta = \ln \frac{p}{1-p}, \quad T = T(\mathbf{X}) = X_1 + \cdots + X_n, \quad B(\theta) = -n \ln(1-p),$$

priklauso vienparametrai eksponentinio tipo skirstinių šeimai. Todėl egzistuoja TG kriterijai hipotezei dėl p reikšmės tikrinti, kai alternatyvos vienpusės, ir TGN kriterijus – kai alternatyva dvipusė.

Kai alternatyva yra \bar{H}_1 , TG kriterijus yra

$$\varphi(T) = \begin{cases} 1, & \text{kai } T > m, \\ \gamma, & \text{kai } T = m, \\ 0, & \text{kai } T < m; \end{cases}$$

čia konstantos m ir γ randamos iš sąlygos

$$\mathbf{E}_{p_0}(\varphi(T)) = \sum_{k=m+1}^n C_n^k p_0^k (1-p_0)^{n-k} + \gamma C_n^m p_0^m (1-p_0)^{n-m} = \alpha.$$

Analogiškai, kai alternatyva yra \bar{H}_2 , TG kriterijus yra

$$\varphi(T) = \begin{cases} 1, & \text{kai } T < m, \\ \gamma, & \text{kai } T = m, \\ 0, & \text{kai } T > m; \end{cases}$$

čia konstantos m ir γ randamos iš sąlygos

$$\mathbf{E}_{p_0}(\varphi(T)) = \sum_{k=0}^{m-1} C_n^k p_0^k (1-p_0)^{n-k} + \gamma C_n^m p_0^m (1-p_0)^{n-m} = \alpha.$$

Kai alternatyva dvipusė, egzistuoja TGN kriterijus

$$\varphi(T) = \begin{cases} 1, & \text{kai } T < m_1 \text{ arba } T > m_2, \\ \gamma_i, & \text{kai } T = m_i, i = 1, 2, \\ 0, & \text{kai } m_1 < T < m_2; \end{cases}$$

čia konstantos m_1 , m_2 , γ_1 , γ_2 randamos iš lygčių sistemas ($q_0 = 1 - p_0$)

$$\begin{cases} \sum_{k=m_1+1}^{m_2-1} C_n^k p_0^k q_0^{n-k} + \sum_{i=0}^2 (1-\gamma_i) C_n^{m_i} p_0^{m_i} q_0^{n-m_i} = 1 - \alpha, \\ \sum_{k=m_1+1}^{m_2-1} C_n^{k-1} p_0^{k-1} q_0^{n-k} + \sum_{i=0}^2 (1-\gamma_i) C_n^{m_i-1} p_0^{m_i-1} q_0^{n-m_i} = 1 - \alpha. \end{cases}$$

Nereikalaujant, kad reikšmingumo lygmuo būtų tiksliai lygus α , t. y. įtraukiant taškus $T = m_i$ į priėmimo sritį, nerandomizuotas kriterijus galima suformuluoti taip. Tegu m' yra mažiausias sveikasis skaičius, kuriam $\mathbf{P}_{p_0}\{T \geq m'\} \leq \alpha$. Nerandomizuotas kriterijus gali būti užrašytas tokiai trimis ekvivalenčiais pavidalais:

$$\begin{aligned} K_1 = \{\mathbf{X} : T \geq m'\} &\Leftrightarrow pv = I_{p_0}(t, n-t+1) \leq \alpha \Leftrightarrow \\ &\Leftrightarrow \{\mathbf{X} : p_0 \leq p = X_{1-\alpha}(T, n-T+1)\}; \end{aligned}$$

čia intervalo pasikliovimo lygmuo $Q = 1 - 2\alpha$, o t yra statistikos T realizacija, $I_x(\gamma, \eta)$ beta skirstinio su parametrais γ ir η , o $X_\alpha(\gamma, \eta)$ šio skirstinio eilės α kritinė reikšmė.

Pažymėję m'' didžiausią sveikajių skaičių, kuris tenkina nelygybę $\mathbf{P}_{p_0}\{T \leq m''\} \leq \alpha$, gauname nerandomizuotą kriterijų, kuris taip pat gali būti užrašytas trimis ekvivalentais pavidalais

$$\begin{aligned} K_2 = \{\mathbf{X} : T \leq m''\} &\Leftrightarrow pv = 1 - I_{p_0}(t+1, n-t) \leq \alpha \Leftrightarrow \\ &\Leftrightarrow \{\mathbf{X} : p_0 > \bar{p} = X_{1-\alpha}(T+1, n-T)\}; \end{aligned}$$

čia intervalo pasiklivimo lygmuo $Q = 1 - 2\alpha$.

Pažymėkime m'' didžiausią sveikajių skaičių, kuriam $\mathbf{P}_{p_0}\{T \leq m''\} \leq \alpha/2$, o m' – mažiausią sveikajių skaičių, kuriam $\mathbf{P}_{p_0}\{T \geq m'\} \leq \alpha/2$. Tada gauname nerandomizuotą paslinktajį, tačiau lengviau randamą kriterijų:

$$\begin{aligned} K_3 = \{\mathbf{X} : T \leq m'' \text{ arba } T \geq m'\} &\Leftrightarrow \\ &\Leftrightarrow pv = 2 \min(I_{p_0}(t, n-t+1), I_{p_0}(t+1, n-t)) \leq \alpha \Leftrightarrow \\ &\Leftrightarrow \{\mathbf{X} : p_0 < \underline{p} = X_{1-\alpha/2}(T, n-T+1) \text{ arba } p_0 > \bar{p} = X_{\alpha/2}(T+1, n-T)\}; \end{aligned}$$

čia intervalo pasiklivimo lygmuo $Q = 1 - \alpha$.

I.3.36. 0,0879; 0,2052; 0,3731; 0,5703, kai $\alpha = 0,05$; 0,1581; 0,3101; 0,4917; 0,6752, kai $\alpha = 0,1$; 0,2891; 0,4877; 0,6804; 0,8350, kai $\alpha = 0,2$. Imties didumas: a) $n \geq 39$; b) $n \geq 471$.

I.3.37. Prielaida atmetama, nes P reikšmė $pv = \mathbf{P}\{x \geq 6|n, p_0\} = 0,0378 < 0,05$.

I.3.38. a) H_0 atmetame, kai $S = X_1 + \dots + X_{10} \geq 5$; atmetame su tikimybe $\gamma_1 = 0,4657$, kai $S = 0$; atmetame su tikimybe $\gamma_2 = 0,1954$, kai $S = 4$; b) H_0 atmetame, kai $S = 0, 8, 9, 10$; atmetame su tikimybe $\gamma_1 = 0,4702$, kai $S = 1$; atmetame su tikimybe $\gamma_2 = 0,2992$, kai $S = 7$.

I.3.39. Hipotezę H_0 atmetame, kai $X < k_1$ arba $X > k_2$; atmetame su tikimybe γ_i , kai $X = k_i$, $i = 1, 2$; konstantos $k_1, k_2, \gamma_1, \gamma_2$ randamos iš lygčių sistemos:

$$\begin{aligned} p_0 \left[\sum_{k=k_1+1}^{k_2-1} q_0^{k-1} + (1 - \gamma_1)q_0^{k_1} + (1 - \gamma_2)q_0^{k_2} \right] &= 1 - \alpha, \\ p_0^2 \left[\sum_{k=k_1+1}^{k_2-1} kq_0^{k-1} + (1 - \gamma_1)k_1q_0^{k_1-1} + (1 - \gamma_2)k_2q_0^{k_2-1} \right] &= 1 - \alpha. \end{aligned}$$

I.3.40. Tikėtinumo funkcija

$$L(\theta) = \mathbf{1}_{(0,\theta)}(X_{(n)})/\theta^n.$$

Tegu $\theta_1 < \theta_2$. Tada santykis $L(\theta_2)/L(\theta_1)$ yra nemažėjanti statistikos $X_{(n)}$ funkcija. Remiantis [2], 4.3.1 teorema TG kriterijus alternatyvos $\bar{H}_1 : \theta > \theta_0$ atveju atmeta hipotezę, kai $X_{(n)} > (1 - \alpha)^{1/n}\theta_0$.

Analogiškai, alternatyvos $H_2 : \theta < \theta_0$ atveju TG kriterijus atmeta hipotezę, kai $X_{(n)} < \alpha^{1/n}\theta_0$.

Pastebėkime, kad abiejų alternatyvų atveju TG kriterijai ekvivalentūs kriterijui su kritine sritimi

$$K = \{X_{(n)} : X_{(n)} < \alpha^{1/n}\theta_0 \text{ arba } X_{(n)} > \theta_0\}.$$

Iš tikrujų

$$\mathbf{P}_{\theta_0}\{X_{(n)} < \alpha^{1/n}\theta_0\} + \mathbf{P}_{\theta_0}\{X_{(n)} > \theta_0\} = \alpha.$$

Jeigu $\theta > \theta_0$, tai pirmojo TG kriterijaus galia

$$\mathbf{P}_\theta\{X_{(n)} > (1 - \alpha)^{1/n}\theta_0\} = 1 - (1 - \alpha)(\theta_0/\theta)^n,$$

o kriterijaus su kritine sritimi K galia tokia pat:

$$\mathbf{P}_\theta\{X_{(n)} < \alpha^{1/n}\theta_0\} + \mathbf{P}_\theta\{X_{(n)} > \theta_0\} = \alpha(\theta_0/\theta)^n + 1 - (\theta_0/\theta)^n = 1 - (1 - \alpha)(\theta_0/\theta)^n.$$

Jeigu $\theta < \theta_0$, tai antrojo TG kriterijaus galia

$$\mathbf{P}_\theta\{X_{(n)} < \alpha^{1/n}\theta_0\} = \alpha(\theta_0/\theta)^n,$$

kai $\alpha(\theta_0/\theta)^n < 1$, ir lygi 1 priešingu atveju. Kriterijaus su kritine sritimi K galia tokia pat, nes $\mathbf{P}_\theta\{X_{(n)} > \theta_0\} = 0$.

Taigi kriterijus su kritine sritimi K yra TG ir dvipusės alternatyvos atveju.

I.3.41. a) Kai alternatyva yra $\bar{H} : \sigma > \sigma_0$, tai H atmetame, kai $T = \sum_i(X_i - \mu) < \chi^2_{1-\alpha}(2n)/(2\sigma_0^2)$; jeigu alternatyva yra $\bar{H} : \sigma < \sigma_0$, tai H atmetame, kai $T > \chi^2_\alpha(2n)/(2\sigma_0^2)$; b) Jeigu alternatyva yra $\bar{H} : \mu > \mu_0$, tai kriterijaus funkcija $\varphi(\mathbf{X}) = 1$, kai $X_{(1)} \geq \mu_0 - (\ln \alpha)/(\sigma n)$, ir $\varphi(\mathbf{X}) = 0$ kitais atvejais; jeigu alternatyva yra $\mu < \mu_0$, tai kriterijaus funkcija $\varphi(\mathbf{X}) = 1$, kai $X_{(1)} < \mu_0$, ir $\varphi(\mathbf{X}) = \alpha$, kai $X_{(1)} \geq \mu_0$.

I.3.42. H_0 atmetame, kai: a) $S = X_1 + \dots + X_n > \theta_0 \chi^2_\alpha(2n)/2$; b) $S = -(\ln X_1 + \dots + \ln X_n) < \chi^2_{1-\alpha}(2n)/(2\theta_0)$; c) $\sum_i(X_i - 1)^2 > \theta_0 \chi^2_\alpha(n)$; d) $S = X_1^c + \dots + X_n^c > \theta_0^c \chi^2_\alpha(2n)/2$.

I.3.43. a) $(X_{(1)}, X_{(n)}) \sim f(x, y) = n(n-1)(y-x)^{n-2}$, $\theta < x < y < \theta + 1$. b) 0. c) $\beta(\theta) = 1 - (1 - (\theta - \theta_0))^n$, kai $\theta_0 \leq \theta \leq \theta_0 + 1$; $\beta(\theta) = 1$, kai $\theta > \theta_0 + 1$. d) $n \geq 44$.

I.3.48. TG kriterijus atmeta H , kai $a_2 = \sum_i X_i^2/n > c$; konstanta c randama iš sąlygos $\mathbf{P}\{a_2 > c|\mu_0\} = \alpha$. Kadangi $\mathbf{E}(a_2|\mu) = \mu^2 + k\mu$ ir $\mathbf{V}(a_2|\mu) = 2k\mu^2(k+2\mu)$, tai esant dideliems n konstanta $c \approx \mu_0^2 + k\mu_0 + \mu_0 z_\alpha \sqrt{2k(k+2\mu_0)/n}$; kriterijaus galia $\beta(\mu) \approx 1 - \Phi(\sqrt{n}(c - \mu^2 - k\mu)/(\mu \sqrt{2k(k+2\mu)}))$, $\mu > \mu_0$.

I.3.49. Tai atskiras **I.3.48** pratimo atvejis, kai imties didumas lygus 1, o vietoje k imama k/n , t. y. **I.3.48** pratimo atsakymuose reikia išrašyti \bar{X}^2 vietoje a_2 ir k/n vietoje k .

I.3.50. Kadangi $\mathbf{P}_\beta(0) = 0$, tai a. d. X įgyja reikšmes 1, 2, ... Tankio funkcija $f(x|\beta) = \beta^{x-1} - \beta^x$, $x = 1, 2, \dots$. Kai $\beta_1 > \beta_0$, tai santykis

$$\frac{f(x|\beta_1)}{f(x|\beta_0)} = \left(\frac{\beta_1}{\beta_0}\right)^{x-1} \frac{1 - \beta_1}{1 - \beta_0}$$

didėja X atžvilgiu. Remiantis [2], 4.3.1 teorema TG kriterijus turi pavidalą: $\varphi(X) = 1$, kai $X > c$; $\varphi(X) = \gamma$, kai $X = c$; $\varphi(X = 0) = 0$, kai $X < c$, ir kriterijaus reikšmingumo lygmuo $\alpha = \mathbf{E}_{\theta_0}\varphi(X)$. Randame, kad c yra mažiausias sveikasis skaičius, tenkinantis nelygybę $p = \beta_0^c \leq \alpha$ ir $\gamma = (\alpha - p)/(\beta_0^{c-1}(1 - \beta_0))$.

I.3.4 skyrelis

I.3.51. Pereidami prie a. d. $Y_i = X_i - \mu_0$ nesiaurindami prasmės galime tarti, kad $\mu_0 = 0$. Tikėtinumo funkcija

$$L(\mu, \sigma^2) = (\sqrt{2\pi})^{-n} \exp\{\theta U + \vartheta T\} \exp\{-n\mu^2/(2\sigma^2) - n \ln \sigma\}$$

priklauso dviparametrei eksponentinio tipo skirstinių šeimai su parametru $\theta = n\mu/\sigma^2$, trukdančiuoju parametru $\vartheta = -1/(2\sigma^2)$ ir statistikomis $U = \bar{X}, T = \sum_i X_i^2$.

Kai $\mu = 0$, statistikos

$$V = h(U, T) = \frac{\sqrt{n(n-1)U}}{\sqrt{T-nU^2}} = \frac{\sqrt{n}\bar{X}}{s} \sim S(n-1), \quad s^2 = \frac{1}{n-1} \sum_i (X_i - \bar{X})^2$$

skirstinys nepriklauso nuo ϑ ir monotoninis pagal U . Remiantis [2], 4.4.3 teorema egzistuoja TGN kriterijus hipotezei $H : \theta = 0$, kai alternatyva yra $\bar{H}_1 : \theta > 0$, tikrinti, kurio kritinė sritis

$$K_1 = \{\mathbf{X} : t(\mathbf{X}) = \sqrt{n}\bar{X}/s > t_\alpha(n-1)\}.$$

Kai $\theta > 0$ statistika $t(\mathbf{X})$ turi necentrinį Stjudento skirstinį su $n-1$ laisvės laipsniu ir necentriškumo parametru $\delta = \sqrt{n}\theta/\sigma$. Todėl kriterijaus galia

$$\beta_1(\mu, \sigma^2) = \mathbf{P}\{t_{\delta; n-1} > t_\alpha(n-1)\}.$$

Analogiškai, kai alternatyva yra $\bar{H}_2 : \theta < 0$, TGN kriterijaus kritinė sritis

$$K_2 = \{\mathbf{X} : t(\mathbf{X}) = \sqrt{n}\bar{X}/s < -t_\alpha(n-1)\}.$$

Grįždami prie hipotezės $H : \mu = \mu_0$ gausime, kad vienpusių alternatyvų atvejais kriterijai nusakomi kritinėmis sritimis K_1, K_2 , kuriose reikia imti $t(\mathbf{X}) = \sqrt{n}(\bar{X} - \mu_0)/s$.

Tegu t yra statistikos $t(\mathbf{X})$ realizacija, o $F(x|\nu)$ Stjudento skirstinio su ν laisvės laipsnių pasiskirstymo funkcija. Tada kriterijai su kritinėmis sritimis K_1, K_2 P reikšmių terminais formuluojami taip: hipotezė H atmetama, kai atitinkamai

$$pv = 1 - F(t|n-1) < \alpha, \quad pv = F(t|n-1) < \alpha.$$

I.3.52. Statistika V nėra tiesinė statistikos U atžvilgiu. Imkime statistiką

$$W = \frac{U}{\sqrt{T}} = \frac{\bar{X}}{\sqrt{\sum_i X_i^2}},$$

kurios skirstinys, kai $\theta = 0$, nepriklauso nuo σ^2 ir ji tiesinė U atžvilgiu. Remiantis [2], 4.4.3 teorema egzistuoja TGN kriterijus, kurio priėmimo sritis yra

$$c_1 < W < c_2.$$

Statistikos W skirstinys, kai $\theta = 0$, yra simetriškas 0 atžvilgiu. Todėl kritinė sritis yra $|W| > c$, kai c randamas iš sąlygos $\mathbf{P}_0\{W > c\} = \alpha/2$. Statistikos W ir $t(\mathbf{X})$ susietos lygybe

$$t(\mathbf{X}) = \frac{W \sqrt{n(n-1)}}{\sqrt{1-nW^2}},$$

iš kurios matome, kad $|t|$ yra didėjanti $|W|$ funkcija. Todėl α lygmens kriterijaus kritinę sritį $|W| > c$ galima perrašyti taip

$$K_3 = \{\mathbf{X} : |t(\mathbf{X})| = \sqrt{n}|\bar{X} - \mu_0|/s > t_{\alpha/2}(n-1)\}.$$

P reikšmių terminais hipotezė atmetama, kai

$$pv = 2(1 - F(|t||n-1)) < \alpha.$$

I.3.53. Perrašykime tikétinumo funkciją tokiu būdu

$$L(\mu, \sigma^2) = (\sqrt{2\pi})^{-n} \exp\{\theta U + \vartheta T\} \exp\{-n\mu^2/(2\sigma^2) - n \ln \sigma\},$$

kai dominantis parametras $\theta = -1/(2\sigma^2)$, trukdantysis parametras $\vartheta = n\mu/\sigma^2$ ir statistikos $U = \sum_i X_i^2, T = \bar{X}$.

Statistika

$$V = h(U, T) = U - nT^2 = \sum_i (X_i - \bar{X})^2$$

yra tiesinė U funkcija, o jos skirstinys, kai σ fiksotas, nepriklauso nuo ϑ , taip pat ir nuo T ; statistika $V/\sigma_0^2 \sim \chi^2(n-1)$, kai H teisinga.

Remiantis [2], 4.4.3 teorema alternatyvos $\bar{H}_1 : \sigma^2 > \sigma_0^2$ atveju egzistuoja TGN kriterijus, kurio kritinė sritis yra

$$K_1 = \{\mathbf{X} : V/\sigma_0^2 > \chi_{\alpha}^2(n-1)\}.$$

Jeigu v yra statistikos V/σ_0^2 realizacija, tai P reikšmių terminais hipotezė atmetama, kai

$$pv = \mathbf{P}\{\chi_{n-1}^2 > v\} < \alpha.$$

Analogiškai, kai alternatyva $\bar{H}_2 : \sigma^2 < \sigma_0^2$, egzistuoja TGN kriterijus, kurio kritinė sritis yra

$$K_2 = \{\mathbf{X} : V/\sigma_0^2 < \chi_{1-\alpha}^2(n-1)\},$$

arba P reikšmių terminais hipotezė atmetama, kai

$$pv = \mathbf{P}\{\chi_{n-1}^2 < v\} < \alpha.$$

Kriterijų galios funkcijos

$$\beta_1(\sigma^2) = \mathbf{P}\{\chi_{n-1}^2 > (\sigma_0^2/\sigma^2)\chi_{\alpha}^2(n-1)\}, \quad \beta_2(\sigma^2) = \mathbf{P}\{\chi_{n-1}^2 < (\sigma_0^2/\sigma^2)\chi_{1-\alpha}^2(n-1)\}.$$

I.3.54. Statistika V tiesinė U atžvilgiu. Remiantis [2], 4.4.3 teorema egzistuoja TGN kriterijus, kurio priemimo sritis

$$A_3 = \{\mathbf{X} : c_1 < V/\sigma_0^2 < c_2\}.$$

Analogiškai I.3.25 pratimui konstantos c_1 ir c_2 gali būti surastos iš lygčių sistemos

$$\mathbf{P}\{c_1 < \chi_{n-1}^2 < c_2\} = 1 - \alpha,$$

$$\mathbf{P}\{c_1 < \chi_{n+1}^2 < c_2\} = 1 - \alpha.$$

Imdami paslinktą, tačiau paprasčiau randamą simetrinį kriterijų gausime kritinę sritį

$$K_3^* = \{\mathbf{X} : V/\sigma_0^2 < \chi_{1-\alpha/2}^2(n-1), \text{ arba } V/\sigma_0^2 > \chi_{\alpha/2}^2(n-1)\};$$

P reikšmių terminais hipotezė atmetama, kai

$$pv = 2 \min(\mathbf{P}\{\chi_{n-1}^2 < v\}, \mathbf{P}\{\chi_{n-1}^2 > v\}) < \alpha.$$

Kriterijaus galios funkcija

$$\beta_3(\sigma^2) = 1 - \mathbf{P}\{(\sigma_0^2/\sigma^2)\chi_{1-\alpha/2}^2 < \chi_{n-1}^2 < (\sigma_0^2/\sigma^2)\chi_{\alpha/2}^2\}.$$

I.3.55. Žr. **I.3.51** pratimą.

I.3.56. Žr. **I.3.51** pratimą.

I.3.57. Jeigu σ žinoma, tai kriterijaus galia lygi 0,5573; 0,7228; 0,8505, kai $n = 5$; 0,8119; 0,9354; 0,9842, kai $n = 10$; 0,9270; 0,9871; 0,9987, kai $n = 15$. Jeigu σ nežinoma, tai kriterijaus galia lygi 0,5869; 0,7280; 0,8393, kai $n = 5$; 0,8077; 0,9275; 0,9795, kai $n = 10$; 0,9216; 0,9844; 0,9961, kai $n = 15$.

I.3.58. Užrašę tikėtinumo funkciją tokiu būdu

$$L(\mu_1, \dots, \mu_s, \sigma^2) = \exp\{\theta_1 X_1 + \sum_{j=2}^n \theta_j X_j - \frac{1}{2\sigma^2} \sum_{i=1}^n X_i^2 - B(\theta_1, \dots, \theta_s, \sigma^2)\},$$

čia $\theta_i = \mu_i/\sigma^2$, $i = 1, \dots, s$, matome, kad ji priklauso $(s+1)$ -mačių eksponentinių skirstinių šeimai. Dominantis parametras θ_1 , o trukdantysis $\vartheta = (\theta_2, \dots, \theta_s, -1/(2\sigma^2))^T$; pakanka mosios statistikos $U = U(\mathbf{X}) = X_1$, $\mathbf{T} = \mathbf{T}(\mathbf{X}) = (X_2, \dots, X_s, \sum_i X_i^2)^T$. Nemažinant bendrumo galima tarti, kad tikrinama hipotezė $H : \theta_1 = 0$, t. y. $\mu_1^0 = 0$ (priešingu atveju vietoje X_1 imsime $Y_1 = X_i - \mu_1^0$). Statistikos $V(U, \mathbf{T}) = (X_1 - \mu_1)/\sqrt{\hat{\sigma}^2} \sim S(n-n)$, čia $\hat{\sigma}^2 = \sum_{i=s+1}^n X_i^2/(n-s)$, skirstinys, kai $\theta_1 = 0$, nepriklauso nuo ϑ . Remiantis [2], 4.4.3 teorema, kai alternatyva yra $\bar{H}_1 : \theta_1 > 0$, reikšmingumo α TGN kriterijus atmeta hipotezę, kai $T = (X_1 - \mu_1^0)/\sqrt{\hat{\sigma}^2} > t_\alpha(n-s)$. Alternatyvos $\bar{H}_2 : \theta_1 < 0$ atveju hipotezė atmetama, kai $T < -t_\alpha(n-s)$, o dvipusės alternatyvos $\bar{H}_3 : \theta_1 \neq 0$ atveju – kai $|T| > t_{\alpha/2}(n-s)$.

I.3.59. Pažymėkime $\hat{\beta}_1 = \sum_i X_i(t_i - \bar{t})/\sum_i(t_i - \bar{t})^2$, $\hat{\beta}_0 = \bar{X}$, $\hat{\sigma}^2 = s^2 = \sum_i(X_i - \hat{\beta}_0 - \hat{\beta}_1(t_i - \bar{t}))^2/(n-2)$. Tada: a) H_0 atmetame, kai $\sqrt{n}(\hat{\beta}_0 - \theta_0)/(s) > t_\alpha(n-2)$; b) H_0 atmetame, kai $|\hat{\beta}_0 - \theta_0|/(s) > t_{\alpha/2}(n-2)$; c) H_0 atmetame, kai $(\hat{\beta}_1 - \theta_0)/(sd) > t_\alpha(n-2)$, $d^2 = 1/\sum_i(t_i - \bar{t})^2$; d) H_0 atmetame, kai $|\hat{\beta}_1 - \theta_0|/(sd) > t_{\alpha/2}(n-2)$.

I.3.60. a) Tikėtinumo funkcija

$$L(\lambda, \eta) = \exp\{\theta U + \vartheta T\} \exp\{n\eta \ln \lambda - n \ln \Gamma(\eta)\} / \prod_i X_i$$

priklauso dviparametrei eksponentinio tipo skirstinių šeimai. Dominantis parametras $\theta = \eta$, trukdantysis parametras $\vartheta = -n\lambda$ ir statistikos $U = \sum_i \ln X_i$, $T = \bar{X}$. Remiantis

[2], 4.4.2 teorema egzistuoja TGN kriterijus, kurį apibrežiame kaip sąlyginį paviršiuose $T = t$. Kritinė sritis

$$K = \{\mathbf{X} : U > c(T)\} \Leftrightarrow \{\mathbf{X} : \prod_i X_i > g(\bar{X})\}.$$

b) Analogiškai p. a).

I.3.61. Jungtinės imties $(\mathbf{X}^T, \mathbf{Y}^T)^T$ tankis

$$f(\mathbf{X}, \mathbf{Y}; \boldsymbol{\theta}) = C \exp\left\{-\frac{1}{2\sigma_1^2} \sum_i X_i^2 + \frac{\mu_1}{\sigma_1^2} \sum_i X_i - \frac{1}{2\sigma_2^2} \sum_i Y_i^2 + \frac{\mu_2}{\sigma_2^2} \sum_i Y_i - b(\boldsymbol{\theta})\right\}$$

priklauso keturparametrei eksponentinio tipo skirstinių šeimai, parametras $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1, \sigma_2)^T$, $-\infty < \mu_1, \mu_2 < \infty$, $0 < \sigma_1, \sigma_2 < \infty$, $C = (2\pi)^{-(m+n)/2}$.

Pertvarkykime tankį taip, kad išsiskirtų parametras $\mu_1 - \mu_2 - \beta_0$:

$$f(\mathbf{X}, \mathbf{Y}; \theta, \vartheta) = \exp\{\theta U(\mathbf{X}, \mathbf{Y}) + \vartheta T(\mathbf{X}, \mathbf{Y}) - B(\theta, \vartheta)\},$$

$$\theta = \frac{(\mu_1 - \mu_2 - \beta_0)mn}{m\sigma_{10}^2 + n\sigma_{20}^2}, \quad \vartheta = \frac{n\sigma_{20}^2(\mu_1 - \beta_0) + m\sigma_{10}^2\mu_2}{m\sigma_{10}^2 + n\sigma_{20}^2},$$

$$U = U(\mathbf{X}, \mathbf{Y}) = \bar{X} - \bar{Y}, \quad T = T(\mathbf{X}, \mathbf{Y}) = \frac{n}{\sigma_{10}^2} \bar{X} + \frac{m}{\sigma_{20}^2} \bar{Y}.$$

Statistikos

$$Z = \frac{(\bar{X} - \bar{Y} - \beta_0)\sqrt{mn}}{\sqrt{m\sigma_{10}^2 + n\sigma_{20}^2}}$$

skirstinys, kai $\mu_1 - \mu_2 = \beta_0$, yra $N(0, 1)$ ir nepriklauso nuo ϑ , tai jis nepriklauso ir nuo T . Remiantis [2], 4.4.2 teorema, egzistuoja TGN kriterijai dėl parametro θ (kartu dėl skirtumo $\mu_1 - \mu_2$) reikšmių, kai yra vienpusės ar dvipusė alternatyvos. Kadangi Z yra monotoniskai didėjanti ir tiesinė pagal U , tai alternatyvų $\bar{H}_1 : \mu_1 - \mu_2 > \beta_0$, $\bar{H}_2 : \mu_1 - \mu_2 < \beta_0$, $\bar{H}_3 : \mu_1 - \mu_2 \neq \beta_0$ atvejais kritinės sritys yra

$$K_1 = \{(\mathbf{X}, \mathbf{Y}) : Z > z_\alpha\}, \quad K_2 = \{(\mathbf{X}, \mathbf{Y}) : Z < -z_\alpha\},$$

$$K_3 = \{(\mathbf{X}, \mathbf{Y}) : |Z| > z_{\alpha/2}\}.$$

Kriterijų galios funkcijos išreiškiamos standartinio normaliojo skirstinio pasiskirstymo funkcija $\Phi(x)$.

Pažymėkime z statistikos Z realizaciją. Tada P reikšmių terminais kriterijai K_1, K_2, K_3 formuluojamai taip: hipotezė atmetama, kai atitinkamai teisingos nelygybės

$$pv = 1 - \Phi(z) \leq \alpha, \quad pv = \Phi(z) \leq \alpha,$$

$$pv = 2 \min(1 - \Phi(z), \Phi(z)) = 2(1 - \Phi(|z|)) \leq \alpha.$$

I.3.62. Pertvarkykime tankį taip, kad išsiskirtų dominantis parametras $\mu_1 - \mu_2 - \beta_0$:

$$f(\mathbf{X}, \mathbf{Y}; \theta, \vartheta) = \exp\{\theta U + \vartheta_1 T_1 + \vartheta_2 T_2 - B(\theta, \vartheta_1, \vartheta_2)\},$$

$$U = \bar{X} - \bar{Y}, \quad T_1 = n\bar{X} + m\bar{Y}, \quad T_2 = \sum_i X_i^2 + \sum_i Y_i^2,$$

$$\theta = \frac{(\mu_1 - \mu_2 - \beta_0)mn}{(m+n)\sigma^2}, \quad \vartheta_1 = \frac{n(\mu_1 - \beta_0) + m\mu_2}{(m+n)\sigma^2}, \quad \vartheta_2 = -\frac{1}{2\sigma^2}.$$

Nagrinėkime statistiką

$$V = V(U, T_1, T_2) = \frac{\bar{X} - \bar{Y} - \beta_0}{\sqrt{\sum_i (X_i - \bar{X})^2 + \sum_i (Y_i - \bar{Y})^2}} = \frac{U - \beta_0}{\sqrt{T_2 - \frac{1}{m+n}T_1^2 - \frac{mn}{m+n}U^2}}.$$

Funkcija V yra monotoniškai didėjanti pagal U . Be to, jos skirstinys, kai $\theta = 0$, nepriklauso nuo parametru μ_1, μ_2, σ (kartu su T_1, T_2). Tuo įsitikinti galima pažymėjus, kad V reikšmė nepakinta, kai X_i pakeičiamas į $(X_i - \mu_1)/\sigma$ ir Y_i pakeičiamas į $(Y_i - \mu_2)/\sigma$.

Remiantis [2], 4.4.2 teorema, egzistuoja TGN kriterijus, kai alternatyva yra $\bar{H}_1 : \theta > 0$. Jo kritinė sritis yra $V \geq c_1$, arba ekvivalenčia forma $T \geq c'_1$,

$$T = V \sqrt{\frac{mn(m+n-2)}{m+n}} = \frac{\bar{X} - \bar{Y} - \beta_0}{\sqrt{s_1^2(n-1) + s_2^2(m-1)}} \sqrt{\frac{mn(m+n-2)}{m+n}},$$

čia s_1^2 ir s_2^2 yra nepaslinktieji dispersijos σ^2 įvertiniai, sudaryti pagal imtį \mathbf{X} ir imtį \mathbf{Y} . Kadangi statistikos T skirstinys, kai $\mu_1 - \mu_2 = \beta_0$, yra Stjudento su $m+n-2$ laisvės laipsnių, TGN kriterijaus kritinė sritis yra

$$K_1 = \{(\mathbf{X}, \mathbf{Y}) : T > t_\alpha(m+n-2)\}.$$

Analogiškai, kai alternatyva yra $\bar{H}_2 : \mu_1 - \mu_2 < \beta_0$, TGN kriterijaus kritinė sritis yra

$$K_2 = \{(\mathbf{X}, \mathbf{Y}) : T < -t_\alpha(m+n-2)\}.$$

Tikrinant hipotezę $H_3 : \theta = 0$ (arba $\mu_1 - \mu_2 = \beta_0$), kai alternatyva $\bar{H}_3 : \theta \neq 0$ yra dvipusė, tiesiogiai pritaikyti [2], 4.4.3 teoremos negalima, nes V nėra tiesinė U funkcija. Imkime funkciją

$$W = \frac{\bar{X} - \bar{Y} - \beta_0}{\sqrt{\sum_i X_i^2 + \sum_i Y_i^2 - \frac{1}{m+n}(\sum_i X_i + \sum_i Y_i)^2}} = \frac{U}{\sqrt{T_2 - \frac{1}{m+n}T_1^2}},$$

kuri tiesiškai priklauso nuo U . Kadangi W ir V susieti lygybe

$$V = \frac{W}{\sqrt{1 - \frac{mn}{m+n}W^2}},$$

tai W skirstinys, kai $\theta = 0$, taip pat nepriklauso nuo T_1, T_2 . Be to, W skirstinys, kai $\theta = 0$, yra simetrinis taško $\theta = 0$ atžvilgiu, todėl, remiantis 4.4.2 teorema, TGN kriterijaus kritinė sritis yra $|W| > c$.

Funkcija $|V|$ yra monotoniškai didėjanti pagal $|W|$. Todėl šią kritinę sritį galima perrašyti $|V|$ (kartu ir $|T|$) terminais. Gauname kritinę sritį

$$K_3 = \{(\mathbf{X}, \mathbf{Y}) : |T| > t_{\alpha/2}(m+n-2)\}.$$

Pažymėkime t statistikos T realizaciją ir tegu $F(x|\nu)$ yra Stjudento skirstinio su ν laisvės laipsniais pasiskirstymo funkcija. Tada P reikšmių terminais kriterijai K_1, K_2, K_3 formuluojami taip: hipotezė atmetama, kai atitinkamai teisingos nelygybės

$$pv = 1 - F(t|m+n-2) \leq \alpha, \quad pv = F(t|m+n-2) \leq \alpha,$$

$$pv = 2 \min(1 - F(t|m+n-2), F(t|m+n-2)) = 2(1 - F(|t||m+n-2)) \leq \alpha.$$

I.3.63. Tanki pertvarkykime taip:

$$f(\mathbf{X}, \mathbf{Y}; \theta, \vartheta) = \exp\{\theta \mathbf{U} + \vartheta_1 \mathbf{T}_1 + \vartheta_2 \mathbf{T}_2 + \vartheta_3 \mathbf{T}_3 - \mathbf{B}(\theta, \vartheta)\},$$

$$\theta = -\frac{1}{2\sigma_2^2} + \frac{1}{2\sigma_1^2}, \quad \vartheta_1 = -\frac{1}{2\sigma_1^2}, \quad \vartheta_2 = \frac{n\mu_1}{\sigma_1^2}, \quad \vartheta_3 = \frac{n\mu_2}{\sigma_2^2},$$

$$U = \sum_i Y_i^2, \quad T_1 = \sum_i X_i^2 + \sum_i Y_i^2, \quad T_2 = \bar{X}, \quad T_3 = \bar{Y}.$$

Nagrinėkime šių statistikų funkciją

$$F = \frac{(m-1) \sum_i (X_i - \bar{X})^2}{(n-1) \sum_i (Y_i - \bar{Y})^2} = \frac{s_1^2}{s_2^2} = \frac{(m-1)(T_1 - U - nT_2^2)}{(n-1)(U - nT_3^2)},$$

kuri monotoninė pagal U . Jos skirtinys, kai $\theta = 0$ (t. y. $\sigma_1^2 = \sigma_2^2$), yra Fišerio skirtinys su $n-1$ ir $m-1$ laisvės laipsnių. Taigi F skirtinys, kai $\theta = 0$, nepriklauso nuo parametru $\vartheta_1, \vartheta_2, \vartheta_3$, o kartu nuo statistikų T_1, T_2, T_3 . Remiantis [2], 4.4.3 teorema, egzistuoja TGN kriterijai, kai alternatyvos yra $\bar{H}_1 : \sigma_1^2 > \sigma_2^2$, $\bar{H}_2 : \sigma_1^2 < \sigma_2^2$ vienpusės. Jų kritinės sritys yra

$$K_1 = \{(\mathbf{X}, \mathbf{Y}) : F > F_\alpha(n-1, m-1)\},$$

$$K_2 = \{(\mathbf{X}, \mathbf{Y}) : F < F_{1-\alpha}(n-1, m-1)\};$$

čia $F_\alpha(\nu_1, \nu_2)$ yra Fišerio skirtinio su ν_1 ir ν_2 laisvės laipsnių α kritinė reikšmė.

Pažymėkime f statistikos F realizaciją. Tada P reikšmių terminais kriterijai K_1, K_2 formuluojami taip: hipotezė atmetama, kai atitinkamai teisingos nelygybės

$$pv = 1 - \mathbf{P}\{F_{n-1, m-1} \geq f\} \leq \alpha, \quad pv = \mathbf{P}\{F_{n-1, m-1} \leq f\} \leq \alpha.$$

Kriterijų K_1, K_2 galia išreiškiama Fišerio skirtinio pasiskirstymo funkcija, kai jos argumentas priklauso nuo dispersijų santykio $\lambda = \sigma_1^2/\sigma_2^2$:

$$\beta_1(\lambda) = \mathbf{P}\{F_{n-1, m-1} > \frac{1}{\lambda} F_\alpha(n-1, m-1)\}, \quad \lambda > k,$$

$$\beta_2(\lambda) = \mathbf{P}\{F_{n-1, m-1} < \frac{1}{\lambda} F_{1-\alpha}(n-1, m-1)\}, \quad \lambda < k.$$

Kai alternatyva $\bar{H}_3 : \theta \neq 0$ yra dvipusė, tiesiogiai pritaikyti [2], 4.4.3 teoremos negalima, nes F nėra tiesinė U funkcija. Apibrėžkime statistiką W lygybe

$$W = \frac{(n-1)F}{m-1 + (n-1)F} = \frac{T_1 - kU - nT_2^2}{(T_1 - nT_2^2 - knT_3^2)}.$$

Statistika W yra tiesinė pagal U . Kadangi ji išreiškiama per F , tai jos skirtinys, kai $\theta = 0$, taip pat nepriklauso nuo T_1, T_2, T_3 . Remiantis [2] 4.4.3 teorema, hipotezė H_3 atmetama, kai

$$W < c'_1 \quad \text{arba} \quad W > c'_2.$$

Funkcija W yra monotoniskai didėjanti pagal F , kai $0 < F < \infty$. Todėl kritinę sritį galime perrašyti statistikos F terminais: $F < c_1$, arba $F > c_2$. Konstantos c_1 ir c_2 randamos iš sąlygų

$$\mathbf{E}(\varphi(F)|\sigma_1^2 = \sigma_2^2) = \mathbf{P}\{F_{n-1,m-1} < c_1\} + \mathbf{P}\{F_{n-1,m-1} > c_2\} = \alpha,$$

$$\mathbf{E}(F\varphi(F)|\sigma_1^2 = \sigma_2^2) = \alpha\mathbf{E}(F|\sigma_1^2) = \sigma_2^2.$$

Tada

$$\mathbf{E}(F|\sigma_1^2 = \sigma_2^2) = \mathbf{E}(F_{n-1,m-1}) = \frac{m-1}{m-3},$$

$$\mathbf{E}(F\varphi(F)|\sigma_1^2 = \sigma_2^2) = \frac{m-1}{m-3}[\mathbf{P}\{F_{n+1,m-3} < c_1\} + \mathbf{P}\{F_{n+1,m-3} > c_2\}].$$

Lygčių sistema parametrams c_1 ir c_2 rasti gali būti užrašyta taip:

$$\begin{cases} \mathbf{P}\{c_1 < F_{n-1,m-1} < c_2\} = 1 - \alpha, \\ \mathbf{P}\{c_1 < F_{n+1,m-3} < c_2\} = 1 - \alpha. \end{cases}$$

Praktiskai vietoje K_3 TGN kriterijaus dažniau naudojamas paslinktasis, tačiau pa- prasčiau randamas simetrinis kriterijus, kurio kritinė sritis

$$\tilde{K}_3 = \{(\mathbf{X}, \mathbf{Y}) : F < F_{1-\alpha/2}(n-1, m-1), \text{ arba } F > F_{\alpha/2}(n-1, m-1)\},$$

P reikšmių terminais kriterijus formuluojamasis taip: hipotezė atmetama, kai teisinga nelygybė

$$pv = 2 \min(1 - \mathbf{P}\{F_{n-1,m-1} \leq f\}, \mathbf{P}\{F_{n-1,m-1} \geq f\}) \leq \alpha.$$

I.3.64. Tikėtinumo funkciją $L(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ užrašykime tokiu pavidalu

$$L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \exp\{\theta U + \vartheta_1 T_1 + \vartheta_2 T_2 + \vartheta_3 T_3 + \vartheta_4 T_4 - B(\theta, \boldsymbol{\vartheta})\},$$

čia $\theta = \rho / (\sigma_1 \sigma_2 (1 - \rho^2))$ yra dominantis parametras

$$\begin{aligned} \vartheta_1 &= \frac{-1}{2\sigma_1^2(1 - \rho^2)}, \quad \vartheta_2 = \frac{-1}{2\sigma_2^2(1 - \rho^2)}, \quad \vartheta_3 = \frac{1}{(1 - \rho^2)}\left(\frac{\mu_1}{\sigma_1^2} - \frac{\rho\mu_2}{\sigma_1\sigma_2}\right), \\ \vartheta_4 &= \frac{1}{(1 - \rho^2)}\left(\frac{\mu_2}{\sigma_2^2} - \frac{\rho\mu_1}{\sigma_1\sigma_2}\right) \end{aligned}$$

trukdantieji parametrai; statistikos

$$U = \sum_i X_i Y_i, \quad T_1 = \sum_i X_i^2, \quad T_2 = \sum_i Y_i^2, \quad T_3 = \sum_i X_i, \quad T_4 = \sum_i Y_i.$$

Turime penkiaparametrę eksponentinio tipo skirstinių šeimą. Hipotezė $H : \rho = 0$ ekvivalenti hipotezei $H : \theta = 0$. Nagrinėkime statistiką

$$r = r(U, \mathbf{T}) = \frac{s_{12}}{s_1 s_2} = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i (X_i - \bar{X})^2 \sum_i (Y_i - \bar{Y})^2}} = \frac{U - T_3 T_4 / n}{\sqrt{(T_1 - T_3^2/n)(T_2 - T_4^2/n)}}.$$

Statistikos r skirstinys nepriklauso nuo parametrų $\mu_1, \mu_2, \sigma_1^2, \sigma_2^2$. Kai hipotezė $H : \rho = 0$ yra teisinga, tai r skirstinys nepriklauso nuo parametro $\boldsymbol{\vartheta} = (\vartheta_1, \vartheta_2, \vartheta_3, \vartheta)^T$, o

kartu pačiu ir nuo statistikos $\mathbf{T} = (T_1, T_2, T_3, T_4)^T$. Kadangi r yra tiesinė U funkcija, tai remiantis [2] 4.4.3 teorema, tikrinant hipotezę $H : \rho = 0$, kai alternatyvos yra $\bar{H}_1 : \rho > 0$ arba $\bar{H}_2 : \rho < 0$, egzistuoja TGN kriterijai, kurių atmetimo sritys $r > c_2$, arba $r < c_1$. Dvipusės alternatyvos $\bar{H}_3 : \rho \neq 0$ atveju, remiantis statistikos r skirstinio simetriškumu 0 atžvilgiu, TGN kriterijus atmeta hipotezę, kai $|r| > d$. Jeigu kriterijaus reikšmingumo lygmuo α , tai konstantos c_1, c_2, d randamos iš sąlygų

$$F(c_1|0) = \alpha, \quad 1 - F(c_2|0) = \alpha, \quad F(-d|0) + 1 - F(d|0) = \alpha,$$

čia $F(x|\rho)$ – statistikos r pasiskirstymo funkcija; tankio funkcija $f(x|\rho)$ pateikta I.2.169 pratime. Kai $\rho = 0$, tankis yra

$$f(x|0) = \frac{1}{\sqrt{\pi}} \frac{\Gamma(\frac{n-1}{2})}{\Gamma(\frac{n-2}{2})} (1 - r^2)^{\frac{n-4}{2}}.$$

Atlikę a. d. r transformaciją: $t = \sqrt{n-2r}/\sqrt{1-r^2}$, gauname, kad $t \sim S(n-2)$, kai $\rho = 0$. Kadangi t yra monotoniškai didėjanti r funkcija, tai pateiktieji reikšmingumo lygmens α TGN kriterijai įgauna tokį pavidalą

$$t > t_\alpha(n-2), \quad t < -t_\alpha(n-2), \quad |t| > t_{\alpha/2}(n-2).$$

Tegu $S(x|\nu)$ yra Stjudento skirstinio su ν laisvės laipsniais pasiskirstymo funkcija. Tada P reikšmių terminais kriterijai formuluojami taip: hipotezė atmetama, kai atitinkamai teisingos nelygybės

$$pv = 1 - S(t|n-2) \leq \alpha, \quad pv = S(t|n-2) \leq \alpha,$$

$$pv = 2 \min(1 - S(t|n-2), S(t|n-2)) = 2(1 - S(|t||n-2)) \leq \alpha;$$

šiose nelygybėse t yra statistikos realizacija.

I.3.65. a) Tikėtinumų santykis

$$\Lambda = \frac{\max_{\boldsymbol{\mu}, \boldsymbol{\Sigma}: \rho = \rho_0} L(\boldsymbol{\mu}, \boldsymbol{\Sigma})}{\max_{\boldsymbol{\mu}, \boldsymbol{\Sigma}} L(\boldsymbol{\mu}, \boldsymbol{\Sigma})} = \frac{L(\tilde{\boldsymbol{\mu}}, \tilde{\boldsymbol{\Sigma}})}{L(\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}})},$$

čia $\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}}$ yra parametru $\boldsymbol{\mu}, \boldsymbol{\Sigma}$ DT įvertiniai, o $\tilde{\boldsymbol{\mu}}, \tilde{\boldsymbol{\Sigma}}$ DT įvertiniai, surasti esant sąlygai $\rho = \rho_0$.

Parametru $\boldsymbol{\mu}, \boldsymbol{\Sigma}$ DT įvertiniai (žr. [4], 1.2 skyrelį) yra $\hat{\mu}_1 = \bar{X}, \hat{\mu}_2 = \bar{Y}, \hat{\boldsymbol{\Sigma}} = \mathbf{S}/n; \mathbf{S} = [S_{ij}]_{2 \times 2}, S_{11} = \sum_i (X_i - \bar{X})^2, S_{22} = \sum_i (Y_i - \bar{Y})^2, S_{12} = S_{21} = \sum_i (X_i - \bar{X})(Y_i - \bar{Y})$, o tikėtinumo funkcijos maksimumas

$$L(\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}}) = (\sqrt{2\pi})^{-n} n^n e^{-n} |\mathbf{S}|^{-n/2}.$$

Užrašę tikėtinumo funkciją, kai $\rho = \rho_0$, tokiu pavidalu

$$L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(\sqrt{2\pi(1-\rho_0^2)}\sigma_1\sigma_2)^n} \exp \left\{ -\frac{1}{2(1-rho_0^2)} \frac{S_{11}}{\sigma_1^2} - 2\rho_0 \frac{S_{12}}{\sigma_1\sigma_2} + \frac{S_{22}^2}{\sigma_2^2} \right\}$$

$$\exp \left\{ -\frac{n}{2(1-\rho_0^2)} \left[\frac{(\bar{X} - \mu_1)^2}{\sigma_1^2} - 2\rho_0 \frac{(\bar{X} - \mu_1)(\bar{Y} - \mu_2)}{\sigma_1\sigma_2} + \frac{(\bar{Y} - \mu_2)^2}{\sigma_2^2} \right] \right\}$$

matome, kad paskutinis daugiklis įgyja maksimalią reikšmę 1, kai $\tilde{\mu}_1 = \bar{\mu}_1 = \bar{X}$, $\tilde{\mu}_2 = \bar{\mu}_2 = \bar{Y}$. Lieka rasti daugiklio, priklausančio nuo σ_1 ir σ_2 , maksimumą. Logaritmuodami gauname

$$h(\sigma_1, \sigma_2) = -n \ln \sigma_1 - n \ln \sigma_2 - \frac{1}{2(1 - \rho_0^2)} \left[\frac{S_{11}}{\sigma_1^2} - 2\rho_0 \frac{S_{12}}{\sigma_1 \sigma_2} + \frac{S_{22}}{\sigma_2^2} \right].$$

Prilyginę funkcijos h išvestines pagal σ_1 ir σ_2 nuliui, gauname lygčių sistemą

$$\frac{S_{11}}{\sigma_1^2} - \rho_0 \frac{S_{12}}{\sigma_1 \sigma_2} = n(1 - \rho_0^2),$$

$$\frac{S_{22}}{\sigma_2^2} - \rho_0 \frac{S_{12}}{\sigma_1 \sigma_2} = n(1 - \rho_0^2).$$

Atėmę iš pirmosios lygties antrają gauname, kad $S_{11}/\sigma_1^2 = S_{22}/\sigma_2^2$. Irašę į pirmąją lygtį randame

$$\frac{S_{11}}{\sigma_1^2} - \rho_0 r \frac{S_{11}}{\sigma_1^2} \Rightarrow \tilde{\sigma}_1^2 = \frac{S_{11}(1 - \rho_0 r)}{n(1 - \rho_0^2)} = \hat{\sigma}_1^2 \frac{1 - \rho_0 r}{1 - \rho_0^2}.$$

Analogiškai iš antrosios lygties gauname

$$\frac{S_{22}}{\sigma_2^2} - \rho_0 r \frac{S_{22}}{\sigma_2^2} \Rightarrow \tilde{\sigma}_2^2 = \frac{S_{22}(1 - \rho_0 r)}{n(1 - \rho_0^2)} = \hat{\sigma}_2^2 \frac{1 - \rho_0 r}{1 - \rho_0^2}.$$

Naudodamini šiuos įvertinius gaume tikėtinumo funkcijos sąlyginį maksimumą

$$L(\tilde{\mu}, \tilde{\Sigma}) = \frac{\sqrt{2\pi}^{-n} n^n e^{-n} (1 - rho_0^2)^{n/2}}{(S_{11} S_{22})^{n/2} (1 - rho_0 r)^n}.$$

Tada

$$\Lambda^{2/n} = \frac{(1 - \rho_0^2)(1 - r^2)}{(1 - \rho_0 r)^2}.$$

Tikėtinumų santykio kriterijus atmeta hipotezę, kai Λ įgyja mažas reikšmes (žr. [2], 4.6.1 skyrelj). Spręsdami nelygybę

$$(1 - \rho_0^2)(1 - r^2) < c(1 - \rho_0 r)^2$$

r atžvilgiu gausime, kad hipotezė atmetama, kai

$$r < d_1(c) = \frac{c\rho_0 - (1 - \rho_0^2)\sqrt{1 - c}}{1 - \rho_0^2(1 - c)} \text{ arba } r > d_2(c) = \frac{c\rho_0 + (1 - \rho_0^2)\sqrt{1 - c}}{1 - \rho_0^2(1 - c)}.$$

Parametras c reikia parinkti taip, kad

$$F(d_1(c)|\rho_0) + 1 - F(d_2(c)|\rho_0) = \alpha;$$

čia $F(x|\rho)$ yra statistikos r pasiskirstymo funkcija.

b) Hipotezę atmetame, kai $r < c_1$ arba $r > c_2$. Konstantos c_1 ir c_2 randamos iš sąlygų

$$F(c_1|\rho_0) = \alpha/2, \quad 1 - F(c_2|\rho_0) = \alpha/2,$$

arba P reikšmių terminais hipotezė atmetama, kai

$$pv = 2 \max(F(r|\rho_0), 1 - F(r|\rho_0)) < \alpha,$$

čia r yra empirinio koreliacijos koeficiente realizacija.

c) Vienpusių alternatyvų $\bar{H}_1 : \rho > \rho_0$, $\bar{H}_2 : \rho < \rho_0$ atvejais natūralu naudoti vienpusius kriterijus. Hipotezė atmetama, kai atitinkamai

$$pv = 1 - F(r|\rho_0) < \alpha, \quad pv = F(r|\rho_0) < \alpha, \quad pv = 2 \min(F(r|\rho_0), 1 - F(r|\rho_0)) < \alpha.$$

Šiose nelygybėse r yra empirinio koreliacijos koeficiente realizacija.

Irodyta (žr. [12]), kad pateiktieji kriterijai yra TG tarp kriterijų, kurių statistikos invariantiškos poslinkio ir mastelio transformacijų atžvilgiu.

I.3.66. Praktiškai dažniau naudojami apytikslieji kriterijai, kurie grindžiami statistikos r Fišerio transformacija

$$Z = Z(r) = \frac{1}{2} \ln \frac{1+r}{1-r}$$

ir a. d. Z asimptotiniu ($n \rightarrow \infty$) normalumu

$$V_n(\rho_0) = \sqrt{n-3} \left(\frac{1}{2} \ln \frac{1+r}{1-r} - \frac{1}{2} \ln \frac{1+\rho_0}{1-\rho_0} \right) \xrightarrow{d} Y \sim N(0, 1),$$

kai tikroji parametru reikšmė yra ρ_0 . Apytikslieji kriterijai gaunami lyginant $V_n(\rho_0)$ su standartinio normaliojo skirstinio kritinėmis reikšmėmis. Gauname tokias apytikslį kriterijų kritines sritis

$$V_n(\rho_0) > z_\alpha, \quad V_n(\rho_0) < -z_\alpha, \quad |V_n(\rho_0)| > z_{\alpha/2}.$$

Pažymėkime v statistikos $V_n(\rho_0)$ realizaciją. Tada kriterijus galima suformuluoti asimptotinių P reikšmių pv_a terminais: hipotezė atmetama, kai atitinkamai teisingos nelygybės

$$pv_a = 1 - \Phi(v) \leq \alpha, \quad pv_a = \Phi(v) \leq \alpha,$$

$$pv_a = 2 \min(1 - \Phi(v), \Phi(v)) = 2(1 - \Phi(|v|)) \leq \alpha.$$

I.3.67. Pažymėkime $Z_i = X_i - Y_i$, $i = 1, 2, \dots, n$. Tada $\mathbf{Z} = (Z_1, \dots, Z_n)^T$ yra paprastoji imtis a. d. $Z \sim N(\mu, \sigma^2)$, $\mu = \mu_1 - \mu_2$, $\sigma^2 = VZ = \sigma_1^2 - 2\rho\sigma_1\sigma_2 + \sigma_2^2$. Vietoje hipotezės H galime tikrinti analogišką hipotezę dėl normaliojo skirstinio vidurkio μ reikšmės naudodamiesi imtimi $(Z_1, \dots, Z_n)^T$, kai dispersija σ^2 yra nežinoma (žr. I.3.51, I.3.52 pratimus).

I.3.68. Jungtinės imties tankis (skaičiuojančiojo mato atžvilgiu) priklauso dviparametrei eksponentinio tipo skirstinių šeimai. Jি galime pertvarkyti taip:

$$f(\mathbf{X}, \mathbf{Y} | \lambda_1, \lambda_2) = \exp\{\theta U + \vartheta T - B(\theta, \vartheta)\} h(\mathbf{X}, \mathbf{Y}),$$

$$\theta = \ln \frac{\lambda_2}{\lambda_1}, \quad \vartheta = \ln \lambda_1, \quad U = \sum_i X_i, \quad T = \sum_i X_i + \sum_i Y_i,$$

$$B(\theta, \vartheta) = m\lambda_1 + n\lambda_2.$$

Remiantis [2], 4.4.2 teorema, egzistuoja TGN kriterijai hipotezėms dėl θ (kartu ir dėl santykio λ_1/λ_2) reikšmių tikrinti. Jie sudaromi kaip sąlyginiai paviršiuose $T = t$. Kadangi sąlyginis U skirstinys, kai $T = t$, $\lambda_1/\lambda_2 = c_0$, yra binominis $B(t, mc_0/(mc_0 + n))$, tai kriterijus hipotezei $H : \lambda_1/\lambda_2 = c_0$ tikrinti sudarome kaip ir kriterijus dėl binomino skirstinio tikimybės p reikšmių (žr. I.3.35 pratimą), kur tikimybės p hipotetine reikšme reikia laikyti $p_0 = mc_0/(mc_0 + n)$. Tikrinant hipotezę reikia tarti, kad Bernulio eksperimentų skaičius t , o teigiamų įvykių skaičius yra U .

I.3.69. Turime dvi n. a. d. X ir Y , pasiskirsčiusių pagal Puasono dėsnį su parametrais λ_1 ir λ_2 , imtis, kurių didumai $m = 2$ ir $n = 1$. Reikia patikrinti hipotezę $H_3 : \lambda_1/\lambda_2 = 1/5$, kai alternatyva $\bar{H}_3 : \lambda_1/\lambda_2 \neq 1/5$. Vietoje šios hipotezės tikriname hipotezę $H'_3 : p = p_0 = 2/7$, kai alternatyva yra $\bar{H}'_3 : p \neq 2/7$, o bandymų skaičius yra a. d. $T = X_1 + X_2 + Y$, jo realizacija $t = 73$; teigiamo įvykio įvykimų skaičiaus $U = X_1 + X_2$ realizacija $u = 28$. Randame tikimybės pasiklivimo intervalą, kurio pasiklivimo lygmuo $Q = 0,95$. Gauname $(\underline{p}, \bar{p}) = (0,272, 0,505)$. Kadangi $p_0 = 0,286$ patenka į šį intervalą, tai darome išvadą, kad turimi stebėjimai suformuluotai hipotezei nepriestarauja. Naudodam kriterijų P reikšmių terminais, randame $pv = 2 \min(I_{5/7}(45, 29), I_{2/7}(28, 46)) = 2 \min(0,9736, 0,0454) = 0,0908 > 0,05$. Hipotezė neatmetama.

I.3.70. a) A. d. X_1 sąlyginis skirstinys $(X_1|X_1 + X_2 = N) \sim B(N, p)$, $p = \lambda_1/(\lambda_1 + \lambda_2)$. Hipotezė H_0 atmetame, kai $X_1 < k$, ir atmetame su tikimybe γ , kai $X_1 = k$; čia k yra mažiausias sveikasis skaičius, kuriam galioja nelygybė $\sum_{m=0}^{k-1} C_N^m / 2^N = p \leq \alpha$; $\gamma = (\alpha - p)/(C_N^k / 2^N)$; $N = X_1 + X_2$.

b) $\beta = \sum_{m=0}^{k-1} C_N^m 2^{N-m} / 3^N + \gamma C_N^k 2^{N-k} / 3^N$ pirmaisiais trimis atvejais ir

$$\beta = \sum_{m=0}^{k-1} C_N^m 4^{N-m} / 5^N + \gamma C_N^k 4^{N-k} / 5^N$$

paskutiniu atveju.

I.3.71. Jungtinės imties tankis (skaičiuojančiojo mato atžvilgiu) priklauso dviparametrei eksponentinio tipo skirstinių šeimai. Jি galime pertvarkyti taip:

$$f(\mathbf{X}, \mathbf{Y}, |p_1, p_2) = \exp\{\theta U + \vartheta T - B(\theta, \vartheta)\},$$

$$\theta = \ln \left(\frac{p_1(1-p_2)}{(1-p_1)p_2} \right), \quad \vartheta = \ln \frac{p_2}{1-p_2}, \quad U = \sum_i X_i, \quad T = \sum_i X_i + \sum_i Y_i.$$

Remiantis [2], 4.4.1 teorema, egzistuoja TGN kriterijai hipotezėms dėl θ reikšmių tikrinti. Jie sudaromi kaip sąlyginiai paviršiuose $T = t$. Hipotezė $H : \theta = 0$ yra ekvivalenti hipotezei $H' : p_1 = p_2$. Nesunkiai patikriname, kad kai tikimybės vienodos $p_1 = p_2$, a. d. U sąlyginis skirstinys, kai $T = t$, yra hipergeometrinis $H(n+m, n, t)$.

Vadinasi, hipotezė H , kai alternatyva yra $\bar{H}_1 : p_1 > p_2$, taikant nerandomizuotą kriterijų, yra atmetama, kai $U \geq k'$; čia k' yra mažiausias sveikasis skaičius, tenkinantis nelygybę

$$1 - H(k' - 1 | n+m, n, t) = \sum_{i=k'}^{\min(n,t)} \frac{C_n^i C_m^{t-i}}{C_{n+m}^t} \leq \alpha.$$

Norint įsitikinti, kad U pateko į kritinę sritį, galima apskaičiuoti P reikšmę, t. y. hipotezė atmeti, kai $1 - H(u - 1|n + m, n, t) \leq \alpha$; čia u yra statistikos U realizacija.

Analogiškai, kai alternatyva yra $\bar{H}_2 : p_1 < p_2$, kritinė sritis gali būti užrašyta taip: $p_v = H(u|n + m, n, t) \leq \alpha$.

Kai alternatyva $\bar{H}_3 : p_1 \neq p_2$ yra dvipusė, H atmetama, kai teisinga kuri nors iš pateiktų nelygybių, kuriose α reikia pakeisti į $\alpha/2$.

I.3.72. Tarkime, p_1 ir p_2 yra tikimybės, kad susirgs pirmosios ir antrosios grupių darbininkai. Reikia patikrinti hipotezę $H_1 : p_1 = p_2$, kai alternatyva yra $\bar{H}_1 : p_1 < p_2$. Parinkime reikšmingumo lygmenį $\alpha = 0,05$. Tada $n + m = 25$, $t = 6 + 4 = 10$, $u = 6$, $n = 20$. Naudojantis **I.3.71** pratimo kriterijumi, hipotezę reikia atmeti, jeigu suma

$$p_v = H(u|n + m, n, t) = \sum_{i=\max(0,t-m)}^u \frac{C_n^i C_m^{t-i}}{C_{n+m}^t} \leq 0,05.$$

Tada (kadangi $t - m = 5$, tai suma turi tik du dėmenis)

$$p_v = H(6|25, 10, 20) = \frac{C_{20}^5 C_5^5}{C_{25}^{10}} + \frac{C_{20}^6 C_5^4}{C_{25}^{10}} = 0,064.$$

Taigi iškeltosios hipotezės neatmetame.

I.3.73. Pažymėkime $S_i = \sum_{j=1}^{n_i} X_{ij}$, $i = 1, 2$. Tikėtinumo funkcija

$$L = h(\mathbf{X}_1, \mathbf{X}_2) \exp\{-\theta S_1 - \vartheta(S_1 + S_2) - B(\theta, \vartheta)\}, \quad \theta = \theta_1 - \theta_2, \vartheta = \theta_2.$$

Kadangi esant teisingai hipotezei $H : \theta_1 = \theta_2$ (arba $\theta = 0$) statistika $S_1/(S_1 + S_2) \sim Be(n_1\gamma_1, n_2\gamma_2)$, tai remdamiesi [2], 4.4.3 teorema TGN kriterijus galime suformuluoti naudodami beta skirstinį.

I.3.74. a) Atlikime transformaciją $U_i = \Delta_0 X_i + Y_i$, $Z_i = X_i - Y_i/\Delta_0$, $i = 1, \dots, n$. Tada hipotezė $H_0 : \sigma_2/\sigma_1 = \Delta_0$ yra ekvivalenti hipotezei, kad koreliacijos koeficientas $\rho = \rho(U_i, Z_i) = 0$. Statistika R yra empirinio koreliacijos koeficiente, apskaičiuoto pagal imtį $(U_i, Z_i)^T$, $i = 1, \dots, n$, modulis; b) $(n - 2)R^2/(1 - R^2) \sim F(1, n - 2)$; c) Atlikime transformaciją $U_i = X_i + Y_i$, $Z_i = X_i - Y_i$, $i = 1, \dots, n$. Tada statistika $V = |\bar{Z}|/\sqrt{\sum_i (Z_i - \bar{Z})^2}$; d) $(n - 1)V^2 \sim F(1, n - 1)$.

I.3.75. a) Remiantis **I.2.13** pratimu $V/\theta \sim \chi^2(2n - 2)$. Hipotezė atmetama, kai $V < c_1$ arba $V > c_2$. Lygtys konstantoms c_1, c_2 apskaičiuoti randamos analogiškai **I.3.30** pratimui. Imant simetriškus kriterijus hipotezė atmetama, kai $V < \chi_{1-\alpha/2}^2$ arba $V > \chi_{\alpha/2}^2$.

b) Remiantis **I.2.13** ir **I.2.14** pratimais $X_{(1)}$ ir V nepriklausomi; $X_{(1)} \sim \mathcal{E}(a, \theta/n)$. Jei teisinga hipotezė $H : a = 0$, tai $X_{(1)} \sim \mathcal{E}(\theta/n)$ ir $n(n - 2)X_{(1)}/V \sim F(2, 2n - 2)$. Hipotezė atmetama simetrišku reikšmingumo lygmens α kriterijumi, kai

$$\frac{n(n - 2)X_{(1)}}{V} < F_{1-\alpha/2}(2, 2n - 2), \quad \text{arba} \quad \frac{n(n - 2)X_{(1)}}{V} > F_{\alpha/2}(2, 2n - 2).$$

I.3.5 skyrelis

I.3.76. Pažymėkime $n = n_1 + \dots + n_k$,

$$X_{i(1)} = \min(X_{i1}, \dots, X_{in_i}), \quad X_{(1)} = \min(X_{1(1)}, \dots, X_{k(1)}).$$

Tada

a) tikėtinumų santykis $\Lambda = \prod_{i=1}^k (\hat{\sigma}_i / \tilde{\sigma}_i)^{n_i}$,

$$\hat{\sigma}_i = \sum_{j=1}^{n_i} (X_{ij} - X_{i(1)})/n_i, \quad \tilde{\sigma}_i = \sum_{j=1}^{n_i} (X_{ij} - X_{(1)})/n_i;$$

b) $\Lambda = \prod_{i=1}^k (\hat{\sigma}_i / \hat{\sigma})^{n_i}$, $\hat{\sigma} = \sum_{i=1}^k n_i \hat{\sigma}_i / n$; c) $\Lambda = (\hat{\sigma} / \tilde{\sigma})^n$, $\tilde{\sigma} = \sum_{i=1}^k n_i \tilde{\sigma}_i / n$.

I.3.77. a) Tikėtinumų santykis

$$\Lambda = \frac{\max_{\mu=\mu_0, \sigma^2} L(\mu, \sigma^2)}{\max_{\mu, \sigma^2} L(\mu, \sigma^2)} = \frac{L(\mu_0, \tilde{\sigma}^2)}{L(\hat{\mu}, \hat{\sigma}^2)} = \left(\frac{\hat{\sigma}^2}{\tilde{\sigma}^2} \right)^{n/2};$$

čia $\hat{\sigma}^2 = m_2 = (n-1)s^2/n = \sum_i (X_i - \bar{X})^2/n$ yra dispersijos σ^2 DT įvertinys, o $\tilde{\sigma}^2 = \sum_i (X_i - \mu_0)^2/n$ yra dispersijos σ^2 DT įvertinys, kai $\mu = \mu_0$. Gauname

$$\Lambda^{2/n} = \frac{1}{1 + n(\bar{X} - \mu_0)^2 / ((n-1)s^2)} = \frac{1}{1 + t^2(\mathbf{X})/(n-1)}.$$

Taigi

$$\{\mathbf{X} : \Lambda < c\} \Leftrightarrow \{\mathbf{X} : |t(\mathbf{X})| > t_{\alpha/2}(n-1)\}.$$

b) Tikėtinumų santykis

$$\Lambda = \frac{\max_{\mu, \sigma^2 = \sigma_0^2} L(\mu, \sigma^2)}{\max_{\mu, \sigma^2} L(\mu, \sigma^2)} = (m_2 / \sigma_0^2)^{n/2} e^{-nm_2/(2\sigma_0^2) + n/2}.$$

Funkcija $h(x) = x^{n/2} e^{-nx/2}$ didėjanti intervalo $(0, 1)$ ir mažėjanti intervalo $1, \infty$. Gauname

$$\Lambda < c \Leftrightarrow \frac{nm_2}{\sigma_0^2} < c_1 \text{ arba } \frac{nm_2}{\sigma_0^2} > c_2.$$

I.3.78. Tikėtinumų santykis

$$\Lambda = \frac{\max_{\pi_i = \pi_i^0} L(\pi_1, \dots, \pi_k)}{\max_{\pi_i} L(\pi_1, \dots, \pi_k)} = \frac{L(\pi_1^0, \dots, \pi_k^0)}{L(\hat{\pi}_1, \dots, \hat{\pi}_k)} = \frac{\prod_{i=1}^k (\pi_i^0)^{V_i}}{\prod_{i=1}^k (V_i/n)^{V_i}};$$

čia $\hat{\pi}_i = V_i/n$ yra parametru π_i DT įvertinys (žr. I.2.131 pratima). Gauname

$$\Lambda = \left(\prod_{i=1}^k (\pi_i^0 / \hat{\pi}_i)^{\hat{\pi}_i} \right)^n.$$

I.3.79. Remiantis [2], 3.5.4 skyreliu $-2 \ln \Lambda \xrightarrow{d} \chi_{k-1}^2$. Skleidžiant $-2 \ln \Lambda$ eilutę (žr. [4], 2.2.1 teorema) gaunama, kad $-2 \ln \Lambda = \sum_i (V_i - n\pi_i^0)^2 / (n\pi_i^0) + o_P(1)$.

I.3.80. a) Tikétinumų santykis

$$\Lambda = \frac{\max_{\mu_1=\mu_2, \sigma^2} L(\mu_1, \mu_2, \sigma^2)}{\max_{\mu_1, \mu_2, \sigma^2} L(\mu_1, \mu_2, \sigma^2)} = \frac{L(\tilde{\mu}_1, \tilde{\mu}_2, \tilde{\sigma}^2)}{L(\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}^2)} = \left(\frac{\hat{\sigma}^2}{\tilde{\sigma}^2} \right)^n,$$

čia $\hat{\mu}_1 = \bar{X}$, $\hat{\mu}_2 = \bar{Y}$, $\hat{\sigma}^2 = [\sum_i (X_i - \bar{X})^2 + \sum_i (Y_i - \bar{Y})^2]/(2n)$ yra parametru μ_1, μ_2, σ^2 DT įvertiniai, o $\tilde{\mu}_1 = \tilde{\mu}_2 = (\bar{X} + \bar{Y})/2$,

$$\tilde{\sigma}^2 = [\sum_i (X_i - \tilde{\mu}_1)^2 + \sum_i (Y_i - \tilde{\mu}_2)^2]/(2n) = (n-1)(s_1^2 + s_2^2)/(2n) + n(\bar{X} - \bar{Y})^2/4$$

yra parametru μ_1, μ_2, σ^2 DT įvertiniai, kai $\mu_1 = \mu_2$.

Vienodo didumo imčių atveju Stjudento statistika

$$T = T(\mathbf{X}, \mathbf{Y}) = \sqrt{n}(\bar{X} - \bar{Y})/\sqrt{s_1^2 + s_2^2} \sim S(2n-2),$$

kai hipotezė teisinga. Gauname

$$\Lambda^{1/n} = \frac{1}{1 + nT^2(\mathbf{X}, \mathbf{Y})/(2(n-1))}.$$

Tikétinumų santykis Λ yra monotoniskai mažėjantis T^2 atžvilgiu. Taigi

$$\Lambda < c \Leftrightarrow |T(\mathbf{X}, \mathbf{Y})| > t_{\alpha/2}(2(n-1)).$$

b) Tikétinumų santykis

$$\Lambda = \frac{\max_{\mu_1, \mu_2, \sigma_1^2=\sigma_2^2} L(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)}{\max_{\mu_1, \mu_2, \sigma_1^2, \sigma_2^2} L(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)} = \frac{(\hat{\sigma}_1^2)^{n/2} (\hat{\sigma}_2^2)^{n/2}}{((\hat{\sigma}_1^2 + \hat{\sigma}_2^2)/2)^n};$$

čia $\hat{\sigma}_1^2 = \sum_i (X_i - \bar{X})^2/n = (n-1)s_1^2/n$, $\hat{\sigma}_2^2 = \sum_i (Y_i - \bar{Y})^2/n = (n-1)s_2^2/n$ yra parametru σ_1^2 ir σ_2^2 DT įvertiniai. Fišerio statistika $F = s_1^2/s_2^2 \sim F(n-1, n-1)$, kai hipotezė teisinga. Gauname

$$\Lambda^{1/n} = \frac{2s_1 s_2}{s_1^2 + s_2^2} = 2 \frac{\sqrt{F}}{1+F}.$$

Nelygybė $\Lambda < c$ ekvivalenti nelygybei $2\sqrt{F}/(1+F) > d$, $d > 0$. Funkcija $h(x) = 2x/(1+x^2)$, kai $x > 0$, didėja nuo 0 iki 1, kai x kinta nuo 0 iki 1, ir mažėja nuo 1 iki 0, kai x kinta nuo 1 iki ∞ . Taigi

$$\Lambda < c \Leftrightarrow F < c_1 \text{ arba } F > c_2.$$

I.3.81. Tikétinumų santykis $\Lambda = [1/(1+kF/(n-k))]^{n/2}$.**I.3.82.** Tikétinumų santykis

$$\Lambda = \hat{p}^{S_1} (1-\hat{p})^{n_1-S_1} \hat{p}^{S_2} (1-\hat{p})^{n_2-S_2} / [\hat{p}_1^{S_1} (1-\hat{p}_1)^{n_1-S_1} \hat{p}_2^{S_2} (1-\hat{p}_2)^{n_2-S_2}];$$

$S_1 = X_1 + \dots + X_{n_1}$, $S_2 = Y_1 + \dots + Y_{n_2}$, $\hat{p}_1 = S_1/n_1$, $\hat{p}_2 = S_2/n_2$, $\hat{p} = (S_1 + S_2)/(n_1 + n_2)$. Remiantis I.3.79 pratimu $-2 \ln \Lambda \xrightarrow{d} \chi^2_1$.

I.3.83. $\Lambda = \hat{p}^S (1 - \hat{p})^{n-S} / (\prod_{i=1}^k \hat{p}_i^{S_i} (1 - \hat{p}_i)^{n_i - S_i})$, $S = S_1 + \dots + S_k$, $n = n_1 + \dots + n_k$, $\hat{p} = S/n$, $\hat{p}_i = S_i/n_i$, $i = 1, 2, \dots, k$; $-2 \ln \Lambda \xrightarrow{d} \chi^2_{k-1}$, kai $n_i \rightarrow \infty$, $i = 1, 2, \dots, k$, ir hipotezė $H : p_1 = p_2 = \dots = p_k$ yra teisinga.

I.3.84. Tikėtinumų santykis $\Lambda = (\hat{\lambda}^{S_1+S_2} / (\hat{\lambda}_1^{S_1} \hat{\lambda}_2^{S_2})) \exp\{n_1 \hat{\lambda}_1 + n_2 \hat{\lambda}_2 - (n_1 + n_2) \hat{\lambda}\}$; $S_1 = X_1 + \dots + X_{n_1}$, $S_2 = Y_1 + \dots + Y_{n_2}$, $\hat{\lambda}_1 = S_1/n_1$, $\hat{\lambda}_2 = S_2/n_2$, $\hat{\lambda} = (S_1 + S_2)/(n_1 + n_2)$. Remiantis I.3.79 pratimu $2 \ln \Lambda \xrightarrow{d} \chi^2_1$.

I.3.85. $\Lambda = \hat{\lambda}^S / (\prod_{i=1}^k \hat{\lambda}_i^{S_i})$, $S = S_1 + \dots + S_k$, $n = n_1 + \dots + n_k$, $\hat{\lambda} = S/n$, $\hat{\lambda}_i = S_i/n_i$, $i = 1, 2, \dots, k$; $-2 \ln \Lambda \xrightarrow{d} \chi^2_{k-1}$, kai $n_i \rightarrow \infty$, $i = 1, 2, \dots, k$, ir hipotezė $H : \lambda_1 = \lambda_2 = \dots = \lambda_k$ yra teisinga.

I.3.86. A. d. $\bar{X}/\bar{Y} \sim (\theta_1/\theta_2) F_{2n_1, 2n_2}$; čia $F_{m,n}$ – a. d., turintis Fišerio skirstinį su m ir n laisvės laipsnių. Tikėtinumų santykis

$$\Lambda = \frac{\max_{\theta_1=\theta_2} L(\theta_1, \theta_2)}{\max_{\theta_1, \theta_2} L(\theta_1, \theta_2)} = \frac{L(\tilde{\theta}, \tilde{\theta})}{L(\theta_1, \hat{\theta}_2)},$$

čia $\hat{\theta}_1 = \bar{X}$, $\hat{\theta}_2 = \bar{Y}$ yra parametru θ_1, θ_2 DT įvertiniai, $\tilde{\theta} = (n_1 \bar{X} + n_2 \bar{Y})/(n_1 + n_2)$ yra parametru θ įvertinys, kai $\theta_1 = \theta_2 = \theta$. Gauname

$$\Lambda = \frac{(n_1 + n_2)^{n_1+n_2}}{n_1^{n_1} n_2^{n_2}} \frac{(n_1 \bar{X})^{n_1} (n_2 \bar{Y})^{n_2}}{(n_1 \bar{X} + n_2 \bar{Y})^{n_1+n_2}} = \left(\frac{n_1 + n_2}{n_2} \right)^{n_1+n_2} \frac{F^{n_1}}{1 + n_1 F/n_2}^{n_1+n_2}$$

$$\Lambda < c \Leftrightarrow F < c_1 \text{ arba } F > c_2.$$

Tegu alternatyva yra $\bar{H} : \theta_1 > \theta_2$. Tada hipotezė H atmetama, kai

$$\bar{X}/\bar{Y} > F_\alpha(2n_1, 2n_2),$$

o kriterijaus galia $\beta(\theta_2) = \mathbf{P}\{F_{2n_1, 2n_2} > (\theta_2/\theta_1) F_\alpha(2n_1, 2n_2)\}$, $\theta_2 < \theta_1$.

I.3.87. Nurodymas. Pasinaudokime tuo, kad a. d. $V = \sum_i (m_i - np_i^0)^2 / (np_i^0)$ apytiksliai turi χ^2 skirstinį su 3 laisvės laipsniais; čia p_i^0 – tikimybė, kad a. d. $X \sim N(0, 1/4)$ igijo reikšmę iš i -ojo intervalo: $p_1^0 = 0, 00135$; $p_2^0 = 0, 1573$; $p_3^0 = 0, 6827$; $p_4^0 = 0, 15865$. Atsitiktinis dydis V igijo reikšmę 2,6578. Asimptotinė P -reikšmė $pv_a = \mathbf{P}\{\chi^2_3 > 2,6578\} = 0, 4474$. Atmeti hipotezę néra pagrindo.

I.3.88. Analogiškai kaip ir I.3.87 pratime gauname, kad a. d. V , kuris apytiksliai turi χ^2 skirstinį su 3 laisvės laipsniais, igijo reikšmę 19,453. Asimptotinė P -reikšmė $pv_a = \mathbf{P}\{\chi^2_3 > 19,453\} = 0, 00022$. Hipotezę atmetame.

I.3.89. Atsitiktinis dydis V , kuris apytiksliai turi χ^2 skirstinį su 2 laisvės laipsniais, igijo reikšmę 5,3446. Asimptotinė P -reikšmė $pv_a = \mathbf{P}\{\chi^2_2 > 5,3446\} = 0, 0691$. Hipotezę atmetame, jei kriterijaus reikšmingumo lygmuo viršija 0,0691. Tirkindami hipotezę $H : X \sim B(2, p)$, apskaičiuojame statistikos $\hat{V} = (m_0 - n\hat{p}^2)^2 / (n\hat{p}^2) + (m_1 - n2\hat{p}\hat{q})^2 / (n2\hat{p}\hat{q}) + (m_2 - n\hat{q}^2)^2 / (n\hat{q}^2)$, kuri apytiksliai turi χ^2 skirstinį su 1 laisvės laipsniu, reikšmę; čia \hat{p} yra tikimybės p DT įvertinys. Gauname $\hat{p} = (1017 + 1054)/4040 = 0, 5126$; $\hat{V} =$

0,2317. Asimptotinė P -reikšmė $pv_a = \mathbf{P}\{\chi_1^2 > 0,2317\} = 0,6303$. Atmesti hipotezę nėra pagrindo.

I.3.90. Parametro p DT įvertis $\hat{p} = 0,2675$. Analogiskai kaip **I.3.89** pratime statistikos \hat{V} , kuri esant teisingai hipotezei apytiksliai turi χ^2 skirstinį su 1 laisvės laipsniu, reikšmė yra $\hat{V} = 0,757$. Asimptotinė P -reikšmė $pv_a = \mathbf{P}\{\chi_1^2 > 0,757\} = 0,3843$. Todėl atmesti hipotezę nėra pagrindo.

I.3.91. Parametro p DT įvertis $\hat{p} = 0,1232$. Analogiskai kaip **I.3.89** pratime statistikos \hat{V} , kuri esant teisingai hipotezei apytiksliai turi χ^2 skirstinį su 1 laisvės laipsniu, reikšmė lygi 0,444. Todėl atmesti hipotezę nėra pagrindo.

I.3.6 skyrelis

I.3.92. $n \geq 74$.

I.3.93. $\leq 0,6737$; $n \geq 133$.

I.3.94. Taikant TGN kriterijų $n \geq 45$, taikant simetrinį kriterijų $n \geq 47$.

I.3.95. Pereiname prie logaritmų. Kadangi atmesti dispersijų lygybės hipotezę nėra pagrindo, tai taikome kriterijų esant vienodomis dispersijoms. Statistikos T realizacija $t = 4,2745$; P reikšmė $pv = 9,45 \times 10^{-5}$. Hipotezė atmetama.

I.3.96. Pagal turimus duomenis randame vidurinio laikotarpio vidurkio ir kvadratinio nuokrypio įverčius $\bar{X}_0 = 16,563$, $s_0 = 1,5362$ ir taikome Stjudento dviejų imčių kriterijų. Lygindami pirmą ir vidurinį laikotarpius, gauname statistikos T realizaciją 0,8761, o lyginant vidurinį ir paskutinį laikotarpius statistikos T realizacija yra -1,5652; atitinkamos P reikšmės esant dvipusei alternatyvai yra 0,3841 ir 0,1222. Atmesti hipotezę nėra pagrindo.

I.3.97. Neatmetama.

I.3.98. $n \geq 211$; $n \geq 74$; $n \geq 31$.

I.3.99. Dispersijų lygybės hipotezė neatmetama, nes a. d., turintis Fišerio skirstinį $F(7,9)$, įgijo reikšmę 1,9584; sisteminių paklaidų vienodumo hipotezė neatmetama, nes a. d., turintis Stjudento skirstinį $S(16)$, įgijo reikšmę 0,4099.

I.3.100. Tikriname hipotezę $H : \sigma_1^2 = \sigma_2^2$, kai alternatyva yra $\bar{H} : \sigma_1^2 < \sigma_2^2$. Statistika $F = s_1^2/s_2^2$, kuri esant teisingai hipotezei turi Fišerio skirstinį su $\nu_1 = 10$ ir $\nu_2 = 10$ laisvės laipsniu, įgijo reikšmę 0,1783. P reikšmė $pv = \mathbf{P}\{F_{10;10} < 0,1783\} = 0,0059$. Hipotezė atmetame, kai $\alpha \geq 0,0059$.

I.3.101. a) Tikėtinumų santykio statistika \tilde{R}_{TS} įgijo reikšmę 1,8931; asimptotinė P -reikšmė $pv_a = \mathbf{P}\{\chi_2^2 > 1,8931\} = 0,3881$; atmesti hipotezę nėra pagrindo. b) Hipotezė neatmetama.

I.3.102. Tikėtinumų santykio statistika įgijo reikšmę 0,3086; atmesti hipotezę nėra pagrindo.

I.3.103. a) Statistika Z įgijo reikšmę 1,882. Tegu $F(x|\nu)$ yra Stjudento skirstinio su ν laisvės laipsnių pasiskirstymo funkcija. Tada P -reikšmė $pv = 2[1 - F(1,882|18)] = 0,0761$. Reikšmingumo lygmens $\alpha = 0,05$ kriterijumi hipotezė neatmetama. b) Statis-

tika T įgijo reikšmę 3,2143. P reikšmė $pv = 2[1 - F(3, 2143|8)] = 0,0106$; hipotezę atmetame, kai kriterijaus reikšmingumo lygmuo α viršija 0,0106. c) Pagal prasmę a. d. X ir Y yra teigiamai priklausomi (jei gretimų sklypelių žemė derlingesnė, tai abu a. d. X ir Y turės tendenciją įgyti didesnes reikšmes ir atvirkščiai). Todėl lentelės duomenis reikia traktuoti kaip 10 dvimačio a. v. $(X, Y)^T$ realizacijų.

I.3.104. Koreliacijos koeficiente įvertis $\hat{\rho} = r = 0,7055$. Statistika U įgijo reikšmę 2,8157. Jeigu hipotezės $H : \rho = 0$ alternatyva yra $\bar{H} : \rho > 0$, tai P reikšmė $pv = 1 - F(2, 8157|8) = 0,0113$; nepriklausomumo hipotezė $H : \rho = 0$ atmetama, kai kriterijaus reikšmingumo lygmuo $\alpha \geq 0,0113$.

I.3.105. Statistika T įgijo reikšmę 1,7718. Jeigu alternatyva yra $\bar{H} : \theta > 0$, tai P reikšmė $pv = 1 - F(1, 7718|15) = 0,0484$. Hipotezė $H : \theta = 0$ atmetama, kai kriterijaus reikšmingumo lygmuo $\alpha \geq 0,0484$.

I.3.106. Tikriname hipotezę dėl a. d. X ir Y vidurkių lygybės. Statistika T įgijo reikšmę 4,1212. Jeigu alternatyva dvipusė, tai P reikšmė $pv = 2[1 - F(4, 1212|9)] = 0,0026$. Hipotezė $H : \theta = 0$ atmetama, kai kriterijaus reikšmingumo lygmuo $\alpha \geq 0,0026$.

I.3.107. Statistika $T = X_1 + \dots + X_n$ įgijo reikšmę $t = 185$. P reikšmė $pv = \mathbf{P}\{\chi^2_{400} < 2t\} = 0,1435$. Hipotezė atmeti nėra pagrindo.

I.3.108. Hipotezė neatmetama. Pasiklivimo intervalas uždengia hipotetinę reikšmę λ_0 .

I.3.109. Hipotezė neatmetama. Pasiklivimo intervalas uždengia hipotetinę reikšmę λ_0 .

I.3.110. a) Tikėtinumų santykio statistika R_{TS} įgijo reikšmę 19,3386; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi^2_6 > 19,3386\} = 0,0036$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0036. b) Tikėtinumų santykio statistika R_{TS} įgijo reikšmę 5,1783; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi^2_4 > 5,1783\} = 0,2695$. Hipotezė neatmetama.

I.3.111. Antros rūšies gaminių skaičius 277; nerandomizuoto kriterijaus P reikšmė $pv = \mathbf{P}\{S \geq 277\}$; čia $S \sim B(1000; 0,25)$; randame $pv = 0,0275$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0275.

I.3.112. Tikrinama hipotezė $H : \lambda_1 = \lambda_2$. Jei alternatyva yra $\bar{H} : \lambda_1 > \lambda_2$, tai P reikšmė $pv = \mathbf{P}\{S \geq 150\}$; čia $S \sim B(400; 1/3)$. Randame $pv = 0,0442$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0442.

I.3.113. P reikšmė $pv = \mathbf{P}\{S \leq 75\}$; čia $S \sim B(275; 1/3)$. Randame $pv = 0,0181$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0181.

I.3.114. Tikrinama hipotezė $H : \lambda_1 = \lambda_2$. Jei alternatyva yra $\bar{H} : \lambda_1 > \lambda_2$, tai P reikšmė $pv = \mathbf{P}\{S \geq 20026\}$; čia $S \sim B(39606; 1/2)$. Randame $pv = 0,0123$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0123.

I.3.115. Statistika $\sqrt{n}(\hat{p}_1 - \hat{p}_2)/\sqrt{\hat{p}_1\hat{q}_1 + \hat{p}_2\hat{q}_2}$, kuri esant teisingai hipotezei asimptotiškai turi standartinį normalujį skirstinį, įgijo reikšmę 4,0834; asimptotinė P reikšmė $pv_a = 2(1 - \Phi(4,0834)) = 4,44 \times 10^{-5}$. Hipotezė atmetama.

I.3.116. Tikėtinumų santykio statistika R_{TS} įgijo reikšmę 9,3113; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi^2_4 > 9,3113\} = 0,0538$. Hipotezė atmetama, jei kriterijaus reikšmin-

gumo lygmuo viršija 0,0538.

I.3.117. Statistika $2n\bar{R}^2$ (žr. [2], 4.7.12 skyrelj) įgijo reikšmę 43,888; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi_2^2 > 43,888\} = 2,9 \cdot 10^{-10}$; statistika $-2 \ln \Lambda$ įgijo reikšmę 55,099; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi_{11}^2 > 55,099\} = 7,4 \cdot 10^{-8}$. Hipotezė atmetama.

I.3.118. Statistika $2n\bar{R}^2$ įgijo reikšmę 10,2248; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi_2^2 > 10,2248\} = 0,006$; statistika $-2 \ln \Lambda$ įgijo reikšmę 20,0797; asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi_{11}^2 > 20,0797\} = 0,0443$. Reikšmingumo lygmens $\alpha = 0,05$ kriterijumi hipotezė atmetama.

I.3.119. Hipotezė atmetama, nes statistika $2n\bar{R}^2$ įgijo reikšmę 112,8, o statistika $-2 \ln \Lambda$ įgijo reikšmę 137,9.

II. Tiesiniai modeliai

II.1. Gauso ir Markovo tiesinis modelis

II.1.1. Mažiausiuju kvadratų metodas

II.1.1. Turime tiesinį Gauso ir Markovo modelį, t. y. imtis $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ turi tokią struktūrą

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e},$$

čia $\mathbf{A} = [a_{ij}]_{n \times m}$ eksperimentų plano matrica su žinomais elementais a_{ij} ; $\boldsymbol{\beta} = (\beta_1, \dots, \beta_m)^T$ nežinomų parametru vektorius; $\mathbf{e} = (e_1, \dots, e_n)^T$ paklaidų vektorius, $\mathbf{E}(\mathbf{e}) = \mathbf{0}$, $\mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I}$. Tegu matricos \mathbf{A} ranga lygus m . a) Raskite parametru $\boldsymbol{\beta}$ mažiausiuju kvadratų (MK) ivertinį $\hat{\boldsymbol{\beta}}$. b) Raskite ivertinio $\hat{\boldsymbol{\beta}}$ pirmuosius du momentus. c) Raskite k -mačio parametru $\boldsymbol{\theta} = \mathbf{H}\boldsymbol{\beta}$ ivertinio $\hat{\boldsymbol{\theta}} = \mathbf{H}\hat{\boldsymbol{\beta}}$ vidurkį ir kovariacijų matricą (čia \mathbf{H} yra dimensijos $k \times m$ rango $k \leq m$ matrica).

II.1.2. (II.1.1 pratimo tēsinys). a) Įrodykite, kad liekamoji kvadratų suma

$$SS_E = \min_{\boldsymbol{\beta}} SS(\boldsymbol{\beta}) = (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}})$$

gali būti surasta tokiu būdu

$$SS_E = \mathbf{Y}^T \mathbf{Y} - \hat{\boldsymbol{\beta}}^T \mathbf{A}^T \mathbf{Y}.$$

b) Raskite kvadratų sumos SS_E vidurkį ir parametru σ^2 nepaslinktajį ivertinį.

II.1.3. Norint ištirti kviečių derlingumo priklausomybę nuo jų veislės, atliekamas toks eksperimentas. Atsitiktinai parinktų n_1 sklypelių apsėjama pirmaja kviečių veisle; n_2 – antraja ir t. t., ir pagaliau n_m sklypelių – m -aja veisle. Pažymėkime Y_{ij} i -osios kviečių veislės derlingumą j -ajame sklypelyje. Tarkime, kad derlingumo pokyčiai pereinant nuo vienos kviečių veislės prie kitos nekeičia dispersijos, o gali keisti tik vidurkį. a) Užrašykite imtį tiesinio modelio (žr. **I.1.1** pratimą) pavidalu. b) Raskite modelio parametrų ivertinius.

II.1.4. Norint ištirti vyrių sistolinio krauso spaudimo Y priklausomybę nuo jų svorio X_1 ir amžiaus X_2 , atsitiktinai atrenkama n vyrių ir jiems pamatuojamos a. v. $(Y, X_1, X_2)^T$ reikšmės $(Y_i, x_{1i}, x_{2i})^T$, $i = 1, \dots, n$. a) Užrašykite imtį tiesinio modelio (žr. **II.1.1** pratimą) pavidalu. b) Raskite modelio parametrų ivertinius.

II.1.5. Tarkime, imties $\mathbf{Y} = (Y_1, Y_2, Y_3, Y_4)^T$ elementai turi tokią struktūrą $Y_1 = \alpha - \beta_2 + e_1$, $Y_2 = \alpha + 2\beta_1 - \beta_2 + e_2$, $Y_3 = \alpha + \beta_2 + e_3$, $Y_4 = \alpha - 2\beta_1 + \beta_2 + e_4$;

čia e_1, \dots, e_4 yra n. a. d., turintys nuliniaus vidurkius ir vienodas dispersijas σ^2 . Raskite parametruo $\beta = (\alpha, \beta_1, \beta_2)^T$ MK įvertinį ir jo realizaciją (įvertį), kai a. v. \mathbf{Y} realizacija yra $(-1, 9; 2, 05; 3, 15; 0, 1)^T$.

II.1.6. (II.1.5 pratimo tėsinys). Raskite liekamosios kvadratų sumos SS_E realizaciją.

II.1.7. (II.1.5 pratimo tėsinys). Raskite įvertinio $\hat{\beta}$ kovariacių matricą ir dispersijos σ^2 įvertį.

II.1.8. (II.1.5 pratimo tėsinys). Tarkime, kad domina parametras $\theta = (\theta_1, \theta_2)^T$, $\theta_1 = 2\alpha - \beta_1$, $\theta_2 = \alpha + \beta_1 - \beta_2$. Raskite parametruo θ įvertinį ir jo kovariacių matricą.

II.1.9. Tegu $Y_1 = \alpha + e_1$, $Y_2 = 2\alpha - \beta + e_2$, $Y_3 = \alpha + 2\beta + e_3$; čia $\{e_i\}$ neprisklausomi a. d., $\mathbf{E}(e_i) = 0$, $\mathbf{V}(e_i) = \sigma^2$. Raskite parametrų α ir β mažiausiuju kvadratų įvertinius ir jų dispersijas.

II.1.10. Turime tiesinį modelį

$$\mathbf{E}(Y_i) = \beta_0 + \beta_1 x_i + \beta_2 (3x_i^2 - 2), \quad i = 1, 2, 3;$$

čia $x_1 = -1$, $x_2 = 0$, $x_3 = 1$. Raskite parametrų $\beta_0, \beta_1, \beta_2$ įvertinius. Irodykite, kad parametrų β_0, β_2 įvertiniai modelyje, kuriame $\beta_1 = 0$, turi tą patį pavidałą.

II.1.11. Parametrams α ir β įvertinti turime stebėjimus: m stebėjimų a. d. Y_1 , kurio $\mathbf{E}(Y_1) = \alpha$; m stebėjimų a. d. Y_2 , kurio $\mathbf{E}(Y_2) = \alpha + \beta$, ir n stebėjimų a. d. Y_3 , kurio $\mathbf{E}(Y_3) = \alpha - 2\beta$. Stebėjimų paklaidos nekoreliuotos ir turi vienodas dispersijas. Irodykite, kad mažiausiuju kvadratų įvertiniai $\hat{\alpha}$ ir $\hat{\beta}$ nekoreliuoti, kai $m = 2n$.

II.1.12. Mažiausiuju kvadratų metodu parenkami pirmojo ir antrojo laipsnio polinomai pagal didumo n imtį $(X_i, Y_i)^T$, $i = 1, 2, \dots, n$. Tegu ω ir Ω yra šitokios prielaidos:

$$\omega : Y_i = \alpha + \beta X_i + e_i,$$

$$\Omega : Y_i = \alpha + \beta X_i + \gamma X_i^2 + e'_i;$$

čia e_i, e'_i – n. a. d. su nuliniais vidurkiais ir vienodomis dispersijomis σ^2 . Sudarykite normaliųjų lygčių sistemas ir raskite parametrų α, β ir α, β, γ mažiausiuju kvadratų įvertinius.

II.1.13 (II.1.12 pratimo tėsinys). Raskite parametrų įvertinių dispersijas. Irodykite: jeigu prielaidoje ω vietoje $\alpha + \beta X_i$ imsime $\delta + \beta(X_i - \bar{X})$, tai $\mathbf{Cov}(\hat{\delta}, \hat{\beta}) = 0$.

II.1.14. Gauti nepriklausomi ir vienodo tikslumo keturkampio ABCD kampų ABD, DBC, ABC, BCD, CDB, BDA, CDA, DAB matavimai (laipsniais): 50,78; 30,25; 78,29; 99,57; 50,42; 40,59; 88,87; 89,96. Raskite kampų $\beta_1 = \text{ABD}$, $\beta_2 = \text{DBC}$, $\beta_3 = \text{CDB}$, $\beta_4 = \text{BDA}$ mažiausiuju kvadratų įverčius ir matavimo paklaidos dispersijos σ^2 nepaslinktajį įvertį.

II.1.15. $\hat{\theta}_1, \dots, \hat{\theta}_k$ yra vienmačio parametruo θ nepaslinktieji įvertiniai ir $\mathbf{Cov}(\hat{\theta}_i, \hat{\theta}_j) = \sigma_{ij}$. Raskite tiesinę $\hat{\theta}_1, \dots, \hat{\theta}_k$ funkciją, kuri būtų nepaslinktasis θ įvertinys ir turėtų minimalią dispersiją. Raskite tos dispersijos reikšmę.

II.1.16. (II.1.15 pratimo tėsinys). Tegu $\mathbf{Cov}(\hat{\theta}_i, \hat{\theta}_j) = 0$, $i \neq j$, $\mathbf{V}\hat{\theta}_i = \sigma_i^2$, $i = 1, \dots, k$. Irodykite, kad $\mathbf{V}(c_1\hat{\theta}_1 + \dots + c_k\hat{\theta}_k)$, $c_1 + \dots + c_k = 1$, yra minimali, kai $c_i = \sigma_i^{-2}/(\sigma_1^{-2} + \dots + \sigma_k^{-2})$, ir raskite tos dispersijos reikšmę.

II.1.17. Irodykite, kad jeigu $\hat{\theta}_1, \dots, \hat{\theta}_k$ yra parametruo $\theta_1, \dots, \theta_k$ nepriklausomi NMD įvertiniai, tai $c_1\hat{\theta}_1 + \dots + c_k\hat{\theta}_k$ yra parametruo $\theta = c_1\theta_1 + \dots + c_k\theta_k$ NMD įvertinys.

II.1.18. $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. X , kurio $\mathbf{E}X = \mu$ ir $\mathbf{V}X = \sigma^2$. Užrašykite stebėjimus kaip tiesinį modelį. Raskite parametru μ mažiausiuju kvadratų įvertinį.

II.1.2. Normaliojo skirstinio atvejis

II.1.19. Tarkime, **II.1.1** pratimo sąlygomis papildomai priimama prielaida, kad paklaidų vektorius $\mathbf{e} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I})$ (arba $\mathbf{Y} \sim N_n(\mathbf{A}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$). a) Įrodykite, kad MK metodas parametru $\boldsymbol{\beta}$ įvertiniui rasti yra ekvivalentus DT metodui. b) Įrodykite, kad a. v. $\mathbf{T} = ((\mathbf{A}^T \mathbf{Y})^T, \mathbf{Y}^T \mathbf{Y})^T$ yra parametru $(\beta_1, \dots, \beta_m, \sigma^2)^T$ pilnoji ir pakankamoji statistika. c) Įrodykite, kad $\hat{\beta}_i, \mathbf{L}^T \hat{\boldsymbol{\beta}}, s^2$ yra parametrų $\beta_i, \mathbf{L}^T \boldsymbol{\beta}, \sigma^2$ NMD įvertiniai.

II.1.20. (**II.1.19** pratimo tēsinys). a) Raskite įvertinių $\hat{\boldsymbol{\beta}}, \hat{\theta} = \mathbf{L}^T \hat{\boldsymbol{\beta}}, s^2$ tikimybinius skirstinius. b) Raskite parametrų $\beta_i, \theta, \sigma^2$ pasiklovimo intervalus. c) Sudarykite hipotezų $H : \beta_i = \beta_i^0, H : \theta = \theta_0, H : \sigma^2 = \sigma_0^2$ tikrinimo kriterijus.

II.1.21. (**II.1.19** pratimo tēsinys). a) Raskite k -mačio a. v. $\hat{\boldsymbol{\theta}} = \mathbf{H}\hat{\boldsymbol{\beta}}$ (žr. **II.1.1** pratimą, p. c) tikimybinį skirstinį. b) Sudarykite parametru $\boldsymbol{\theta}$ pasiklovimo sritį. c) Raskite reikšmingumo lygmens α kriterijų hipotezei $H : \mathbf{H}\boldsymbol{\beta} = \boldsymbol{\theta}_0$ tikrinti. d) Užrašykite p. c) kriterijų naudodamasi kvadratinės formos $SS(\boldsymbol{\beta})$ sąlyginį minimum, surastą, kai H teisinga.

II.1.22. (**II.1.19** pratimo tēsinys). a) Raskite parametrų β_1, \dots, β_m pasiklovimo intervalų rinkinį, kad jie dengtų visus parametrus su tikimybe, ne mažesne už Q , remdamiesi **II.1.21** pratime surasta pasiklovimo sritimi. b) Raskite tokį pasiklovimo intervalų rinkinį pasiremdami Bonferonio nelygybe.

II.1.23. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastojo imtis a. d. $X \sim N(\mu, \sigma^2)$. Raskite parametru μ MK įvertinį ir liekamąją kvadratų sumą SS_E .

II.1.24. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ ir $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ yra paprastosios imtys n. a. d. X ir Y , kurių $\mathbf{E}X = \mu_1$, $\mathbf{E}Y = \mu_2$ ir $\mathbf{V}X = \mathbf{V}Y = \sigma^2$. Užrašykite stebėjimus tiesinio modelio pavidalu. Raskite parametrų μ_1, μ_2 mažiausiuju kvadratų įvertinius.

II.1.25. (**II.1.24** pratimo tēsinys). Tarkime, kad stebėti normalieji a. d. $X \sim N(\mu_1, \sigma^2)$ ir $Y \sim N(\mu_2, \sigma^2)$. Raskite liekamąją kvadratų sumą SS_E ir jos skirstinį.

II.1.26. (**II.1.24** pratimo tēsinys). Reikia patikrinti sudėtingąją hipotezę $H : \mu_1 = \mu_2$. Užrašykite šią hipotezę matriciniu pavidalu kaip **II.1.21** pratime. Raskite SS_{EH} ir $SS_{EH} - SS_E$.

II.1.27. (**II.1.12** pratimo tēsinys). Sukurkite kriterijų hipotezei $H : \gamma = 0$ tikrinti, kai a. d. e'_i pasiskirstę pagal normaliųjų skirstinių.

II.1.28. (**II.1.5** pratimo tēsinys). Tarkim, kad **II.1.5** pratime paklaidos turi normaliuosius skirstinius. Raskite parametrų $\alpha, \beta_1, \beta_2, \sigma^2$ lygmens $Q = 0,95$ pasiklovimo intervalus.

II.1.29. (**II.1.28** pratimo tēsinys). Raskite parametrų α, β_1, β_2 pasiklovimo intervalų rinkinius, kurie uždengtų visus parametrus su tikimybe, ne mažesne už $Q = 0,95$. a) Remdamiesi **II.1.22** pratimo p. a). b) Remdamiesi **II.1.22** pratimo p. b).

II.1.30. Kiek kartų **II.1.22** parametru p. a) intervalų ilgiai yra didesni už **II.1.22** p. b) intervalų ilgius, kai $n = 20, 100; m = 2, 5, 10$, o pasiklovimo lygmuo $Q = 0,95$.

II.1.31. (II.1.7 pratimo tēsinys). Tarkime, kad paklaidos normaliosios. a) Raskite parametru $\theta = (\theta_1, \theta_2)^T$, $\theta_1 = 2\alpha - \beta_1$, $\theta_2 = \alpha + \beta_1 - \beta_2$ lygmens Q pasiklovimo sritį. b) Reikšmingumo lygmens $\alpha = 0,05$ kriterijumi patikrinkite hipotezę $H : \theta = \mathbf{0}$.

II.1.32. (II.1.14 pratimo tēsinys). Tardami, kad kampų matavimų paklaidos turi normaliuosius skirstinius $N(0, \sigma^2)$, patikrinkite hipotezę $H : \beta_1 + \beta_2 = 90, \beta_3 + \beta_4 = 90$, t. y. kad keturkampis yra stačiakampis.

II.1.33. Tarkime, kad tiesinio modelio matrica $\mathbf{A}^T \mathbf{A} = [a_{ij}]_{(m) \times (m)}$ neišsigimus ir diagonaliniai elementai a_{ii} , $i = 1, \dots, m$ fiksuoti. Įrodykite, kad

- parametru β_i įvertinio dispersija tenkina nelygybę $V\hat{\beta}_i \geq 1/a_{ii}$;
- įvertinių $\hat{\beta}_i$ dispersijos minimalios, kai plano matricos A stulpeliai ortogonalūs, t. y. $\mathbf{A}^T \mathbf{A}$ – diagonalioji matrica.

II.1.34. Turime m objektų, kurių svoriai β_1, \dots, β_m yra nežinomi. Objektų svoris nustatomas sveriant juos lėkštelinėmis svarstyklėmis dvem būdais.

1) Kiekvienas objektas sveriamas r kartų ir jo svorio įvertiniu imamas gautų rezultatų aritmetinis vidurkis.

2) Sveriant keli objektais dedami ant vienos lėkštėlės, keli objektais – ant kitos ir pridedamas sarelis y , kad svarstyklės būtų pusiausviros. Tada k -ajam svérimui aprašyti turime tiesinį modelį:

$$y_k = a_{k1}\beta_1 + a_{k2}\beta_2 + \dots + a_{km}\beta_m + e_k, \quad k = 1, \dots, n;$$

čia plano matrica $A = [a_{kj}]_{n \times m}$, elementas $a_{kj} = +1$, -1 arba 0 , atsižvelgiant į tai, ar j -asis objektas padėtas ant kairės, dešinės lėkštutės arba apskritai nedalyvauja sveriant. Tarkime, kad matavimo paklaidos e abiem svérimo būdais yra vienodai pasiskirstę n. a. d. su ta pačia dispersija σ^2 .

Įrodykite, kad antruoju būdu didžiausio tikslumo pasiekiamą, kai plano matricos A elementai yra arba $+1$, arba -1 ir jos stulpeliai ortogonalūs.

II.1.35. (II.1.34 pratimo tēsinys). Tarkime, kad reikia įvertinti $m = 4$ objektų svorius $V\hat{\beta}_i = \sigma^2/4$ tikslumu. Tada pirmuoju būdu reikėtų atlikti $mr = 16$ svérimus. Kiek kartų galima sumažinti svérimų skaičių antruoju būdu? Raskite tokį minimalaus skaičiaus svérimų plano matricos A pavidalus.

II.1.36. (II.1.34 pratimo tēsinys). Sveriant 4 objektus antruoju būdu gauti dviejų nepriklausomų serijų po 4 svérimus rezultatai

y_k	a_{k1}	a_{k2}	a_{k3}	a_{k4}
20,2	+1	+1	+1	+1
8,1	+1	-1	+1	-1
9,7	+1	+1	-1	-1
1,9	+1	-1	-1	+1

y_k	a_{k1}	a_{k2}	a_{k3}	a_{k4}
19,9	+1	+1	+1	+1
8,3	+1	-1	+1	-1
10,2	+1	+1	-1	-1
1,8	+1	-1	-1	+1

a) Raskite parametrų β_1, \dots, β_4 įverčius pagal vieno ir kito eksperimento rezultatus. Ar galima pagal tas atskiras eksperimentų serijas įvertinti dispersiją σ^2 ?

b) Sujunkite šiuos abu eksperimentus ir įvertinkite parametrus $\beta_1, \dots, \beta_4, \sigma^2$. Kiek kartų reikėtų padidinti svérimų skaičių naudojant pirmąjį būdą, kad parametru β_1, \dots, β_4 įvertiniai būtų tokio paties tikslumas?

c) Tarę, kad paklaidų skirstiniai yra normalieji, palyginkite dispersijos σ^2 įvertinių dispersijas pirmuoju ir antruoju būdu, kai parametru β_1, \dots, β_4 įvertinių tikslumas yra vienodas.

II.1.37. Tarkime, $\mathbf{Y} = \mathbf{A}\beta + \mathbf{e}$, $\mathbf{E}(\mathbf{e}) = \mathbf{0}$, $\mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{\Lambda}$; čia $\text{Rang}(\mathbf{A}^T \mathbf{A}) = m$, o $\mathbf{\Lambda} = [\lambda_{ij}]_{n \times n}$ – žinoma teigiamai apibrėžta matrica. Raskite parametru β mažiausiuju kvadratų įvertinį ir jo kovariacinę matricą.

II.1.38. (II.1.37 pratimo tēsinys). Tegu $Y_i, i = 1, \dots, n$, yra nepriklausomi a. d., kurių $\mathbf{E}(Y_i) = \theta$, $\mathbf{V}(Y_i) = \sigma^2/\omega_i$; ω_i – žinomi. Raskite parametru θ tiesinį nepaslinktajį įvertinį su minimalia dispersija. Raskite šios dispersijos išraišką.

II.1.39. (II.1.37 pratimo tēsinys). Tegu Y_1, \dots, Y_n yra nepriklausomi a. d. ir $Y_i \sim N(i\theta, i^2\sigma^2)$, $i = 1, \dots, n$. Raskite parametru θ NMD įvertinį ir įrodykite, kad jo dispersija lygi σ^2/n .

II.1.40. (II.1.37 pratimo tēsinys). Tarkime, kad II.1.37 pratimo sąlygomis $\mathbf{e} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{\Lambda})$. Raskite parametrų β ir σ^2 įvertinius ir jų skirstinius.

II.1.41. (II.1.37 pratimo tēsinys). Reikia įvertinti skysčio tankį d atliekant nepriklausomus įvairaus tūrio skysčio svėrimus. Tegu Y_i yra gautas tūrio X_i skysčio svoris; $\mathbf{E}(Y_i) = dX_i$, $\mathbf{V}(Y_i) = \sigma^2 f(X_i)$, $i = 1, \dots, n$. Raskite parametru d mažiausiuju kvadratų įvertinį, kai a) $f(X_i) = 1$; b) $f(X_i) = X_i$; c) $f(X_i) = X_i^2$.

II.1.42. (II.1.37 pratimo tēsinys). Tegu $Y_i = \beta_0 + \beta_1 X_i + e_i$, $i = 1, 2, 3$; $\mathbf{E}(\mathbf{e}) = \mathbf{0}$, $\mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{\Lambda}$; čia

$$\mathbf{\Lambda} = \begin{pmatrix} 1 & \rho & \rho \\ \rho & 1 & \rho \\ \rho & \rho & 1 \end{pmatrix},$$

o ρ yra žinomas. Raskite parametrų β_0 ir β_1 mažiausiuju kvadratų įvertinius ir jų dispersijas.

II.1.43. Tegu imties elementai Y_1, \dots, Y_n , aprašomi tiesiniu modeliu su normaliosiomis paklaidomis, turi vienodas dispersijas $\mathbf{V}(Y_i) = \sigma^2$ ir vienodas kovariacijas $\mathbf{Cov}(Y_i, Y_j) = \rho\sigma^2, i \neq j$. Atliekame ortogonalią tiesinę transformaciją, pervedančią a. v. $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ į vektorių $\mathbf{Z} = (Z_1, \dots, Z_n)^T$, kai $Z_1 = (Y_1 + \dots + Y_n)/n$. Įrodykite, kad vektoriaus $\mathbf{Z}_2 = (Z_2, \dots, Z_n)^T$ koordinatės nekoreliuotos ir turi vienodas dispersijas $\sigma^2(1 - \rho)$. Įrodykite, kad parametrinių funkcijų nepaslinktieji tiesiniai įvertiniai su minimalia dispersija yra tiesinio modelio $\mathbf{Z}_2 = \mathbf{U}\beta + \mathbf{e}$, $\mathbf{e} \sim N_{n-1}(\mathbf{0}, \sigma^2(1 - \rho)\mathbf{I})$ mažiausiuju kvadratų įvertiniai.

II.1.44. Tarkime, kad i II.1.1 pratimo tiesinį modelį įtraukiame papildomai r kovariančių. Tada gauname išplėstą tiesinį modelį

$$\mathbf{Y} = \mathbf{A}\beta + \mathbf{B}\gamma + \mathbf{e} = (\mathbf{A} : \mathbf{B}) \begin{pmatrix} \beta \\ \cdots \\ \gamma \end{pmatrix} = \mathbf{W}\delta + \mathbf{e}.$$

Tarę, kad $\text{Rang}(\mathbf{W}) = m + r$, gauname išplėstinio modelio parametru δ įvertinį

$$\hat{\delta} = \begin{pmatrix} \beta^* \\ \cdots \\ \gamma^* \end{pmatrix} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{Y},$$

kuris yra sistemos, susidedančios iš $m + r$ lygčių, sprendinys. Įrodykite, kad

a) $\beta^* = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T (\mathbf{Y} - \mathbf{B}\gamma^*)$, $\gamma^* = (\mathbf{B}^T \mathbf{R}\mathbf{B})^{-1} \mathbf{B}^T \mathbf{R}\mathbf{Y}$, $\mathbf{R} = \mathbf{I} - \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$, t. y. galima spręsti dvi sistemas, susidedančias iš m ir r lygčių;

b) $SS_E = (\mathbf{Y} - \mathbf{B}\boldsymbol{\gamma}^*)^T \mathbf{R}(\mathbf{Y} - \mathbf{R}\boldsymbol{\gamma}^*) = \mathbf{Y}^T \mathbf{R}\mathbf{Y} - (\boldsymbol{\gamma}^*)^T \mathbf{B}^T \mathbf{R}\mathbf{Y};$
c) $\mathbf{V}(\boldsymbol{\beta}^*) = \sigma^2[(\mathbf{A}^T \mathbf{A})^{-1} + \mathbf{LML}^T], \quad \mathbf{V}(\boldsymbol{\gamma}^*) = \sigma^2 \mathbf{M},$

$$\text{Cov}(\boldsymbol{\beta}^*, \boldsymbol{\gamma}^*) = -\sigma^2 \mathbf{LM}; \quad \mathbf{L} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{B}, \quad \mathbf{M} = (\mathbf{B}^T \mathbf{R}\mathbf{B})^{-1}.$$

II.1.3. Atsakymai, nurodymai, sprendimai

II.1.1 skyrelis

II.1.1. a) Mažiausiuju kvadratų įvertinys gaunamas minimizuojant pagal $\boldsymbol{\beta}$ kvadratinę formą (žr. [3], 1.2 skyrelį)

$$SS(\boldsymbol{\beta}) = (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta})^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta}) \rightarrow \min_{\boldsymbol{\beta}}.$$

Diferencijuodami $SS(\boldsymbol{\beta})$ pagal $\boldsymbol{\beta}$ ir prilyginę išvestinę nuliui, gauname lygčių sistemą

$$\mathbf{A}^T \mathbf{A}\boldsymbol{\beta} = \mathbf{A}^T \mathbf{Y},$$

iš kurios randame parametru $\boldsymbol{\beta}$ MK įvertinį

$$\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}.$$

b) Įvertinys $\hat{\boldsymbol{\beta}}$ yra tiesinė a. v. \mathbf{Y} funkcija. Taigi

$$\mathbf{E}(\hat{\boldsymbol{\beta}}) = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A}\boldsymbol{\beta} = \boldsymbol{\beta},$$

$$\mathbf{V}(\hat{\boldsymbol{\beta}}) = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}(\mathbf{Y}) \mathbf{A} (\mathbf{A}^T \mathbf{A})^{-1} = \sigma^2 (\mathbf{A}^T \mathbf{A})^{-1}.$$

c) Įvertinys $\hat{\boldsymbol{\theta}}$ yra tiesinė a. v. \mathbf{Y} funkcija. Gauname

$$\mathbf{E}(\hat{\boldsymbol{\theta}}) = \mathbf{H}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A}\boldsymbol{\beta} = \mathbf{H}\boldsymbol{\beta} = \boldsymbol{\theta}, \quad \mathbf{V}(\hat{\boldsymbol{\theta}}) = \sigma^2 \mathbf{H}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{H}^T.$$

II.1.2. a) Randame

$$\begin{aligned} SS_E &= \mathbf{Y}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{A}\hat{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}^T \mathbf{A}^T \mathbf{Y} + \hat{\boldsymbol{\beta}}^T \mathbf{A}^T \mathbf{A}\hat{\boldsymbol{\beta}} = \\ &= \mathbf{Y}^T \mathbf{Y} - \hat{\boldsymbol{\beta}}^T \mathbf{A}^T \mathbf{Y} + \hat{\boldsymbol{\beta}}^T [\mathbf{A}^T \mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}^T \mathbf{Y}] = \mathbf{Y}^T \mathbf{Y} - \hat{\boldsymbol{\beta}}^T \mathbf{A}^T \mathbf{Y}, \end{aligned}$$

nes (**II.1.1** pratimo p. a)) laužtiniuose skliaustuose parašytas reiškinys lygus nuliui.

b) Turime

$$\begin{aligned} SS(\boldsymbol{\beta}) &= (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}} + \mathbf{A}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}))^T (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}} + \mathbf{A}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})) = \\ &= SS_E + (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})^T \mathbf{A}^T \mathbf{A}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}), \end{aligned}$$

nes

$$(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})^T \mathbf{A}^T (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}}) = (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})^T \mathbf{A}^T (\mathbf{I} - \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T) \mathbf{Y} = 0.$$

Kadangi $\mathbf{E}(SS(\boldsymbol{\beta})) = \mathbf{E}(e_1^2 + \dots + e_n^2) = n\sigma^2$, o (žr. [3], 7.3 skyrelį)

$$\mathbf{E}((\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})^T \mathbf{A}^T \mathbf{A}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})) = Tr(\mathbf{V}(\hat{\boldsymbol{\beta}}) \mathbf{A}^T \mathbf{A}) = \sigma^2 Tr(\mathbf{I}) = m\sigma^2,$$

tai $\mathbf{E}(SS_E) = (n - m)\sigma^2$. Nepaslinktasis dispersijos σ^2 įvertinys

$$s^2 = SS_E/(n - m), \quad \mathbf{E}(s^2) = \sigma^2.$$

II.1.3. a) Sujungę stebėjimus Y_{ij} į vieną bendrą vektorių

$$\mathbf{Y} = (Y_{11}, \dots, Y_{1n_1}, Y_{21}, \dots, Y_{2n_2}, \dots, Y_{m1}, \dots, Y_{mn_m})^T,$$

pažymėję nežinomų parametru vektorių $\boldsymbol{\beta} = (\mu_1, \dots, \mu_m)^T$ (čia μ_i yra i -osios kviečių veislės vidutinis derlingumas) ir tarę, kad paklaidų vektorius \mathbf{e} tenkina sąlygas $\mathbf{E}(\mathbf{e}) = \mathbf{0}$, $\mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I}$, gausime modelio aprašymą matricine forma $\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}$. Matrica \mathbf{A} turi $n = n_1 + \dots + n_m$ eilučių ir m stulpelių. Pirmosios n_1 eilutės turi pavidalą $(1, 0, \dots, 0)$, paskui n_2 eilučių turi pavidalą $(0, 1, 0, \dots, 0)$, pagaliau paskutinės n_m eilučių turi pavidalą $(0, 0, \dots, 0, 1)$.

b) Matrica $\mathbf{A}^T \mathbf{A}$ diagonali su diagonaliniais elementais $n_i, i = 1, \dots, m$; vektoriaus $\mathbf{A}^T \mathbf{Y}$ elementai yra

$$\sum_{j=1}^{n_i} Y_{ij} = n_i \bar{Y}_{i.}, \quad i = 1, \dots, m.$$

Gauname parametru įvertinius

$$\hat{\mu}_i = \bar{Y}_{i.}, \quad i = 1, \dots, m, \quad \hat{\sigma}^2 = s^2 = \sum_{i=1}^m \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2 / (n - m).$$

II.1.4. a) Tarkime, kad stebėjimai, kai skirtinti $i = 1, \dots, n$ yra nekoreliuoti a.d.; Y sąlyginio skirstinio, kai $\mathbf{X} = (X_1, X_2)^T = (x_1, x_2)^T$ yra fiksotas, dispersija lygi σ^2 ir nepriklauso nuo $\mathbf{x} = (x_1, x_2)^T$, o Y vidurkis yra tiesinė funkcija: $\mathbf{E}(Y|\mathbf{X} = \mathbf{x}) = \beta_0 + \beta_1 x_1 + \beta_2 x_2$. Tardami, kad a.v. $(X_1, X_2)^T$ realizacijos $(x_{1i}, x_{2i}), i = 1, \dots, n$ yra fiksatos, gauname modelį

$$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + e_i, \quad i = 1, \dots, n.$$

Pažymėjus $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ ir $\boldsymbol{\beta} = (\beta_0, \beta_1, \beta_2)^T$ nežinomų parametru vektorių, modelį galima užrašyti matriciniu pavidalu $\mathbf{Y} = \mathbf{A}^T \boldsymbol{\beta} + \mathbf{e}$ su matrica \mathbf{A} , kuri turi n eilučių ir 3 stulpelius: i -oji eilutė turi pavidalą $(1, x_{1i}, x_{2i})$.

b) Parametro $\boldsymbol{\beta}$ MK įvertinys yra $\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}$, kai matricos $\mathbf{A}^T \mathbf{A} = [a_{ij}]_{3 \times 3}$ elementai yra $a_{11} = n, a_{22} = \sum_i x_{1i}^2, a_{33} = \sum_i x_{2i}^2, a_{12} = \sum_i x_{1i} x_{2i}, a_{13} = \sum_i x_{1i} x_{2i}, a_{23} = \sum_i x_{1i} x_{2i}$; vektorius $\mathbf{A}^T \mathbf{Y} = (\sum_i Y_i, \sum_i Y_i x_{1i}, \sum_i Y_i x_{2i})^T$;

$$\hat{\sigma}^2 = s^2 = \sum_i (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \hat{\beta}_2 x_{2i})^2 / (n - 3).$$

II.1.5. Turime tiesinį Gauso ir Markovo modelį $\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}$, kuriamame

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \alpha \\ \beta_1 \\ \beta_2 \end{pmatrix}, \quad \mathbf{A} = \begin{pmatrix} 1 & 0 & -1 \\ 1 & 2 & -1 \\ 1 & 0 & 1 \\ 1 & -2 & 1 \end{pmatrix}, \quad \mathbf{e} = \begin{pmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \end{pmatrix}.$$

Gauname

$$(\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{4} \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 1 \\ 0 & 1 & 2 \end{pmatrix}, \quad \mathbf{A}^T \mathbf{Y} = \begin{pmatrix} Y_1 + Y_2 + Y_3 + Y_4 \\ 2Y_2 - 2Y_4 \\ -Y_1 - Y_2 + Y_3 + Y_4 \end{pmatrix}$$

ir

$$\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \frac{1}{4} \begin{pmatrix} Y_1 + Y_2 + Y_3 + Y_4 \\ -Y_1 + Y_2 + Y_3 - Y_4 \\ -2Y_1 + 2Y_3 \end{pmatrix}.$$

Pagal turimą imties realizaciją gauname įvertį

$$\mathbf{A}^T \mathbf{Y} = \begin{pmatrix} 4,2 \\ 3,9 \\ 3,9 \end{pmatrix}, \quad \hat{\boldsymbol{\beta}} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \frac{1}{4} \begin{pmatrix} 4,2 \\ 7,8 \\ 11,7 \end{pmatrix} = \begin{pmatrix} 1,05 \\ 1,95 \\ 2,93 \end{pmatrix}.$$

II.1.6. Gauname

$$SS_E = (Y_1 - \hat{\alpha} + \hat{\beta}_2)^2 + (Y_2 - \hat{\alpha} - 2\hat{\beta}_1 + \hat{\beta}_2)^2 + (Y_3 - \hat{\alpha} - \hat{\beta}_2)^2 + (Y_4 - \hat{\alpha} + 2\hat{\beta}_1 - \hat{\beta}_2)^2 = 0,0025.$$

Liekamają kvadratų sumą galima rasti ir pagal **II.1.2** pratimo p. a) formulę

$$SS_E = Y_1^2 + Y_2^2 + Y_3^2 + Y_4^2 - 4,2\hat{\alpha} - 3,9\hat{\beta}_1 - 3,9\hat{\beta}_2 = 0,0025.$$

II.1.7. Remiantis **II.1.1** pratimu

$$\mathbf{V}(\hat{\boldsymbol{\beta}}) = \sigma^2 (\mathbf{A}^T \mathbf{A})^{-1} = \frac{\sigma^2}{4} \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 1 \\ 0 & 1 & 2 \end{pmatrix},$$

iš čia $\mathbf{V}\hat{\alpha} = \sigma^2/4, \mathbf{V}\hat{\beta}_1 = \sigma^2/4, \mathbf{V}\hat{\beta}_2 = \sigma^2/2, \mathbf{Cov}(\hat{\alpha}, \hat{\beta}_1) = 0, \mathbf{Cov}(\hat{\alpha}, \hat{\beta}_2) = 0, \mathbf{Cov}(\hat{\beta}_1, \hat{\beta}_2) = \sigma^2/4$. Dispersijos σ^2 nepaslinktasis įvertis

$$s^2 = SS_E/(n - m) = SS_E = 0,0025.$$

II.1.8. Parametras $\boldsymbol{\theta}$ yra tiesinė $\boldsymbol{\beta}$ funkcija

$$\boldsymbol{\theta} = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} = \begin{pmatrix} \mathbf{L}^T \boldsymbol{\beta} \\ \mathbf{K}^T \boldsymbol{\beta} \end{pmatrix}, \quad \mathbf{L} = (2, -1, 0)^T, \quad \mathbf{K} = (1, 1, -1)^T.$$

Remiantis [3], 1.2.3 teorema vienintelis mažiausios dispersijos įvertinys tiesinių nepaslinktujų įvertinių klasėje yra

$$\hat{\boldsymbol{\theta}} = \begin{pmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{L}^T \hat{\boldsymbol{\beta}} \\ \mathbf{K}^T \hat{\boldsymbol{\beta}} \end{pmatrix} = \begin{pmatrix} 2\hat{\alpha} - \hat{\beta}_1 \\ \hat{\alpha} + \hat{\beta}_1 - \hat{\beta}_2 \end{pmatrix},$$

o jo kovariacinė matrica

$$\mathbf{V}(\hat{\boldsymbol{\theta}}) = \sigma^2 \begin{pmatrix} \mathbf{L}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{L} & \mathbf{L}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{K} \\ \mathbf{K}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{L} & \mathbf{K}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{K} \end{pmatrix} = \frac{\sigma^2}{4} \begin{pmatrix} 5 & 2 \\ 2 & 2 \end{pmatrix}.$$

Ivertinio $\hat{\theta}$ realizacija yra $(0, 15, 0, 075)$.

II.1.9. $\hat{\alpha} = (Y_1 + 2Y_2 + Y_3)/6$, $\hat{\beta} = (2Y_3 - Y_2)/5$, $\mathbf{V}\hat{\alpha} = \sigma^2/6$, $\mathbf{V}\hat{\beta} = \sigma^2/5$, $\text{Cov}(\hat{\alpha}, \hat{\beta}) = 0$.

II.1.10. $\hat{\beta}_0 = (Y_1 + Y_2 + Y_3)/3$, $\hat{\beta}_1 = (Y_3 - Y_1)/2$, $\hat{\beta}_2 = (Y_1 - 2Y_2 + Y_3)/6$.

II.1.11. Matricos $\mathbf{A}^T \mathbf{A} = [c_{ij}]_{2 \times 2}$ elementas $c_{12} = c_{21} = m - 2n$.

II.1.12. Tarkime, kad $X_i = x_i, i = 1, \dots, n$, reikšmės yra fiksuotos. Atveju ω parametru $\beta = (\alpha, \beta)^T$ ivertinys $\tilde{\beta}$ gaunamas sprendžiant dviejų lygčių sistemą:

$$\mathbf{A}^T \mathbf{A} \tilde{\beta} = \mathbf{A}^T \mathbf{Y};$$

čia matrica $\mathbf{A}^T \mathbf{A} = [a_{ij}]_{2 \times 2}$, $a_{11} = n, a_{12} = a_{21} = \sum_i x_i, a_{22} = \sum_i x_i^2$, o vektorius $\mathbf{A}^T \mathbf{Y} = (\sum_i Y_i, \sum_i Y_i x_i)^T$. Atveju Ω parametru $\beta = (\alpha, \beta, \gamma)^T$ ivertinys $\tilde{\beta}$ gaunamas sprendžiant trijų lygčių sistemą: $\mathbf{A}^T \mathbf{A} \tilde{\beta} = \mathbf{A}^T \mathbf{Y}$; čia matrica $\mathbf{A}^T \mathbf{A} = [a_{ij}]_{3 \times 3}$, $a_{13} = a_{31} = \sum_i x_i^2, a_{23} = a_{32} = \sum_i x_i^3, a_{33} = \sum_i x_i^4$, o vektorius $\mathbf{A}^T \mathbf{Y} = (\sum_i Y_i, \sum_i Y_i x_i, \sum_i Y_i x_i^2)^T$.

II.1.13. Ivertinių dispersijos yra matricos $\sigma^2(\mathbf{A}^T \mathbf{A})^{-1}$ diagonaliniai elementai. Jeigu atveju ω vietoje $\alpha + \beta X_i$ imsimė $\delta + \beta(X_i - \bar{X})$, tai matrica $\mathbf{A}^T \mathbf{A}$ diagonali.

II.1.14. Imties $\mathbf{Y} = (Y_1, \dots, Y_8)^T$ elementai turi tokią struktūrą $Y_1 = \beta_1 + e_1, Y_2 = \beta_2 + e_2, Y_3 = \beta_1 + \beta_2 + e_3, 180 - Y_4 = \beta_2 + \beta_3 + e_4, Y_5 = \beta_3 + e_5, Y_6 = \beta_4 + e_6, Y_7 = \beta_3 + \beta_4 + e_7, 180 - Y_8 = \beta_1 + \beta_4 + e_8$. Pažymėkime $Z_4 = 180 - Y_4, Z_8 = 180 - Y_8, Z_i = Y_i, i \neq 4, 8$. Tada turime tiesinį modelį $\mathbf{Z} = \mathbf{A}\beta + \mathbf{e}$, kuriame plano matrica

$$\mathbf{A}^T = \begin{pmatrix} 1 & 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 \end{pmatrix}.$$

Randame

$$(\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{15} \begin{pmatrix} 7 & -3 & 2 & -3 \\ -3 & 7 & -3 & 2 \\ 2 & -3 & 7 & -3 \\ -3 & 2 & -3 & 7 \end{pmatrix}, \mathbf{A}^T \mathbf{Z} = \begin{pmatrix} Z_1 + Z_3 + Z_8 \\ Z_2 + Z_3 + Z_4 \\ Z_4 + Z_5 + Z_7 \\ Z_6 + Z_7 + Z_8 \end{pmatrix} = \begin{pmatrix} 219, 21 \\ 188, 97 \\ 219, 72 \\ 219, 60 \end{pmatrix}.$$

Gauname parametrų jverčius $\hat{\beta} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Z} = (49, 88; 29, 68; 50, 05; 39, 89)^T$. Liekamoji kvadratų suma

$$SS_E = \sum_{i=1}^8 Z_i^2 - \hat{\beta}^T \mathbf{A}^T \mathbf{Z} = 5,1465.$$

Dispersijos σ^2 nepaslinktasis jvertis $s^2 = SS_E/4 = 1,2866$.

II.1.15. Pažymėkime $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_k)^T$ ir Σ^{-1} kovariacinės matricos $\Sigma = \mathbf{V}(\hat{\theta})$ atvirkštinę matricą. Tiesinės formos $\hat{\theta} = \mathbf{L}^T \hat{\theta}$ dispersija $\mathbf{V}\theta = \mathbf{L}^T \Sigma \mathbf{L}$. Ivertinys $\hat{\theta}$

nepaslinktas, kai $\mathbf{L}^T \mathbf{1} = 1$; čia $\mathbf{1} = (1, 1, \dots, 1)^T$ yra vektorius su vienetinėmis koordinatėmis. Reikia rasti vektorių \mathbf{L} tenkinantį sąlygas

$$\begin{cases} \mathbf{L}^T \Sigma \mathbf{L} \rightarrow \min_{\mathbf{L}}, \\ \mathbf{L}^T \mathbf{1} = 1. \end{cases}$$

Remiantis Lagranžo neapibréžtinių daugiklių metodu reikia minimizuoti $\mathbf{L}^T \Sigma \mathbf{L} - 2\lambda(\mathbf{L}^T \mathbf{1} - 1)$. Diferencijuodami pagal \mathbf{L}^T gauname

$$\Sigma \mathbf{L} - \lambda \mathbf{1} = 0 \Leftrightarrow \mathbf{L} = \lambda \Sigma^{-1} \mathbf{1}.$$

Iš sąlygos $\mathbf{L}^T \mathbf{1} = 1$ randame $\lambda = 1/(\mathbf{1}^T \Sigma^{-1} \mathbf{1})$.

Taigi minimali dispersija $\mathbf{V}(\mathbf{L}^T \hat{\boldsymbol{\theta}}) = 1/(\mathbf{1}^T \Sigma^{-1} \mathbf{1})$.

II.1.16. Remiantis II.1.15 pratimu $c_i = \sigma_i^{-2}/(\sigma_1^{-2} + \dots + \sigma_k^{-2})$ ir $\mathbf{V}(c_1 \hat{\theta}_1 + \dots + c_k \hat{\theta}_k) = 1/(\sigma_1^{-2} + \dots + \sigma_k^{-2})$.

II.1.17. Ivertinys $\hat{\theta} = c_1 \hat{\theta}_1 + \dots + c_k \hat{\theta}_k$ yra nepaslinktasis $\mathbf{E}\hat{\theta} = \theta$, o jo dispersija $\mathbf{V}(\hat{\theta}) = c_1^2 \mathbf{V}(\hat{\theta}_1) + \dots + c_k^2 \mathbf{V}(\hat{\theta}_k)$ minimali, nes kiekvienas dėmuo įgyja minimalią reikšmę.

II.1.18. $\mathbf{X} = \mathbf{A}\mu + \mathbf{e}$, $\mathbf{A}^T = (1, 1, \dots, 1)$; $\mathbf{E}(\mathbf{e}) = \mathbf{0}$, $\mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I}$;

$$\hat{\mu} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{X} = \bar{X}.$$

II.1.2 skyrelis

II.1.19. a) Tikėtinumo funkcija

$$\begin{aligned} L(\boldsymbol{\beta}, \sigma^2) &= (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta})^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta}) - \frac{n}{2} \ln \sigma^2\right\} = \\ &= (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} SS(\boldsymbol{\beta}) - \frac{n}{2} \ln \sigma^2\right\}. \end{aligned}$$

Funkcijos L maksimizavimas $\boldsymbol{\beta}$ atžvilgiu yra ekvivalentus $SS(\boldsymbol{\beta})$ minimizavimui.

b) Perrašykime tikėtinumo funkciją tokiu būdu

$$L(\boldsymbol{\beta}, \sigma^2) = (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} (\mathbf{Y}^T \mathbf{Y} - 2\boldsymbol{\beta}^T \mathbf{A}^T \mathbf{Y}) - \frac{1}{2\sigma^2} \boldsymbol{\beta}^T \mathbf{A}^T \mathbf{A} \boldsymbol{\beta} - \frac{n}{2} \ln \sigma^2\right\}.$$

Imties \mathbf{Y} tankis priklauso $(m+1)$ parametrai eksponentinio tipo skirstinių šeimai. Remiantis faktorizacijos kriterijumi \mathbf{T} yra pakankamoji statistika. Kadangi parametrų kitimo sričiai priklauso vidiniai taškai, tai statistika \mathbf{T} pilnoji.

c) Kadangi \mathbf{T} pilnoji ir pakankamoji statistika, tai bet kuri \mathbf{T} funkcija yra jos vidurkio NMD įvertinys. Ivertinai $\hat{\beta}_i, \mathbf{L}^T \hat{\boldsymbol{\beta}}, s^2$ yra statistikos \mathbf{T} funkcijos ir

$$\mathbf{E}\hat{\beta}_i = \beta_i, \quad \mathbf{E}(\mathbf{L}\hat{\boldsymbol{\beta}}) = \mathbf{L}\boldsymbol{\beta}, \quad \mathbf{E}s^2 = \sigma^2.$$

II.1.20. a) Ivertinai $\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}$ ir $\hat{\theta} = \mathbf{L}^T \hat{\boldsymbol{\beta}}$ yra normaliojo vektoriaus $\mathbf{Y} \sim N_n(\mathbf{A}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$ tiesinės funkcijos. Remiantis daugiamacojo normaliojo vektoriaus savybėmis ([3], 7.4 skyrelis)

$$\hat{\boldsymbol{\beta}} \sim N_m(\boldsymbol{\beta}, \sigma^2 (\mathbf{A}^T \mathbf{A})^{-1}), \quad \hat{\theta} \sim N(\theta, \sigma^2 \mathbf{L}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{L}).$$

Turime (žr. **II.1.2** pratimą)

$$\frac{SS(\boldsymbol{\beta})}{\sigma^2} = \frac{SS_E}{\sigma^2} + \frac{(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})^T \mathbf{A}^T \mathbf{A} (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})}{\sigma^2}.$$

Kairėje lygybės pusėje $SS(\boldsymbol{\beta})/\sigma^2 = (e_1^2 + \dots + e_n^2)/\sigma^2 \sim \chi^2(n)$. Remiantis daugiamaco normaliojo vektoriaus savybėmis ([3], 7.4 skyrelis) antrasis dėmuo dešinėje pusėje turi χ^2 skirstinį $\chi^2(m)$. Remiantis Kornišo ir Fišerio teorema ([15], 3b.4 skyrelis) kvadratinė forma $s^2(n-m)/\sigma^2 = SS_E/\sigma^2 \sim \chi^2(n-m)$ ir nepriklauso nuo $\hat{\boldsymbol{\beta}}$.

b) Remiantis p. a)

$$\frac{\hat{\beta}_i - \beta_i}{s\sqrt{b_{ii}}} \sim S(n-m), \quad \frac{\hat{\theta} - \theta}{sb} \sim S(n-m),$$

čia b_{ij} yra matricos $(\mathbf{A}^T \mathbf{A})^{-1} = [b_{ij}]_{m \times m}$ elementai, o $b^2 = \mathbf{L}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{L}$. Gauname pasikliovimo lygmens $Q = 1 - \alpha$ pasikliovimo intervalus

$$(\underline{\beta}_i; \bar{\beta}_i) = (\hat{\beta}_i - s\sqrt{b_{ii}}t_{\alpha/2}(n-m); \hat{\beta}_i + s\sqrt{b_{ii}}t_{\alpha/2}(n-m)),$$

$$(\underline{\theta}; \bar{\theta}) = (\hat{\theta} - sbt_{\alpha/2}(n-m); \hat{\theta} + sbt_{\alpha/2}(n-m)).$$

Kadangi $s^2(n-m)/\sigma^2 \sim \chi^2(n-m)$, tai gauname

$$(\underline{\sigma^2}_i; \bar{\sigma^2}) = \left(\frac{s^2(n-m)}{\chi^2_{\alpha/2}(n-m)}, \frac{s^2(n-m)}{\chi^2_{1-\alpha/2}(n-m)} \right).$$

c) Kriterijus galime suformuluoti p. b) surastų pasikliovimo intervalų terminais. Arba kriterijai yra tokie: suformuluotos hipotezės, kai alternatyvos dvipusės, atmetamos reikšmingumo lygmens α kriterijais, kai atitinkamai teisingos nelygybės

$$|t_i| = \frac{|\hat{\beta}_i - \beta_i^0|}{s\sqrt{b_{ii}}} > t_{\alpha/2}(n-m), \quad |t| = \frac{|\hat{\theta} - \theta_0|}{sb} > t_{\alpha/2}(n-m);$$

$$\frac{s^2(n-m)}{\sigma_0^2} < \chi^2_{1-\alpha/2}(n-m) \quad \text{arba} \quad \frac{s^2(n-m)}{\sigma_0^2} < \chi^2_{\alpha/2}(n-m).$$

II.1.21. a) Ivertinys $\hat{\boldsymbol{\theta}} = \mathbf{H}\hat{\boldsymbol{\beta}} = \mathbf{H}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}$ yra tiesinė normaliojo a. v. $\mathbf{Y} \sim N_n(\mathbf{A}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$ funkcija. Taigi

$$\hat{\boldsymbol{\theta}} \sim N_k(\boldsymbol{\theta}, \sigma^2 \boldsymbol{\Sigma}), \quad \boldsymbol{\Sigma} = \mathbf{H}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{H}^T,$$

$$(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) / \sigma^2 \sim \chi^2(k).$$

Kadangi $\hat{\boldsymbol{\theta}}$ ir SS_E nepriklausomi, tai

$$\frac{(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})}{ks^2} \sim F(k, n-m)$$

ir

$$C(\hat{\boldsymbol{\theta}}, s^2) = \left\{ \boldsymbol{\theta} : \frac{(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})}{ks^2} < F_\alpha(k, n-m) \right\}$$

yra parametru $\boldsymbol{\theta}$ pasiklivimo lygmens $Q = 1 - \alpha$ pasiklivimo sritis.

c) Hipotezė H atmetama, kai

$$F = \frac{(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0)^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0)}{ks^2} > F_\alpha(k, n-m),$$

t. y. kai taškas $\boldsymbol{\theta}_0$ nepatenka į pasiklivimo sritį $C(\hat{\boldsymbol{\theta}}, s^2)$.

d) Pažymėkime

$$SS_{EH} = \min_{\boldsymbol{\beta}: \mathbf{H}\boldsymbol{\beta}=\boldsymbol{\theta}_0} SS(\boldsymbol{\beta}) = \min_{\boldsymbol{\beta}: \mathbf{H}\boldsymbol{\beta}=\boldsymbol{\theta}_0} (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta})^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta}).$$

Tada (žr. [3], 1.3.2 teorema) $SS_{EH} - SS_E$ ir SS_E yra nepriklausomi; $(SS_{EH} - SS_E)/\sigma^2 \sim \chi^2(k; \lambda)$, necentriškumo parametras $\lambda = (\mathbf{H}\boldsymbol{\beta} - \boldsymbol{\theta}_0)^T \boldsymbol{\Sigma}^{-1} (\mathbf{H}\boldsymbol{\beta} - \boldsymbol{\theta}_0)$. Jeigu hipotezė H teisinga, tai $\lambda = 0$ ir $(SS_{EH} - SS_E)/\sigma^2 \sim \chi^2(k)$. Hipotezė H atmetama, kai

$$F = \frac{SS_{EH} - SS_E}{ks^2} > F_\alpha(k, n-m).$$

Pastaba. Palyginę p. c) ir d) kriterijus matome, kad $SS_{EH} - SS_E = (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0)^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0)$. Praktiškai dažnai yra paprasčiau rasti sąlyginį minimum SS_{EH} negu rasti ir apversti matricą $\boldsymbol{\Sigma}$.

II.1.22. a) Remiantis sritimi $C(\hat{\boldsymbol{\theta}}, s^2)$ gaunama, kad visoms tiesinėms funkcijoms $\mathbf{c}^T \boldsymbol{\beta}$ su tikimybe $Q = 1 - \alpha$ galioja nelygybės (žr. [3], 1.3.3 teorema)

$$\mathbf{c}^T \hat{\boldsymbol{\beta}} - \delta_\alpha \sqrt{\mathbf{c}^T \boldsymbol{\Sigma} \mathbf{c}} \leq \mathbf{c}^T \boldsymbol{\beta} \leq \mathbf{c}^T \hat{\boldsymbol{\beta}} + \delta_\alpha \sqrt{\mathbf{c}^T \boldsymbol{\Sigma} \mathbf{c}},$$

čia $\boldsymbol{\Sigma} = (\mathbf{A}^T \mathbf{A})^{-1}$, $\delta_\alpha = s \sqrt{m F_\alpha(m, n-m)}$. Imdami paeiliui $\mathbf{c}_1 = (1, 0, \dots, 0)^T$, $\mathbf{c}_2 = (0, 1, \dots, 0)^T, \dots, \mathbf{c}_m = (0, 0, \dots, 1)^T$, gausime

$$\mathbf{P}_{\boldsymbol{\beta}}\{\underline{\beta}_i < \beta_i < \bar{\beta}_i, i = 1, 2, \dots, m\} \geq Q = 1 - \alpha;$$

$$(\underline{\beta}_i; \bar{\beta}_i) = (\hat{\beta}_i - s \sqrt{b_{ii}} \sqrt{m F_\alpha(m, n-m)}, \hat{\beta}_i + s \sqrt{b_{ii}} \sqrt{m F_\alpha(m, n-m)}).$$

b) Tegu A_i įvykis, kad intervalas $(\underline{\beta}_i; \bar{\beta}_i)$, surastas **II.1.20** pratime, uždengia parametrą β_i ir tegu $\mathbf{P}\{A_i\} = 1 - \alpha_i$. Tada

$$\mathbf{P}\left\{\bigcap_{i=1}^m A_i\right\} = 1 - \mathbf{P}\left\{\bigcup_{i=1}^m \bar{A}_i\right\} \geq 1 - \sum_{i=1}^m \mathbf{P}\{\bar{A}_i\} = 1 - (\alpha_1 + \dots + \alpha_m).$$

Jeigu parinksime $\alpha_i = \alpha/m, i = 1, \dots, m$, tai intervalų rinkinys

$$(\underline{\beta}'_i; \bar{\beta}'_i) = (\hat{\beta}_i - s \sqrt{b_{ii}} t_{\alpha/(2m)}(n-m), \hat{\beta}_i + s \sqrt{b_{ii}} t_{\alpha/(2m)}(n-m))$$

uždengs visus parametrus β_i su tikimybe, ne mažesne už $Q = 1 - \alpha$.

II.1.23. Plano matrica $\mathbf{A}^T = (1, 1, \dots, 1)$, $\hat{\mu} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{X} = \bar{X}$; $SS_E = \sum_i (X_i - \bar{X})^2 / \sigma^2 \sim \chi^2_{n-1}$.

II.1.24. Tegu $\mathbf{Z} = (X_1, \dots, X_n, Y_1, \dots, Y_m)^T$. Tada $\mathbf{Z} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}$, $\boldsymbol{\beta} = (\mu_1, \mu_2)^T$; $\mathbf{E}(\mathbf{e}) = 0$, $\mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I}$. Plano matrica \mathbf{A} turi $n+m$ eilučių ir du stulpelius; pirmosios

n eilučių turi pavidalą (1, 0), o likusios turi pavidalą (0, 1). Parametru β MK įvertinys $\hat{\beta} = (\hat{\mu}_1, \hat{\mu}_2)^T$; $\hat{\mu}_1 = \bar{X}$, $\hat{\mu}_2 = \bar{Y}$.

$$\text{II.1.25. } SS_E/\sigma^2 = [\sum_i(X_i - \bar{X})^2 + \sum_j(Y_j - \bar{Y})^2]/\sigma^2 \sim \chi^2_{n+m-2}.$$

$$\text{II.1.26. } \text{Tikrinama hipotezė } H : \mathbf{H}\beta = \mathbf{0}; \text{ čia } \mathbf{H} = (1, -1). \quad SS_{EH} = \sum_i(X_i - \bar{Z})^2 + \sum_j(Y_j - \bar{Z})^2, \bar{Z} = (n\bar{X} + m\bar{Y})/(m+n); \quad SS_{EH} - SS_E = mn(\bar{X} - \bar{Y})^2/(m+n).$$

$$\text{II.1.27. } SS_E = \sum_i(Y_i - \tilde{\alpha} - \tilde{\beta}x_i - \tilde{\gamma}x_i^2)^2, \quad SS_{EH} = \sum_i(Y_i - \hat{\alpha} - \hat{\beta}x_i)^2. \text{ Hipotezė atmetama reikšmingumo lygmens } \alpha \text{ kriterijumi, kai } (SS_{EH} - SS_E)(n-3)/SS_E > F_\alpha(1, n-3).$$

II.1.28. Remdamiesi **II.1.20** pratimu gauname

$$\begin{aligned} (\underline{\sigma^2}; \bar{\sigma^2}) &= (0, 0005; 2, 5456); \quad (\underline{\alpha}; \bar{\alpha}) = (0, 7323; 1, 3677); \\ (\underline{\beta_1}; \bar{\beta_1}) &= (1, 6323; 2, 2677); \quad (\underline{\beta_2}; \bar{\beta_2}) = (2, 4758; 3, 3742). \end{aligned}$$

II.1.29. Gauname intervalus

$$\text{a) } (\underline{\alpha}; \bar{\alpha}) = (0, 4140; 1, 6860); \quad (\underline{\beta_1}; \bar{\beta_1}) = (1, 3140; 2, 5860); \quad (\underline{\beta_2}; \bar{\beta_2}) = (2, 0256; 3, 8244).$$

$$\text{b) } (\underline{\alpha}; \bar{\alpha}) = (0, 0953; 2, 0047); \quad (\underline{\beta_1}; \bar{\beta_1}) = (0, 9953; 2, 9047); \quad (\underline{\beta_2}; \bar{\beta_2}) = (1, 5748; 4, 2752).$$

Intervalai gerokai platesni už **II.1.28** pratimo intervalus.

II.1.30. Kai $m = 2$, atitinkamai 1,0905 ir 1,0919 kartų; kai $m = 5$, atitinkamai 1,2925 ir 1,2930 kartų; kai $m = 10$, atitinkamai 1,5328 ir 1,5296 kartų.

II.1.31. a) Parametru θ įvertinys ir jo kovariacijų matrica surasti **II.1.8** pratime

$$\hat{\theta} = \begin{pmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{pmatrix} = \begin{pmatrix} 2\hat{\alpha} - \hat{\beta}_1 \\ \hat{\alpha} + \hat{\beta}_1 - \hat{\beta}_2 \end{pmatrix}, \quad V(\hat{\theta}) = \frac{\sigma^2}{4} \begin{pmatrix} 5 & 2 \\ 2 & 2 \end{pmatrix} = \sigma^2 \Sigma.$$

Remiantis **II.1.21** pratimu lygmens $Q = 0, 95$ pasiklivimo sritis

$$\begin{aligned} C(\hat{\theta}, s^2) &= \{\theta : (\hat{\theta} - \theta)^T \Sigma^{-1} (\hat{\theta} - \theta)/(2s^2) < F_{0,05}(2, 1)\} = \\ &\{ \theta : 2(\hat{\theta}_1 - \theta_1)^2 - 4(\hat{\theta}_1 - \theta_1)(\hat{\theta}_2 - \theta_2) + 5(\hat{\theta}_2 - \theta_2)^2 < 1,496 \}. \end{aligned}$$

b) Hipotezė atmetama, kai

$$F = \hat{\theta}^T \Sigma^{-1} \hat{\theta} / (2s^2) > F_{0,05}(2, 1) = 199,5.$$

Kadangi statistika F įgijo reikšmę 0,75, tai atmesti hipotezę nėra pagrindo.

II.1.32. Tikrinama hipotezė $H : \mathbf{H}\beta = \theta = \theta_0$; čia matricos \mathbf{H} pirmoji eilutė (1, 1, 0, 0), o antroji eilutė (0, 0, 1, 1); $\theta_0 = (90, 90)^T$. Randame

$$V(\theta) = \sigma^2 \Sigma = \sigma^2 \frac{2}{15} \begin{pmatrix} 4 & -1 \\ -1 & 4 \end{pmatrix}, \quad \Sigma^{-1} = \frac{1}{2} \begin{pmatrix} 4 & 1 \\ 1 & 4 \end{pmatrix}.$$

Hipotezė atmetama reikšmingumo lygmens $\alpha = 0, 05$ kriterijumi, kai

$$F = \frac{(\hat{\theta} - \theta_0)^T \Sigma^{-1} (\hat{\theta} - \theta_0)}{2s^2} > F_{0,05}(2, 4).$$

Kadangi statistika F įgijo reikšmę 84,96, o $F_{0,05}(2, 4) = 6,9443$, tai hipotezė atmetama; P reikšmė $p_v = \mathbf{P}\{F_{2,4} > 84,96\} = 0,0005$.

II.1.33. a) $\mathbf{V}(\hat{\beta}) = \sigma^2(\mathbf{A}^T \mathbf{A})^{-1}$. Pažymėkime matricos $(\mathbf{A}^T \mathbf{A})^{-1}$ elementus a^{ij} , Tada $\mathbf{V}\hat{\beta}_i = \sigma^2 a^{ii}$. Tegu

$$\mathbf{A}^T \mathbf{A} = \begin{pmatrix} a_{11} & \mathbf{b}^T \\ \mathbf{b} & \mathbf{C} \end{pmatrix}, \quad a^{11} = \frac{|\mathbf{C}|}{|\mathbf{A}^T \mathbf{A}|} = \frac{|\mathbf{C}|}{|\mathbf{C}|(a_{11} - \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b})} \geq \frac{1}{a_{11}}.$$

$$\mathbf{V}\hat{\beta}_i \geq \frac{\sigma^2}{a_{ii}}, \quad i = 1, \dots, m.$$

b) Išplaukia iš p. a).

II.1.34. Žr. **II.1.33** pratimą.

II.1.35. Keturis kartus.

II.1.36. a) Pagal pirmo eksperimento rezultatus parametrujų iverčiai: $\bar{\beta}_1 = (Y_1 + Y_2 + Y_3 + Y_4)/4 = 9,975$, $\bar{\beta}_2 = (Y_1 - Y_2 + Y_3 - Y_4)/4 = 4,975$, $\bar{\beta}_3 = (Y_1 + Y_2 - Y_3 - Y_4)/4 = 4,175$, $\bar{\beta}_4 = (Y_1 - Y_2 - Y_3 + Y_4)/4 = 1,075$. Analogiskai pagal antro eksperimento rezultatus: $\bar{\beta}_1 = 10,050$, $\bar{\beta}_2 = 5,000$, $\bar{\beta}_3 = 4,050$, $\bar{\beta}_4 = 0,800$; negalima.

b) $\bar{\beta}_1 = 10,0125$, $\bar{\beta}_2 = 4,9875$, $\bar{\beta}_3 = 4,1125$, $\bar{\beta}_4 = 0,9375$, $\hat{\sigma}^2 = s^2 = 0,04875$; keturis kartus;

c) $\mathbf{V}(\hat{\sigma}^2) = 2\sigma^4/8$; taikant pirmajį būdą reikėtų 32 svērimų.

II.1.37. Parinkime kvadratinę matricą \mathbf{B} , kad $\Lambda = \mathbf{B}\mathbf{B}^T$, ir atlikime transformaciją $\mathbf{Z} = \mathbf{B}^{-1}\mathbf{Y}$. Tada a.v. \mathbf{Z} tenkina tiesinį modelį: $\mathbf{Z} = \mathbf{C}\beta + \theta$; čia $\mathbf{C} = \mathbf{B}^{-1}\mathbf{A}$, o $\mathbf{V}(\theta) = \sigma^2 \mathbf{I}$. Gauname $\hat{\beta} = (\mathbf{C}^T \mathbf{C})^{-1} \mathbf{C}^T \mathbf{Z} = (\mathbf{A}^T \Lambda^{-1} \mathbf{A})^{-1} \mathbf{A}^T \Lambda^{-1} \mathbf{Y}$, $\mathbf{V}(\hat{\beta}) = \sigma^2 (\mathbf{C}^T \mathbf{C})^{-1} = \sigma^2 (\mathbf{A}^T \Lambda^{-1} \mathbf{A})^{-1}$.

II.1.38. **II.1.37** pratime reikia imti $\Lambda = [\lambda_{ij}]_{n \times n}$; $\lambda_{ii} = 1/\omega_i$, $\lambda_{ij} = 0, i \neq j$. Gauname $\hat{\theta} = \sum_i (\omega_i Y_i) / \sum_i \omega_i$, $\mathbf{V}(\hat{\theta}) = \sigma^2 / \sum_i \omega_i$.

II.1.39. **II.1.37** pratime reikia imti $\Lambda = [\lambda_{ij}]_{n \times n}$; $\lambda_{ii} = i^2$, $\lambda_{ij} = 0, i \neq j$; $\mathbf{A}^T = (1, 2, \dots, n)$. Gauname $\hat{\theta} = [\sum_i (Y_i/i)]/n$, $\mathbf{V}(\hat{\theta}) = \sigma^2/n$.

II.1.40. $\hat{\beta} \sim N_m(\beta, \sigma^2(\mathbf{A}^T \Lambda^{-1} \mathbf{A})^{-1})$, $\hat{\sigma}^2 = s^2 = SS_E/(n-m)$, $SS_E = (\mathbf{B}^{-1})^T (\mathbf{Y} - \mathbf{A}\hat{\beta})^T (\mathbf{Y} - \mathbf{A}\hat{\beta}) \mathbf{B}^{-1} \sim \sigma^2 \chi_{n-m}^2$.

II.1.41. a) $\hat{d} = [\sum_i (X_i Y_i)] / \sum_i X_i^2$; b) $\hat{d} = (\sum_i Y_i) / \sum_i X_i$; c) $\hat{d} = [\sum_i (Y_i / X_i)]/n$.

II.1.42. $\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$, $\hat{\beta}_1 = \sum_i Y_i (X_i - \bar{X}) / \sum_i (X_i - \bar{X})^2$; $\mathbf{V}\hat{\beta}_1 = \sigma^2 (1 - \rho) / \sum_i (X_i - \bar{X})^2$, $\mathbf{V}\hat{\beta}_0 = \sigma^2 [(1 + 2\rho)/3 + \bar{X}^2 (1 - \rho) / \sum_i (X_i - \bar{X})^2]$. Nagrinėkime tiesinį modelį $Y_i = \alpha + \beta_1 (X_i - \bar{X}) + e_i$, $i = 1, 2, 3$; $\alpha = \beta_0 + \beta_1 \bar{X}$. Tada

$$[\mathbf{A}^T \Lambda^{-1} \mathbf{A}]^{-1} = \begin{pmatrix} (1 + 2\rho)/3 & 0 \\ 0 & (1 - \rho) / \sum_i (X_i - \bar{X})^2 \end{pmatrix},$$

$$\mathbf{A}^T \Lambda^{-1} \mathbf{Y} = \begin{pmatrix} \sum_i Y_i / (1 + 2\rho) \\ \sum_i Y_i (X_i - \bar{X}) / (1 - \rho) \end{pmatrix}$$

ir lieka pasinaudoti **II.1.37** pratimo sprendimu.

II.1.43. Atlikime ortogonalią transformaciją $\mathbf{Z} = \mathbf{CY}$, kai matricos \mathbf{C} pirmoji eilutė yra $(1/n, \dots, 1/n)$. Tada iš ortogonalumo sąlygos

$$\sum_{j=1}^n c_{ij}c_{1j} = \sum_{j=1}^n c_{ij}/n = 0, \quad i = 2, 3, \dots, n.$$

Tarkime, \mathbf{B} yra matrica \mathbf{C} be pirmosios eilutės. Tada a. v. $\mathbf{Z}_2 = (Z_2, \dots, Z_n)^T = \mathbf{BY}$ kovariacinė matrica

$$\mathbf{V}(\mathbf{BY}) = \mathbf{B}\Sigma\mathbf{B}^T = \rho\sigma^2\mathbf{BEB}^T + (1 - \rho)\sigma^2\mathbf{BIB}^T,$$

čia \mathbf{E} – matrica, kurios visi elementai lygūs 1. Gauname, kad pirmasis dėmuo lygus 0, nes $\mathbf{BE} = \mathbf{0}$. Taigi a. v. \mathbf{Z}_2 kovariacinė matrica yra diagonali $\mathbf{V}(\mathbf{Z}_2) = (1 - \rho)\sigma^2\mathbf{I}$.

II.1.44. a) Pradžioje tarkime, kad $\boldsymbol{\gamma}$ yra žinomas. Gauname tiesinį modelį

$$\mathbf{Y} - \mathbf{B}\boldsymbol{\gamma} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}.$$

Iš čia parametru $\boldsymbol{\beta}$ mažiausiuju kvadratų įvertinys

$$\tilde{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T (\mathbf{Y} - \mathbf{B}\boldsymbol{\gamma}).$$

Įrašę šį įvertinį į pradinę išraišką ir pažymėję $\mathbf{R} = \mathbf{I} - \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$, gausime tiesinį modelį parametru $\boldsymbol{\gamma}$ atžvilgiu

$$\mathbf{RY} = \mathbf{RB}\boldsymbol{\gamma} + \mathbf{e}.$$

Parametru $\boldsymbol{\gamma}$ mažiausiuju kvadratų įvertinys

$$\boldsymbol{\gamma}^* = (\mathbf{B}^T \mathbf{R}^T \mathbf{RB})^{-1} \mathbf{B}^T \mathbf{R}^T \mathbf{RY} = (\mathbf{B}^T \mathbf{RB})^{-1} \mathbf{B}^T \mathbf{RY}.$$

Įrašę į $\tilde{\boldsymbol{\beta}}$ išraišką, gauname parametru $\boldsymbol{\beta}$ įvertinį

$$\boldsymbol{\beta}^* = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T (\mathbf{Y} - \mathbf{B}\boldsymbol{\gamma}^*).$$

b) Liekamoji kvadratų suma

$$SS_E = (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta}^* - \mathbf{B}\boldsymbol{\gamma}^*)^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta}^* - \mathbf{B}\boldsymbol{\gamma}^*) = (\mathbf{Y} - \mathbf{B}\boldsymbol{\gamma}^*)^T \mathbf{R} (\mathbf{Y} - \mathbf{B}\boldsymbol{\gamma}^*).$$

II.2. Dispersinė analizė

II.2.1. Vienfaktorių dispersinė analizė

II.2.1. Tarkime, a. d. Y skirstinys gali priklausyti nuo faktoriaus A , kuris gali būti I lygmenų A_1, A_2, \dots, A_I . Tegu a. d. Y skirstinys, kai faktoriaus A lygmuo yra A_i , yra normalusis $N(\mu_i, \sigma^2)$. Tarkime, kad turime I paprastųjų nepriklausomų imčių; i -ają imtį sudaro J_i elementų $Y_{i1}, Y_{i2}, \dots, Y_{iJ_i}$, gautų, kai faktoriaus A lygmuo yra A_i , $i = 1, \dots, I$.

a) Užrašykite jungtinę imtį \mathbf{Y} tiesinio modelio pavidalu (žr. **II.1.1** pratimą).

b) Įrodykite, kad $\mathbf{T} = (\bar{Y}_1, \dots, \bar{Y}_I, \mathbf{Y}^T \mathbf{Y})^T$, $\bar{Y}_i = \sum_j Y_{ij}/J_i$, yra pilnoji ir pakanka-moji parametru $\boldsymbol{\theta} = (\mu_1, \dots, \mu_I, \sigma^2)$ statistika. c) Raskite parametru $\boldsymbol{\theta}$ elementų NMD įvertinius.

II.2.2. (II.2.1 pratimo tēsinys). Raskite parametru

$$\mu = \frac{1}{n} \sum_{i=1}^I J_i \mu_i, \quad n = J_1 + \dots + J_I, \quad \alpha_i = \mu_i - \mu, \quad i = 1, \dots, I$$

NMD įvertinius.

II.2.3. (II.2.1 pratimo tēsinys). Pagrindinė dispersinės analizės hipotezė yra patikrinti, ar priklauso Y skirstinys nuo faktoriaus A . Modelio parametru terminais reikia patikrinti hipotezę $H_A : \mu_1 = \dots = \mu_I$ (arba $H_A : \alpha_1 = \dots = \alpha_I = 0$). Raskite kriterijų hipotezei H_A tikrinti.

- II.2.4.** (II.2.3 pratimo tēsinys). a) Raskite vidutinių kvadratų sumų vidurkius.
b) Raskite II.2.3 pratime pateikto kriterijaus galia.

II.2.5. (II.2.3 pratimo tēsinys). Jeigu hipotezė H_A neatmetama, tai analizę galima tuo ir užbaigti. Priešingu atveju natūraliai iškyla klausimas, kaip stebėjimai Y_{ij} priklauso nuo faktoriaus A lygmenų. Kartais remiantis papildoma informacija apie faktoriaus lygmenis galima juos sudalinti į grupes taip, kad hipotezės H_A atmetimą salygotų skirtumai tarp grupių, o grupių viduje vidurkiai skirtūsi nežymiai. Raskite kriterijų hipotezei $H'_A : \mu_1 = \dots = \mu_r; \mu_{r+1} = \dots = \mu_I$ tikrinti.

II.2.6. (II.2.5 pratimo tēsinys). Jeigu papildomos informacijos apie faktoriaus lygmenis nepakanka, tai galima taikyti statistinius stebėjimų palyginimo metodus esant įvairiems faktoriaus lygmenims, vadinaus kontrastų analize. Parametru μ_1, \dots, μ_I *kontrastu* vadinama tiesinė funkcija

$$\psi = \sum_{i=1}^I c_i \mu_i, \quad \sum_{i=1}^I c_i = 0, \quad c_i \in \mathbf{R}, \quad i = 1, \dots, I.$$

Hipotezė $H_A : \mu_1 = \dots = \mu_I$ ekvivalenti tvirtinimui, kad visi kontrastai ψ lygūs nuliui. Jei H_A neteisinga, tai atsiras kontrastų, kurie nelygūs nuliui.

Įrodykite, kad hipotezė H_A atmetama reikšmingumo lygmens α kriterijumi (II.2.3 pratimas) tada ir tik tada, kai egzistuoja kontrastas ψ , kad intervalas

$$(\hat{\psi} - \sqrt{(I-1)F_\alpha}(I-1, n-I)\sqrt{\hat{V}(\hat{\psi})}, \hat{\psi} + \sqrt{(I-1)F_\alpha}(I-1, n-I)\sqrt{\hat{V}(\hat{\psi})})$$

neuždengia 0; čia

$$\hat{\psi} = \sum_{i=1}^I c_i \hat{\mu}_i = \sum_{i=1}^I c_i \bar{Y}_{i..}, \quad \mathbf{V}(\hat{\psi}) = \sigma^2 \sum_{i=1}^I c_i^2 / J_i, \quad \hat{V}(\hat{\psi}) = s^2 \sum_{i=1}^I c_i^2 / J_i.$$

II.2.7. Tegu $Y_{ij} = \mu + \alpha_i + e_{ij}$, $i = 1, \dots, I$, $j = 1, \dots, J$; čia e_{ij} yra vienodai pasiskirstę n. a. d. ir $\mathbf{E}(e_{ij}) = 0$, o parametrai α_i tenkina sąlygą $\sum_i d_i \alpha_i = 0$, kai d_i žinomi ir $\sum_i d_i \neq 0$. Raskite parametru μ ir α_i mažiausiuju kvadratų įvertinius.

II.2.8. Tegu $Y_{ij} = \mu_i + e_{ij}$, $i = 1, \dots, I$, $j = 1, \dots, J$; čia e_{ij} yra nepriklausomi ir normalieji $e_{ij} \sim N(0, \sigma^2)$. a) Raskite hipotezés $H : \mu_1 = 2\mu_2 = 3\mu_3$ tikrinimo kriterijų, kai $I = 4$. b) Įrodykite, kad hipotezés $H : \mu_1 = \mu_2$ tikrinimo F kriterijus, kai $I = 2$, yra ekvivalentus Stjudento kriterijui dėl vidurkių lygibės dviųose normaliosiose imtyse.

II.2.9. Lentelėje pateikti duomenys, apibūdinantys iškvepiamo azoto kiekį Y esant keturioms skirtingoms dietoms (faktoriaus A lygmenys).

A_1	A_2	A_3	A_4
4,079	4,368	4,169	4,928
4,859	5,668	5,709	5,608
3,540	3,752	4,416	4,940
5,047	5,848	5,666	5,291
3,298	3,802	4,123	4,674

A_1	A_2	A_3	A_4
4,679	4,844	5,059	5,038
2,870	3,578	4,403	4,905
4,648	5,393	4,496	5,208
3,847	4,374	4,688	4,806

Atlikite duomenų vienfaktorių dispersinę analizę.

II.2.10. Iš darbininkų, aptarnaujančių didelės įmonės surinkimo konvejerį, buvo atrinkti 4 darbininkai ir kiekvienam iš jų buvo užfiksuotas tam tikros detalės surinkimo laikas.

Darbininkai	Laikas					
	1	2	3	4	5	6
1	24,2;	22,2;	24,5;	21,1;	22,0;	
2	19,4;	21,1;	16,2;	21,2;	21,6;	17,8;
3	19,0;	23,1;	23,8;	22,8;		19,6;
4	19,9;	15,7;	15,2;	19,8;	18,9;	16,1;
					16,2;	18,5

Ar skiriasi darbininkai pagal detales surinkimo laiką?

II.2.11. Lentelėje pateikti duomenys, apibūdinantys gumos tempiamajį atsparumą $Y \text{kg/cm}^2$ priklausomai nuo vulkanizavimo laiko $X \text{ min}$.

X_i	Y_{ij}			
20	152	152	147	152
25	158	155	146	169
30	149	159	115	152
40	143	121	116	156
60	126	165	153	157

Patikrinkite hipotezę, kad gumos tempiamojos atsparumo vidurkis nepriklauso nuo vulkanizavimo laiko.

II.2.12. Tiriant retujų elementų pasiskirstymą triaso amžiaus nuogulose netoli Birštono, buvo gauti lentelėje pateikti rezultatai (g/t) trijuose šių nuogulų horizontuose (\bar{X} ir s empiriniai vidurkiai ir vidutinio kvadratinio nuokrypio įvertiniai; stebėjimų skaičius atitinkamai I, II ir III horizontuose yra 136, 77, 111). Patikrinkite hipoteses, kad elementų koncentracija visuose trijuose horizontuose yra vienoda.

Elementai	I		II		III	
	\bar{X}	s	\bar{X}	s	\bar{X}	s
Varis	43	12	47	12	44	22
Švinas	13	4	16	5	22	8
Titanas	3428	701	3531	776	4255	1071
Manganas	940	182	1022	146	828	296
Chromas	74	21	84	22	110	64
Nikelis	44	13	55	16	60	22

II.2.13. Tarkime, iš pagamintos produkcijos atsitiktinai atrinkta I gaminių. Kiek-

vienam iš jų su paklaida J kartų matuojama tam tikro požymio X reikšmė. Tarkime, kad požymio ir paklaidos skirstiniai yra nepriklausomi normalieji a. d. Paklaidos vidurkis lygus nuliui. Reikia įvertinti požymio parametrus (vidurkį ir dispersiją). Parinkite tinkamą statistinį modelį.

II.2.14. Nagrinėjamas vienfaktorių dispersinės analizės modelis su atsitiktiniu faktoriumi

$$Y_{ij} = \mu + a_i + e_{ij}, \quad i = 1, \dots, I, \quad j = 1, \dots, J;$$

paklaidos $e_{ij} \sim N(0, \sigma^2)$, a. d. $a_i \sim N(0, \sigma_A^2)$ ir a. d. $\{a_i\}, \{e_{ij}\}$ nepriklausomi. Irodykite, kad parametru $\boldsymbol{\theta} = (\mu, \sigma_A^2, \sigma^2)^T$ pilnoji ir pakankamoji statistika yra

$$\mathbf{T} = (\bar{Y}_{..}, \sum_i \bar{Y}_{i..}^2, \sum_i \sum_j Y_{ij}^2)^T.$$

II.2.15. (**II.2.14** pratimo tēsinys). Raskite parametru $\mu, \tau^2 = \sigma^2 + J\sigma_A^2, \sigma_A^2, \sigma^2$ NMD įvertinius.

II.2.16. (**II.2.14** pratimo tēsinys). Irodykite, kad a. d. $\bar{Y}_{..}, SS_A, SS_E$ yra nepriklausomi.

II.2.17. (**II.2.14** pratimo tēsinys). Raskite parametru $\mu, \tau^2, \sigma^2, \sigma_A^2$ pasiklovimo intervalus ir sudarykite kriterijus hipotezėms dėl šių parametru reikšmių tikrinti.

II.2.18. (**II.2.14** pratimo tēsinys). Raskite pagrindinės dispersinės analizės hipotezės šioje schemae analogo $H_A : \sigma^2 = 0$ tikrinimo kriterijų ir jo galios funkciją.

II.2.19. Atsitiktinai parinkus keturis gaminius po 10 kartų buvo išmatuotas jų požymis X :

x_1	x_2	x_3	x_4	x_1	x_2	x_3	x_4
6,34	5,95	5,23	4,55	6,85	6,52	5,52	4,73
6,36	6,04	5,27	4,65	6,91	6,60	5,52	4,78
6,41	6,11	5,32	4,68	6,91	6,62	5,53	4,78
6,42	6,31	5,39	4,68	7,02	6,64	5,60	4,84
6,80	6,36	5,40	4,72	7,12	6,71	5,78	4,86

a) atlikite vienfaktorių dispersinę analizę su vienu atsitiktiniu faktoriumi A (jo lygmenys – gaminiai numeriai);

b) raskite taškinius ir intervalinius ($Q = 0,95$) parametru $\mu, \sigma_A^2, \sigma^2$ įverčius;

c) raskite parametru σ_A^2/σ^2 pasiklovimo intervalą ($Q = 0,95$).

II.2.20. Konservų fabriko technologiniame procese kiekvienas pjaustantis abrikosus operatorius buvo stebimas penkis dviejų minučių laikotarpius. Trijose skirtingose linijose buvo pjaustomi trijų skirtingu dydžiu vaisiai (didesnis numeris reiškia mažesnį vaisių) ir užfilksuojamas supjaustyti vaisių skaičius Y_{ij} ; $i = 1, \dots, I$ yra operatoriaus numeris, o $j = 1, \dots, 5$ žymi laikotarpio numerį. Analizės rezultatai atskirai kiekvieno dydžio vaisiams pateikti lentelėje.

Dydis	I	$Y_{..}$	MS_A	MS_E
2	9	53,17	59,72	1,144
3	17	52,26	68,20	2,537
4	17	47,32	78,96	4,926

Tardami, kad yra teisingas modelis $Y_{ij} = \mu + a_i + e_{ij}$, kai a. d. $\{a_i\}$ ir $\{e_{ij}\}$ yra nepriklausomi ir normalieji $a_i \sim N(0, \sigma_A^2)$, $e_{ij} \sim N(0, \sigma^2)$, raskite taškinius parametru $\mu, \sigma_A^2, \sigma^2$ įverčius.

II.2.21. Tarkime, kad **II.2.3** pratime faktorius A yra atsitiktinis. Kaip pasikeis dispersinė analizė?

II.2.2. Dvifaktorė dispersinė analizė

II.2.22. Tiriamas požymio Y priklausomybė nuo faktoriaus A , kuris yra I lygmenų A_1, \dots, A_I , ir faktoriaus B , kuris yra J lygmenų B_1, \dots, B_J . Kiekvienam lygmenų dariniui (A_i, B_j) stebėjimai pakartojami po $K > 1$ kartų. Imties elementai aprašomi dvifaktorės dispersinės analizės modeliu

$$Y_{ijk} = \mu_{ij} + e_{ijk}, \quad i = 1, \dots, I, \quad j = 1, \dots, J, \quad k = 1, \dots, K.$$

Tarsime, kad paklaidos e_{ijk} nepriklausomos ir $e_{ijk} \sim N(0, \sigma^2)$. Modelis visiškai nusakytas IJ parametrais $\mu_{11}, \dots, \mu_{IJ}$ ir dispersija $\sigma^2 = \mathbf{V}(Y_{ijk}) = \mathbf{V}(e_{ijk})$. a) Irodykite, kad $\mathbf{T} = (\bar{Y}_{11}, \dots, \bar{Y}_{IJ}, \sum_i \sum_j \sum_k Y_{ijk}^2)^T$ yra parametru $\boldsymbol{\theta} = (\mu_{11}, \dots, \mu_{IJ}, \sigma^2)^T$ pilnoji ir pakankamoji statistika. b) Raskite parametru $\boldsymbol{\theta}$ elementų NMD įvertinius.

II.2.23. (**II.2.22** pratimo tēsinys). Raskite parametru

$$\mu, \quad \alpha_i = \bar{\mu}_i - \mu, \quad \beta_j = \bar{\mu}_j - \mu, \quad \gamma_{ij} = \mu_{ij} - \bar{\mu}_i - \bar{\mu}_j + \mu;$$

$$\mu = \frac{1}{IJ} \sum_i \sum_j \mu_{ij}, \quad \bar{\mu}_i = \frac{1}{J} \sum_j \mu_{ij}, \quad \bar{\mu}_j = \frac{1}{I} \sum_i \mu_{ij};$$

NMD įvertinius.

II.2.24. (**II.2.22** pratimo tēsinys). Raskite kriterijus pagrindinėms dispersinės analizės hipotezėms $H_A : \alpha_i \equiv 0$, $H_B : \beta_j \equiv 0$, $H_{AB} : \gamma_{ij} \equiv 0$ tikrinti.

II.2.25. (**II.2.24** pratimo tēsinys). a) Irodykite, kad kvadratų sumos SS_A, SS_B, SS_{AB} ne tik nepriklauso nuo SS_E (remiantis **II.2.21** pratimu), bet nepriklausomos ir tarpusavyje bei nepriklauso nuo $\bar{Y}_{...}$ b) Irodykite, kad kvadratų sumas galima skaičiuoti tokiu būdu: reikia pakelti kiekvieną daugianarių dėmenų kvadratų paliekant buvusius ženklus ir susumuoti. Pavyzdžiui, $SS_{AB} = K \sum_i \sum_j \sum_k \bar{Y}_{ij}^2 - JK \sum_i \bar{Y}_{..} - IK \bar{Y}_{..} + IJK \bar{Y}_{...}^2$. c) Patikrinkite lygybę $SS_T = SS_A + SS_B + SS_{AB} + SS_E$, čia $SS_T = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{...})^2$.

II.2.26. (**II.2.24** pratimo tēsinys). a) Raskite vidutinių kvadratų sumų vidurkius. b) Raskite **II.2.24** pratime pateiktų kriterijų galios funkcijas.

II.2.27. Tarkime, kad dvifaktorės dispersinės analizės schemaje turime po vieną stebėjimą langelyje, t. y. $K = 1$. Tada stebėjimų Y_{ij} skaičius $n = IJ$ lygus nežinomų parametru μ_{ij} skaičiui ir liekamoji kvadratų suma $SS_E = 0$. Parametru skaičius sumažinamas tariant, kad tarp faktorių nėra sąveikos, t. y. $\gamma_{ij} \equiv 0$. Gauname adityvųjį modelį

$$Y_{ij} = \mu + \alpha_i + \beta_j + e_{ij}, \quad i = 1, \dots, I, \quad j = 1, \dots, J.$$

Tarsime, kad paklaidos e_{ij} nepriklausomos ir $e_{ij} \sim N(0, \sigma^2)$, o parametrai α_i, β_j tenkina sąlygas

$$\sum_i \alpha_i = 0, \quad \sum_j \beta_j = 0.$$

Modelį visiškai nusako $I + J - 1$ parametras $\mu, \alpha_1, \dots, \alpha_{I-1}, \beta_1, \dots, \beta_{J-1}$ ir dispersija σ^2 .

- a) Raskite parametru α_i, β_j mažiausiuju kvadratų įvertinius ir liekamąjų kvadratų sumą.
 b) Irodykite, kad gautieji įvertiniai yra NMD įvertiniai.

II.2.28. (II.2.27 pratimo tēsinys). Raskite kriterijus faktorių įtakos nebuvinimo hipotezėms $H_A : \alpha_i = 0, H_B : \beta_j = 0$ tikrinti.

II.2.29. (Tjukio kriterijus). II.2.28 pratime pateikti kriterijai nėra korektiški, jeigu prielaida $\gamma_{ij} \equiv 0$ nėra teisinga. Sudarykite kriterijų dėl prielaidos $\gamma_{ij} \equiv 0$ teisingumo remdamiesi stebėjimais, kai $K = 1$, o sąveika tenkina sąlygą $\gamma_{ij} = \gamma \alpha_i \beta_j$, t. y. patikrinkite parametrinę hipotezę $H_\gamma : \gamma = 0$.

II.2.30. Tegu dvifaktorės dispersinės analizės schemaje faktoriaus A lygmenų skaičius $I = 2$, o faktoriaus B lygmenų skaičius $J \geq 2$; kiekviename langelyje turime po vieną stebėjimą $Y_{ij}, i = 1, 2; j = 1, \dots, J$. Irodykite, kad hipotezės H_A tikrinimo F kriterijus yra ekvivalentus Stjudento kriterijui, grindžiamam skirtumais $Z_j = Y_{1j} - Y_{2j}, j = 1, \dots, J$. Todėl dispersinės analizės prielaidos gali būti susilpnintos: kriterijus nepakis, jeigu tarime, kad paklaidų vektoriai $(e_{1j}, e_{2j})^T, j = 1, \dots, J$ yra nepriklausomi ir turi dvimatį normalųjį skirstinį su nulinio vidurkių vektoriumi.

II.2.31 (II.2.30 pratimo tēsinys). Lentelėje pateikti miego trukmės pakitimo duomenys Y_{1j} , naudojant pirmo tipo migdomuosius vaistus, ir Y_{2j} – naudojant antro tipo migdomuosius vaistus; čia j žymi paciento numerį, $j = 1, \dots, 10$.

$i; j$	1	2	3	4	5	6	7	8	9	10
1	+0,7	-1,6	-0,2	-1,2	-1,0	+3,4	+3,7	+0,8	0,0	+2,0
2	+1,9	+0,8	+1,1	+0,1	-0,1	+4,4	+5,5	+1,6	+4,6	+3,4

a) Priėmę normalumo prielaidą patikrinkite hipotezę, kad miego trukmės padidėjimo vidurkiai, naudojant pirmo ir antro tipo migdomuosius, nesiskiria; $\alpha = 0,01$.

b) Tarkime, yra žinoma, kad $V(Y_{1j} - Y_{2j}) \leq 1,25$. Kokį skaičių pacientų reikėtų turėti, kad, tikrinant vidurkių lygybės hipotezę, ji būtų atmesta su tikimybe, ne mažesne už 0,95, kai miego trukmės padidėjimo vidurkių skirtumas viršija 1 valandą.

II.2.32. Tarkime, kad II.2.9 pratime tiriami iškvepiamo azoto kieko priklausomybę ne tik nuo dietos (faktorius A), bet ir nuo lyties (faktorius B). Gauti stebėjimų duomenys pateikti lentelėje [1].

	A_1	A_2	A_3	A_4
B_1	4,079	4,368	4,169	4,928
	4,859	5,668	5,709	5,608
	3,540	3,752	4,416	4,940
B_2	2,870	3,578	4,403	4,905
	4,648	5,393	4,496	5,208
	3,847	4,374	4,688	4,806

Atlikite dvifaktorė dispersinę analizę. Patikrinkite pagrindines dispersinės analizės hipotezes.

II.2.33. Iš kiekvienos 4 pelių (faktorius A) palikuonių buvo atrinkta po 1 peliuką ir jam buvo taikoma viena iš trijų dietų (faktorius B). Po trijų savaičių išmatuotas svorio prieaugis Y [1].

	A_1	A_2	A_3	A_4
B_1	5,2	11,4	4,2	10,7
B_2	7,4	13,0	9,5	8,8
B_3	9,1	13,8	8,8	13,0

Atlikite dvifaktorių dispersinę analizę su vienu stebėjimu langelyje. Remdamiesi Tjukio kriterijumi patikrinkite sąveikos nebuvimo hipotezę.

II.2.34. Tiriant, kiek aštuonių skirtingų rūšių aliejaus (faktorius A) sugeria spurgos, šešias dienas (faktorius B) buvo gaminamos vienodo didumo spurgų partijos su kiekviena aliejaus rūšimi [16].

	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8
B_1	164	172	177	178	163	163	150	164
B_2	177	197	184	196	177	193	179	169
B_3	168	167	187	177	144	176	146	155
B_4	156	161	169	181	165	172	141	149
B_5	172	180	179	184	166	176	169	170
B_6	196	190	197	191	178	178	183	167

Užpildykite dispersinės analizės lentelę ir patikrinkite pagrindines hipotezes.

II.2.35 (II.2.34 pratimo tēsinys). Tarkime, kad skirtingų aliejaus rūšių sugėrimo vidurkiai tenkina sąlygas $\mu_5 = \mu_7 = \mu_8 = \mu$, $\mu_1 = \mu_2 = \mu_6 = \mu + 12$, $\mu_3 = \mu_4 = \mu + 22$. Kokia tikimybė atmesti hipotezę H_B , jeigu paklaidos dispersija lygi I.2.34 pratime surastam įverčiui (kriterijaus reikšmingumo lygmuo $\alpha = 0,05$)?

II.2.36 (II.2.34 pratimo tēsinys). Kadangi 5, 7 ir 8 aliejaus rūšys atrodo ekonomiški ausios, tai tolesni eksperimentai bus atliekami tik su šiomis trimis rūšimis. Kiek eksperimentų reikėtų atlikti tikrinant hipotezę $H : \mu_5 = \mu_7 = \mu_8$ kriterijumi, kai reikšmingumo lygmuo $\alpha = 0,05$, kad bet kokį vidurkių skirtumą, viršijantį 10 vienetų, galėtume pastebėti su tikimybe, ne mažesne už 0,8?

II.2.37. Tiriamas konservų dėžutės svorio priklausomybė nuo mėsos tiekėjo (faktorius A) ir nuo dėžutes užpildančio automato užpildymo cilindro (faktorius B). Iš kiekvieno tiekėjo ir kiekvieno cilindro konservų dėžučių partijos atsitiktinai atrenkama po 3 dėžutes. Dėžučių svoriai (sąlyginiais vienetais) pateikti lentelėje [16].

	A_1		A_2		A_3		A_4		A_5						
B_1	1	1;	2	4;	3;	5	6;	3;	7	3;	1;	3	1;	3;	3
B_1	-1;	3;	-1	-2;	1;	0	3;	1;	5	2;	0;	1	1;	0;	1
B_3	1;	1;	1	2;	0;	1	2;	4;	3	1;	3;	3	3;	3;	3
B_4	-2;	3;	0	-2;	0;	1	3;	3;	4	0;	0;	2	0;	1;	1
B_5	1;	1;	-1	2;	1;	5	0;	1;	2	1;	0;	-1	-2;	3;	1
B_6	0;	1;	1	0;	0;	3	3;	3;	4	3;	0;	2	3;	1;	2

Užpildykite dispersinės analizės lentelę ir patikrinkite pagrindines hipotezes.

II.2.38. Eksperimente hibridinius žiurkiukus maitino hibridinės žiurkių patelės. Lentelėje pateikti žiurkiukų svoriai praėjus 28 dienoms nuo gimimo. Šiame eksperimente faktorius A yra maitinančios žiurkės genotipas, o faktorius B – žiurkiukų vados genotipas.

	A_1	A_2	A_3	A_4		A_1	A_2	A_3	A_4
B_1	61,5	55,0	52,5	42,0	B_3	37,0	56,3	39,6	50,0
	68,2	42,0	61,8	54,0		36,3	69,8	46,0	43,8
	64,0	60,2	49,5	61,0		68,0	67,0	61,3	54,5
	65,0		52,7	48,2				55,3	
	59,7			39,6				55,7	
B_2	60,3	50,8	56,5	51,3	B_4	59,0	59,5	45,2	44,8
	51,7	64,7	59,0	40,5		57,4	52,8	57,0	51,5
	49,3	61,7	47,2			54,0	56,0	61,4	53,0
	48,0	64,0	53,0					42,0	
		62,0							54,0

Atlikite dvifaktorė dispersinę analizę, kai stebėjimų skaičiai langeliuose skirtini. Patikrinkite sąveikos nebuvimo hipotezę. Patikrinkite faktorių A ir B įtakos nebuvimo hipotezes dviem būdais: a) tariant, kad modelis adityvus; b) neatsižvelgiant į sąveiką.

II.2.39. Irodykite, kad dvifaktorėje dispersinėje analizėje, kai $I = 2$, kvadratų sumas SS_A ir SS_{AB} galima apskaičiuoti šitaip:

$$SS_A = JK(\bar{Y}_{1..} - \bar{Y}_{2..})^2/2,$$

$$SS_{AB} = (K \sum_j (\bar{Y}_{1j.} - \bar{Y}_{2j.})^2 - SS_A)/2,$$

o jei $K = 2$, tai

$$SS_E = \sum_i \sum_j (Y_{ij1} - Y_{ij2})^2/2.$$

II.2.40. Tarkime, kad imties \mathbf{Y} skirtinys gali priklausyti nuo dviejų atsitiktinių faktorių. Imties \mathbf{Y} elementai turi tokią struktūrą (žr. [3], 2.5.1 skyrelį):

$$Y_{ijk} = \mu + a_i + b_j + c_{ij} + e_{ijk}, \quad i = 1, \dots, I, \quad j = 1, \dots, J, \quad k = 1, \dots, K;$$

čia $\{a_i\}, \{b_j\}, \{c_{ij}\}, \{e_{ijk}\}$ yra nepriklausomi a. d. ir $a_i \sim N(0, \sigma_A^2)$, $b_j \sim N(0, \sigma_B^2)$, $c_{ij} \sim N(0, \sigma_{AB}^2)$, $e_{ijk} \sim N(0, \sigma^2)$. Modelį visiškai nusako vidurkis μ ir keturių dispersijos $\sigma_A^2, \sigma_B^2, \sigma_{AB}^2, \sigma^2$. Irodyta (žr. [15], 4f.3 skyrelį), kad parametru $\boldsymbol{\theta} = (\mu, \sigma_A^2, \sigma_B^2, \sigma_{AB}^2, \sigma^2)^T$ pilnoji ir pakankamoji statistika yra $\mathbf{T} = (\bar{Y}_{...}, SS_A, SS_B, SS_{AB}, SS_E)^T$. a) Raskite vidutinių kvadratų sumų vidurkius. b) Raskite parametru $\boldsymbol{\theta}$ elementų NMD ivertinius.

II.2.41. (II.2.40 pratimo tēsinys). a) Irodykite, kad kvadratų sumos $SS_A, SS_B, SS_{AB}, SS_E$ yra nepriklausomos. b) Raskite ivertinių $\hat{\sigma}_A^2, \hat{\sigma}_B^2, \hat{\sigma}_{AB}^2, \hat{\sigma}^2$ dispersijas. c) Sudarykite pagrindinių dispersijos analizės hipotezių analogų $H_A : \sigma_A^2 = 0$, $H_B : \sigma_B^2 = 0$, $H_{AB} : \sigma_{AB}^2 = 0$ tikrinimo kriterijus ir raskite jų galios funkcijas.

II.2.42. Tegu $Y_{ijk} = \mu + a_i + b_j + e_{ijk}$ ir a. d. $\{a_i\}, \{b_j\}, \{e_{ijk}\}$ nepriklausomi, $a_i \sim N(0, \sigma_A^2)$, $b_j \sim N(0, \sigma_B^2)$, $e_{ijk} \sim N(0, \sigma^2)$; $i = 1, \dots, I, j = 1, \dots, J, k = 1, \dots, K$. Parametrai $\mu, \sigma_A^2, \sigma_B^2, \sigma^2$ nežinomi. Raskite TGN kriterijų

- a) hipotezei $H : \tau^2 = \sigma_A^2 / (\sigma^2 + K\sigma^2) \leq \Delta$, kai alternatyva $\bar{H} : \tau^2 > \Delta$, tikrinti;
- b) hipotezei $H : \sigma_{AB}/\sigma^2 \leq \Delta$, kai alternatyva $\bar{H} : \sigma_{AB}^2/\sigma^2 > \Delta$, tikrinti.

II.2.43. Atlikus dvifaktorė dispersinę analizę su dviem atsitiktiniais faktoriais A ir B, gauta tokia dispersinės analizės lentelė

Faktorius	ν	\overline{SS}
A	24	3 243
B	3	46 659
$A \times B$	72	459
E	1100	243

- a) Patikrinkite hipotezes H_A , H_B , H_{AB} , kai reikšmingumo lygmuo $\alpha = 0,025$.
 b) Raskite dispersijos komponenčių σ_A^2 , σ_B^2 , σ_{AB}^2 , σ^2 įverčius ir jų dispersijų įverčius.
 c) Apskaičiuokite kiekvienos dispersijos komponentės apytikslį pasiklovimo intervalą, kai pasiklovimo lygmuo $Q = 0,95$.

II.2.44. Atlikite dispersinę analizę pagal II.2.33 pratimo duomenis tarę, kad abu faktoriai yra atsitiktiniai.

II.2.45. Atlikite dispersinę analizę pagal II.2.37 pratimo duomenis tarę, kad abu faktoriai yra atsitiktiniai.

II.2.46. Tarkime, kad Y skirstinys gali priklausyti nuo pastovaus faktoriaus A ir atsitiktinio faktoriaus B . Imties \mathbf{Y} elementai turi tokią struktūrą (žr. [3], 2.6.1 skyrelį):

$$Y_{ijk} = \mu + \alpha_i + b_j + c_{ij} + e_{ijk}, \quad i = 1, \dots, I, \quad j = 1, \dots, J, \quad k = 1, \dots, K,$$

čia μ, α_i konstantos, o b_j, c_{ij}, e_{ijk} atsitiktiniai dydžiai,

$$\sum_i \alpha_i = 0, \quad \sum_i c_{ij} \equiv 0, \quad \mathbf{E}b_j = \mathbf{E}c_{ij} = \mathbf{E}e_{ijk} = 0.$$

Tarsime, kad a. v. $(b_j, c_{1j}, \dots, c_{Ij})^T$ skirstinys yra daugiamatis normalusis (su skirtiniais j šie vektoriai nepriklausomi), o a. d. $e_{ijk} \sim N(0, \sigma^2)$ nepriklausomi tarpusavyje ir ne-priklauso nuo šių vektorių. Zymésime $\mathbf{V}b_j = \sigma_B^2$, $\mathbf{V}c_{ij} = \sigma_{AB;i}^2$, $i = 1, \dots, I$. Analogiskai pirmesnėms schemoms sudarykime kvadratų sumas $SS_A, SS_B, SS_{AB}, SS_E$. Raskite vidutinių kvadratų sumų vidurkius.

II.2.47. (II.2.46 pratimo tēsinys). a) Raskite parametrų $\sigma_A^2, \sigma_B^2, \sigma_{AB}^2, \sigma^2$ nepaslinktuosius įvertinius. b) Sudarykite kriterijus pagrindinių dispersinės analizės hipotezių analogams $H_A : \sigma_A^2 = 0$, $H_B : \sigma_B^2 = 0$, $H_{AB} : \sigma_{AB}^2 = 0$ tikrinti.

II.2.48. Lentelėje pateikti duomenys, apibūdinantys kuro ištakėjimo iš trijų skirtingu tipų tūtų greitį; matavimus atliko 5 operatoriai, iš kurių kiekvienas atliko po 3 matavimus kiekvienoje tūtoje.

Tūta	1			2			3		
A	6	6	-15	26	12	5	11	4	4
B	13	6	13	4	4	11	17	10	17
C	10	10	-11	-35	0	-14	11	-10	-17

Tūta	4			5		
A	21	14	7	25	18	25
B	-5	2	-5	15	8	1
C	-12	-2	-16	-4	10	24

- a) Atlikite mišraus modelio, kuriame faktorius A (tūtos) yra pastovus, o faktorius B (operatorius) – atsitiktinis, dispersinę analizę.

b) Atlikite analizę laikydami abu faktorius pastoviais. Kuo paaiškinti skirtinges atsakymus, gautus tikrinant hipotezę, kad rezultatai nepriklauso nuo tūtų tipo.

II.2.49. Lentelėje pateikta tam tikros medžiagos nepralaidumo vandeniu charakteristika priklausomai nuo trijų tipų staklių (faktorius A), su kuriomis ji buvo pagaminta, per 9 skirtinges dienas (faktorius B) [16].

	B ₁	B ₂	B ₃	B ₄	B ₅	B ₆	B ₇	B ₈	B ₉
A ₁	1,40	1,45	1,91	1,89	1,77	1,66	1,92	1,84	1,54
	1,35	1,57	1,48	1,48	1,73	1,54	1,93	1,79	1,43
	1,62	1,82	1,89	1,39	1,54	1,68	2,13	2,04	1,70
A ₂	1,31	1,24	1,51	1,67	1,23	1,40	1,23	1,58	1,64
	1,63	1,18	1,58	1,37	1,40	1,45	1,51	1,63	1,07
	1,41	1,52	1,65	1,11	1,53	1,63	1,44	1,28	1,38
A ₃	1,93	1,43	1,38	1,72	1,32	1,63	1,33	1,69	1,70
	1,40	1,86	1,36	1,37	1,34	1,36	1,38	1,80	1,84
	1,62	1,69	1,49	1,43	1,48	1,49	1,29	1,45	1,75

Atlikite duomenų dispersinę analizę, tarę, kad modelis yra mišrusis, kuriame faktorius A yra pastovus, o faktorius B – atsitiktinis.

II.2.50. Tiriant dujų sunaudojimą per devynias savaites (faktorius A) buvo fiksuojaamas dujų sunaudojimas per parą kiekvieną savaitęs dieną nuo pirmadienio iki šeštadienio imtinai (faktorius B). Gauti rezultatai (salyginiais vienetais) pateikiami lentelėje [16].

	A ₁	A ₂	A ₃	A ₄	A ₅	A ₆	A ₇	A ₈	A ₉
B ₁	5	1	-4	5	-13	-8	-2	-4	-10
B ₂	3	6	-10	-2	-7	-2	-4	2	2
B ₃	8	4	-14	-3	3	0	5	-11	-12
B ₄	8	10	-5	-1	4	-2	4	1	-12
B ₅	4	-1	7	-5	5	-3	-7	-3	-6
B ₆	3	-9	3	-8	-6	0	-3	8	-1

Atlikite dispersinę analizę, tarę, kad faktorius A atsitiktinis, o faktorius B pastovus. Kaip pasikeistų atsakymai, jeigu tartume, kad abu faktoriai yra pastovūs?

II.2.51. Atlikite II.2.32 pratimo duomenų analizę, tarę, kad faktorius A yra atsitiktinis, o faktorius B – pastovus.

II.2.52. Atlikite II.2.34 pratimo duomenų analizę, tarę, kad faktorius A yra pastovus, o faktorius B – atsitiktinis.

II.2.3. Daugiafaktorių dispersinė analizė

II.2.53. Trifaktoriés dispersinės analizés skirtinges langelių stebėjimų vidurkiai μ_{ijl} , $i = 1, 2, 3; j = 1, 2, 3; l = 1, 2$, pateikti lentelėse

C ₁	B ₁	B ₂	B ₃	C ₂	B ₁	B ₂	B ₃
A ₁	5	6	10	A ₁	9	7	14
A ₂	7	7	1	A ₂	9	6	3
A ₃	6	5	7	A ₃	9	5	10

Irodykite, kad visų trijų faktorių sąveika $A \times B \times C$ yra lygi 0.

II.2.54. Nagrinėjame tiesinį modelį $Y_{ijk} = \mu_{ijk} + e_{ijk}$, $i = 1, \dots, I$; $j = 1, \dots, J$; $k = 1, \dots, K$, kuriame $\{e_{ijk}\}$ yra nepriklausomi normalieji $e_{ijk} \sim N(0, \sigma^2)$ a.d. Tarkime, vidurkiai μ_{ijk} tenkina sąlygą

$$\begin{aligned}\mu_{ijk} &= \bar{\mu}_{...} + (\bar{\mu}_{i..} - \bar{\mu}_{...}) + (\bar{\mu}_{i..} - \bar{\mu}_{i..}) + (\bar{\mu}_{..k} - \bar{\mu}_{...}) = \\ &= \mu + \alpha_i + \beta_{ij} + \gamma_k.\end{aligned}$$

Raskite parametru $\mu, \alpha_i, \beta_{ij}, \gamma_k$ įvertinius. Sukurkite kriterijų hipotezei $H_A : \alpha_i = 0, i = 1, \dots, I$.

II.2.55. Sudarykite trifaktorės dispersinės analizės lentelę, kai visi trys faktoriai yra atsitiktiniai. Sukurkite kriterijus pagrindinėms hipotezėms tikrinti.

II.2.56. Tarkime, pilnoje dispersinės analizės schemaje, kai vienodas stebėjimų skaičius langelyje, faktorius A turi I lygmenę. Stebėjimų aritmetinius vidurkius, gautus suvidurkinus pagal visų kitų faktorių lygmenis, pažymėkime $\bar{Y}_1, \dots, \bar{Y}_I$. Tegu šie vidurkiai padalyti į dvi didumo I_1 ir I_2 , $I_1 + I_2 = I$ aibes $\bar{Y}_1, \dots, \bar{Y}_{I_1}$ ir $\bar{Y}_{I_1+1}, \dots, \bar{Y}_I$, o $\bar{Y}^{(1)}$ ir $\bar{Y}^{(2)}$ yra šių aibinių vidurkiai. Irodykite, kad

$$\sum_{i=1}^I (\bar{Y}_i - \bar{Y}_.)^2 = \sum_{i=1}^{I_1} (\bar{Y}_i - \bar{Y}^{(1)})^2 + \sum_{i=I_1+1}^I (\bar{Y}_i - \bar{Y}^{(2)})^2 + I_1 I_2 (\bar{Y}^{(1)} - \bar{Y}^{(2)})^2 / I.$$

II.2.57. Apibendrinkite **II.2.34** pratimą, kai vidurkiai $\bar{Y}_1, \dots, \bar{Y}_I$ padalijami į tris nesikertančias aibes.

II.2.58. Lentelėje pateikti duomenys, apibūdinantys betoninį kelią priklausomai nuo padengimo storio (faktorius A), nuo pagrindo storio (faktorius B) ir nuo papildomo (apatinio) pagrindo storio (faktorius C). Atlolta po du matavimus kiekvieno iš 27 kelių variantų ([11]).

	A_1			A_2			A_3		
	B_1	B_2	B_3	B_1	B_2	B_3	B_1	B_2	B_3
C_1	2,8	4,3	5,7	4,1	5,4	6,7	6,0	6,3	7,1
	2,6	4,5	5,3	4,4	5,5	6,9	6,2	6,5	6,9
C_2	4,1	5,7	6,9	5,3	6,5	7,7	6,1	7,2	8,1
	4,4	5,8	7,1	5,1	6,7	7,4	5,8	7,1	8,4
C_3	5,5	7,0	8,1	6,5	7,7	8,8	7,0	8,0	9,1
	5,3	6,8	8,3	6,7	7,5	9,1	7,2	8,3	9,0

Atlikite trifaktorė analizę su trimis pastoviais faktoriais.

II.2.59. Lentelėje pateikiama izoliacijos kokybės charakteristikos priklausomai nuo keturių faktorių: A – padengimo tipas; B – temperatūra; C – slėgis; D – skirtinges plieninės panelės, kurios buvo naudojamos eksperimente [16].

	A_1				A_2			
	B_1	B_1	B_2	B_2	B_1	B_1	B_2	B_2
	C_1	C_2	C_1	C_2	C_1	C_2	C_1	C_2
D_1	0,25	0,16	0,30	0,27	0,41	0,10	0,13	0,06
D_2	0,36	0,002	0,18	0,03	0,28	0,04	0,06	0,03
D_3	0,36	0,06	0,44	0,13	0,33	0,03	0,19	0,04
D_4	0,25	0,10	0,34	0,04	0,21	0,01	0,20	0,01

	A ₃				A ₄			
	B ₁	B ₁	B ₂	B ₂	B ₁	B ₁	B ₂	B ₂
	C ₁	C ₂						
D ₁	0,44	0,24	0,22	0,18	0,43	0,27	0,26	0,21
D ₂	0,65	0,08	0,14	0,36	0,62	0,03	0,51	0,03
D ₃	0,42	0,49	0,17	0,25	0,47	0,28	0,21	0,25
D ₄	0,47	0,14	0,36	0,19	0,52	0,07	0,32	0,38

Atlikite dispersinę analizę, tare, kad visų keturių faktorių sąveika ir sąveikos po tris faktorius yra lygios 0.

II.2.4. Nepilni dispersinės analizės planai

II.2.60. Lentelėje pateikta keturių atspaudų charakteristikos (salyginiais vienetais) priklausomai nuo keturių galvučių skirtinguose spausdinimo įrenginiuose [16].

A ₁				A ₂				A ₃			
1	2	3	4	5	6	7	8	9	10	11	12
6	13	1	7	10	2	4	0	0	10	8	7
2	3	10	4	9	1	1	3	0	11	5	2
0	9	0	7	7	1	7	4	5	6	0	5
8	8	6	9	12	10	9	1	5	7	7	4

A ₄				A ₅							
13	14	15	16	17	18	19	20				
11	5	1	0	1	6	3	3				
0	10	8	8	4	7	0	7				
6	8	9	6	7	0	2	4				
4	3	4	5	9	3	2	0				

Atlikite dispersinę analizę, tare, kad faktorius B (galvutės) yra sugrupuotas pagal faktorių A (spausdinimo įrenginiai); galvučių numeriai yra antroje lentelės eilutėje. Faktorių B laikyti atsitiktiniu, o skirtinges kopijas interpretuoti kaip matavimo kartotinumą.

II.2.61. Lentelėje pateikti duomenys apie kondensatorinio popieriaus poringumą priklausomai nuo partijos (faktorius A) ir nuo atsitiktinai iš partijos atrinkto rulono (faktorius B). Kiekvieną kartą atlikta po tris matavimus [11].

A ₁				A ₂				A ₃			
1	2	3	4	5	6	7	8	9	10	11	12
1,5	1,5	2,7	3,0	1,9	2,3	1,8	1,9	2,5	3,2	1,4	7,8
1,7	1,6	1,9	2,4	1,5	2,4	2,9	3,5	2,9	5,5	1,5	5,2
1,6	1,7	2,0	2,6	2,1	2,4	4,7	2,8	3,3	7,1	3,4	5,0

Atlikite dispersinę analizę, tare, kad faktorius B (rulonai) yra sugrupuotas pagal faktorių A (partijos); rulonų numeriai yra antroje lentelės eilutėje. Abu faktorius laikyti atsitiktiniais.

II.2.62. Atliekant eksperimentą 9 jūry kiaulytės (faktorius B) atsitiktinai buvo suskirstytos į grupes po 3 ir įdėtos į skirtinges narvelius. Kiekvieno narvelio gyvūnai buvo aprūpinami skirtinai NO_2 lygais (faktorius A); A_1 – kontrolinis; A_2 – dvigubai

didesnis už normą; A_3 – trigubai didesnis už normą. Po savaitės buvo atlikta po du kintamojo Y (arterinis PH) matavimus [1].

	B_1		B_2		B_3	
A_1	7,08	7,02	7,04	7,07	7,07	6,98
A_2	7,29	7,18	7,42	7,32	7,08	7,28
A_3	7,74	7,54	7,53	7,50	7,51	7,63

Ištirkite kintamojo Y priklausomybę nuo faktoriaus A , tardami, kad faktorius B sugrupuotas pagal faktorių A .

II.2.63. Keturios pelės turi po 3 peliukus. Pelės atsitiktinai suskirstyti į 3 grupes po dvi. Pirmos grupės peliukams taikoma pirmoji dieta, o antrosios – antroji dieta. Po trijų savaičių užregistruotas peliukų svorio prieaugis Y [1].

Dieta	Pelė	Y			Dieta	Pelė	Y		
Pirmoji	1	11,8	10,5	12,5	Antroji	3	7,4	9,7	8,2
	2	12,3	15,5	11,4		4	7,2	8,6	7,1

Parinkite tinkamą dispersinės analizės schemą ir užpildykite dispersinės analizės lentelę. Patikrinkite pagrindines dispersinės analizės hipotezes.

II.2.64. Penkiolikai pacientų matuotas fermento kiekis iš karto po širdies operacijos (D_0), praėjus vienai dienai (D_1), dviem dienoms (D_2) ir savaitei (D_7) po operacijos.

Pacientas	D_0	D_1	D_2	D_7	Pacientas	D_0	D_1	D_2	D_7
1	108	63	45	42	9	106	65	49	49
2	112	75	56	52	10	110	70	46	47
3	114	75	51	46	11	120	85	60	62
4	129	87	69	69	12	118	78	51	56
5	115	71	52	54	13	110	65	46	47
6	122	80	68	68	14	132	92	73	63
7	105	71	52	54	15	127	90	73	68
8	117	77	54	61					

Patikrinkite, ar fermento kieko vidurkis kinta po širdies operacijos.

II.2.65. Lentelėje pateikti duomenys apie elektroninių spindulinių vamzdelių stiklo savybes priklausomai nuo cecho (faktorius A) ir nuo pamainos (faktorius B). Matavimai atlikti trijų atsitiktinai parinktų savaičių metu (faktorius C ; blokas) [11]. Atlikite blokuotųjų duomenų dispersinę analizę.

	A_1			A_2		
	B_1	B_2	B_3	B_1	B_2	B_3
C_1	3	3	3	6	3	6
	6	4	6	8	9	8
	6	7	7	11	11	13
C_2	14	8	11	4	15	4
	16	8	12	6	15	7
	19	9	17	7	17	10
C_3	2	2	2	2	2	10
	3	3	4	5	4	12
	6	4	6	7	6	13

II.2.66. Tiriant kineskopo elektros srovės stiprumo priklausomybę nuo keturių kato-do kaitinimo siūlelio apdorojimo režimų (A, B, C, D), per vieną dieną galima realizuoti tik tris apdorojimo metodus. Todėl eksperimentas atliktas pagal nepilnų subalansuotų blokų schemą, kurioje blokus atitinka dienos [11].

Dienos	A	B	C	D
1	2	–	20	7
2	–	32	14	3
3	4	13	31	–
4	0	23	–	11

Patikrinkite hipotezę, kad srovės stiprumas nepriklauso nuo apdorojimo metodo.

II.2.67. Reikia palyginti televizorių ryškumo įvertinimą, gautą keturių operatorių (A, B, C, D). Per vieną dieną eksperimente gali dalyvauti tik trys operatoriai. Duomenys pateikti lentelėje [11].

Dienos	A	B	C	D
1	780	820	800	–
2	950	–	920	940
3	–	880	880	820
4	840	780	–	820

Atlikite duomenų analizę. Ar galima tvirtinti, kad operatorių įvertinimai skiriasi?

II.2.68. Penkioms skalbimo priemonėms (A, B, C, D, E) palyginti buvo atliktas tokis eksperimentas. Skalbimo priemonės buvo lyginamos plaunant specialiai užterštas lėkštės blokuose po tris rezervuarus su skirtingomis skalbimo priemonėmis. Lentelėje pateiktas išplautų vienodu skalbimo priemonės kiekiu lėkščių skaičius [16].

	1	2	3	4	5	6	7	8	9	10
A	27	28	30	31	29	30	–	–	–	–
B	26	26	29	–	–	–	30	21	26	–
C	30	–	–	34	32	–	34	31	–	33
D	–	29	–	33	–	34	31	–	33	31
E	–	–	26	–	24	25	–	23	24	26

Atlikite duomenų analizę. Ar galima tvirtinti, kad skalbimo priemonės skiriasi?

II.2.69. Tiriant penkių tipų (A, B, C, D, E) elektrodus eksperimento metu buvo pradeginta po 5 skylutes 5 metalo juostose. Eksperimentas atliktas pagal lotyniškojo kvadrato schemą, kurioje eilutės atitinka metalo juostas, stulpeliai – skylutės padėtį metalo juostoje, o elektrodo tipas nurodytas skliausteliuose. Registruojama skylutės pradeginimo laikas [11].

3,5 (A)	2,1 (B)	2,5 (C)	3,5 (D)	2,4 (E)
2,6 (E)	3,3 (A)	2,1 (B)	2,5 (C)	2,7 (D)
2,9 (D)	2,6 (E)	3,5 (A)	2,7 (B)	2,9 (C)
2,5 (C)	2,9 (D)	3,0 (E)	3,3 (A)	2,3 (B)
2,1 (B)	2,3 (C)	3,7 (D)	3,2 (E)	3,5 (A)

Atlikite duomenų analizę ir užpildykite dispersinės analizės lentelę. Ar galima tvirtinti, kad elektrodo tipai skiriasi?

II.2.70. Tiriant tam tikros ankštinės kultūros šešių veislių (A, B, C, D, E, F) derlingumą, eksperimentas atliktas pagal lotyniškojo kvadrato schemą. Lentelėje nurodyti gauti derlingumo rodikliai, o kultūros veislė nurodyta skliausteliuose [16].

220 (B)	98 (F)	149 (D)	92 (A)	282 (E)	169 (C)
74 (A)	238 (E)	153 (B)	228 (C)	48 (F)	188 (D)
118 (D)	279 (C)	118 (F)	272 (E)	176 (B)	65 (A)
295 (E)	222 (B)	54 (A)	104 (D)	213 (C)	163 (F)
187 (C)	90 (D)	242 (E)	96 (F)	66 (A)	122 (B)
90 (F)	124 (A)	195 (C)	109 (B)	79 (D)	211 (E)

Atlikite duomenų dispersinę analizę.

II.2.5. Atsakymai, sprendimai, nurodymai

II.2.1 skyrelis

II.2.1. a) Sujunge Y_{ij} į vieną bendrą vektorių

$$\mathbf{Y} = (Y_{11}, \dots, Y_{1J_1}, Y_{21}, \dots, Y_{2J_2}, \dots, Y_{I1}, \dots, Y_{IJ_I})^T$$

ir pažymėję $\boldsymbol{\beta} = (\mu_1, \dots, \mu_I)^T$, imtį \mathbf{Y} galime užrašyti kaip tiesinį modelį

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}, \quad \mathbf{E}(\mathbf{Y}) = \mathbf{A}\boldsymbol{\beta}, \quad \mathbf{V}(\mathbf{Y}) = \mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I}, \quad \mathbf{Y} \sim N_n(\mathbf{A}\boldsymbol{\beta}, \sigma^2 \mathbf{I}).$$

Plano matrica \mathbf{A} turi $n = J_1 + \dots + J_I$ eilučių ir I stulpelių. Pirmosios J_1 eilutės turi pavidalą (1, 0, ..., 0), paskui J_2 eilučių turi pavidalą (0, 1, ..., 0), pagaliau paskutinės J_I eilučių turi pavidalą (0, 0, ..., 1).

b) Tikėtinumo funkcija

$$L(\boldsymbol{\theta}) = (2\pi)^{-n/2} \exp\left\{\frac{-1}{2\sigma^2} \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \mu_i)^2 - \frac{n}{2} \ln \sigma^2\right\} =$$

$$(2\pi)^{-n/2} \exp\left\{\frac{-1}{2\sigma^2} \mathbf{Y}^T \mathbf{Y} + \frac{1}{\sigma^2} \sum_{i=1}^I J_i \mu_i \bar{Y}_{i\cdot} - \sum_{i=1}^I \frac{J_i \mu_i^2}{2\sigma^2} - \frac{n}{2} \ln \sigma^2\right\}$$

priklauso $(I+1)$ -parametrei eksponentinio tipo skirstinių šeimai. Remiantis faktorizacijos kriterijumi \mathbf{T} yra parametru $\boldsymbol{\theta}$ pakankamoji statistika. Kadangi parametru kitimo sričiai priklauso vidiniai taškai, tai statistika \mathbf{T} yra pilnoji.

c) Kadangi \mathbf{T} yra pilnoji ir pakankamoji statistika, tai bet kuri \mathbf{T} funkcija yra jos vidurkio NMD jvertinys. Randame $\mathbf{E}\bar{Y}_{i\cdot} = \mu_i$, todėl $\hat{\mu}_i = \bar{Y}_{i\cdot}$ yra parametru μ_i NMD jvertinys. Liekamoji kvadratų suma

$$SS_E/\sigma^2 = \sum_i \sum_j (Y_{ij} - \bar{Y}_{i\cdot})^2 / \sigma^2 \sim \chi^2(n - I).$$

Gauname, kad

$$s^2 = SS_E/(n - I), \quad \mathbf{E}s^2 = \sigma^2,$$

yra parametru σ^2 NMD jvertinys.

II.2.2. Parametrai μ, α_i yra tiesinės parametru μ_i funkcijos. Nepaslinktieji (kartu ir NMD) įvertiniai gaunami imant tokias pačias tiesines įvertinių $\hat{\mu}_i$ funkcijas

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n J_i \bar{Y}_{i\cdot} = \bar{Y}_{..}, \quad \hat{\alpha}_i = \bar{Y}_{i\cdot} - \bar{Y}_{..}.$$

Šie įvertiniai tenkina sąryšį

$$\sum_{i=1}^I J_i \hat{\alpha}_i = \sum_{i=1}^I J_i (\bar{Y}_{i\cdot} - \bar{Y}_{..}) = 0.$$

II.2.3. Hipotezę H_A galima suformuluoti tokiu būdu $H_A : \mathbf{H}\boldsymbol{\beta} = \boldsymbol{\theta}_0$ (žr. **I.1.21** pratimą), kai matricos \mathbf{H} rargas yra $k = I - 1$. Pavyzdžiui, matricą \mathbf{H} galima imti tokio pavيدalo: pirmoji eilutė $(1, 0, \dots, 0, -1)$, antroji $(0, 1, \dots, 0, -1)$ ir t.t., ir $(I - 1)$ -oji eilutė $(0, 0, \dots, 1, -1)$. Matricos \mathbf{H} rargas yra $I - 1$, o $\boldsymbol{\theta}_0 = \mathbf{0}$. Remiantis **I.1.21** pratimo p. d) hipotezė H_A atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_A = \frac{(SS_{EH_A} - SS_E)(n - I)}{(I - 1)SS_E} = \frac{SS_A(n - I)}{(I - 1)SS_E} > F_\alpha(I - 1, n - I),$$

čia SS_E – liekamoji kvadratų suma (surasta **II.2.1** pratime), o SS_{EH_A} yra kvadratinės formos $SS(\boldsymbol{\beta})$ salyginis minimums, surastas esant sąlygai, kad H_A teisinga.

Salyginę kvadratinę formą lengva surasti tokiu būdu. Tapatybės

$$Y_{ij} - \mu_i = Y_{ij} - \hat{\mu}_i + \hat{\alpha}_i + \hat{\mu} - \mu$$

abi puses pakelkime kvadratu ir susumuokime pagal i ir j . Gauname

$$SS(\boldsymbol{\beta}) = SS_E + \sum_i J_i (\hat{\alpha}_i - \alpha_i)^2 + n(\hat{\mu} - \mu)^2,$$

nes visos mišrios sandaugos lygios nuliui. Tada

$$SS_{EH_A} = \min_{\alpha_i=0} SS(\boldsymbol{\beta}) = SS_E + \sum_i J_i \hat{\alpha}_i^2,$$

$$SS_A = SS_{EH_A} - SS_E = \sum_i J_i (\bar{Y}_{i\cdot} - \bar{Y}_{..})^2.$$

Pažymėjus vidutines kvadratų sumas

$$MS_A = \frac{SS_A}{I - 1}, \quad MS_E = \frac{SS_E}{n - I},$$

kriterijus iugauna tokį pavidalą: hipotezė H_A atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_A = \frac{MS_A}{MS_E} > F_\alpha(I - 1, n - I).$$

Skaičiavimo rezultatai analizę atliekant kompiuteriu pateikiami tokioje lentelėje.

Dispersinės analizės lentelė

Faktorius	SS	ν	$MS = SS/\nu$	$E(MS)$
A	$SS_A = \sum_i J_i (\bar{Y}_{..} - \bar{Y}_{i..})^2$	$I - 1$	MS_A	$\sigma^2 + \sigma_A^2$
E	$SS_E = \sum_i \sum_j (Y_{ij} - \bar{Y}_{i..})^2$	$n - I$	MS_E	σ^2
T	$SS_T = \sum_i \sum_j (Y_{ij} - \bar{Y}_{..})^2$			

Šioje lentelėje antrame stulpelyje pateikiamos kvadratų sumos, trečiame stulpelyje – laisvės laipsniai, ketvirtame – vidutinės kvadratų sumos, $\sigma_A^2 = \sum_i J_i \alpha_i^2 / (I - 1)$.

II.2.4. a)

$$E(SS_E) = E\left(\sum_{i=1}^I \sum_{j=1}^{J_i} (e_{ij} - \bar{e}_{i..})^2\right) = \sigma^2 \sum_{i=1}^I (J_i - 1) = \sigma^2(n - I);$$

$$E(MS_E) = \sigma^2.$$

$$\begin{aligned} E(SS_A) &= E\left(\sum_{i=1}^I J_i (\alpha_i + \bar{e}_{i..} - \bar{e}_{..})^2\right) = \sum_{i=1}^I J_i \alpha_i^2 + E \sum_{i=1}^I J_i (\bar{e}_{i..} - \bar{e}_{..})^2 = \\ &\sum_{i=1}^I J_i \alpha_i^2 + (I - 1)\sigma^2; \quad E(MS_A) = \sigma^2 + \sum_{i=1}^I \frac{J_i \alpha_i^2}{I - 1} = \sigma^2 + \sigma_A^2. \end{aligned}$$

b) remiantis **I.1.21** pratimu $SS_A/\sigma^2 \sim \chi^2(I - 1, \lambda)$, kai necentriškumo parametras $\lambda = (I - 1)\sigma_A^2/\sigma^2$. Tada statistika F_A turi necentrinį Fišerio skirstinį $F(I - 1, n - I; \lambda)$. Kriterijaus galia

$$\beta(\lambda) = P\{F_{I-1, n-I; \lambda} > F_\alpha(I - 1, n - I)\}.$$

II.2.5. Kai hipotezė H'_A teisinga, tai yra tik du parametrai: vidurkis μ'_1 pirmajai faktoriaus lygmenų grupėi ir μ'_2 – antrajai. Šiu parametrų DT įvertiniai

$$\hat{\mu}'_1 = \sum_{i=1}^r \sum_{j=1}^{J_i} Y_{ij}/n'_1 = \bar{Y}_{..}^{(1)}, \quad \hat{\mu}'_2 = \sum_{i=r+1}^I \sum_{j=1}^{J_i} Y_{ij}/n'_2 = \bar{Y}_{..}^{(2)},$$

$$n'_1 = J_1 + \dots + J_r, \quad n'_2 = J_{r+1} + \dots + J_I$$

ir

$$SS_{EH'_A} - SS_E = SS'_A = \sum_{i=1}^r J_i (\bar{Y}_{i..} - \bar{Y}_{..}^{(1)})^2 + \sum_{i=r+1}^I J_i (\bar{Y}_{i..} - \bar{Y}_{..}^{(2)})^2 \stackrel{d}{=} \sigma^2 \chi_{I-2}^2,$$

kai H'_A teisinga. Hipotezė H'_A atmetama, kai

$$F'_A == \frac{SS'_A(n - I)}{(I - 2)SS_E} = \frac{MS'_A}{MS_E} > F_\alpha(I - 2, n - I).$$

II.2.6. Žr. [3], 2.1.2 teorema.

II.2.7. Tarkime, kad $d_I \neq 0$. Tada $\alpha_I = -\sum_{i=1}^{I-1} \alpha_i d_i / d_I$.

Pažymėję $\mathbf{Y} = (Y_{11}, \dots, Y_{1J}, Y_{21}, \dots, Y_{IJ})^T$ ir $\boldsymbol{\beta} = (\mu, \alpha_1, \dots, \alpha_{I-1})^T$, gauname tiesinį modelį $\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}$; $\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}$.

II.2.8. a) Vertindami parametrą $\beta = (\mu_1, \mu_2, \mu_3, \mu_4)^T$ turime tiesinį modelį, kai matrica $A^T A$ diagonali su diagonaliniais elementais J . Taigi parametrų μ_i įvertiniai $\hat{\mu}_i = \bar{Y}_{i.}$ yra nepriklausomi ir $\hat{\mu}_i \sim N(\mu_i, \sigma^2/J)$. Liekamoji kvadratų suma

$$SS_E/\sigma^2 = \sum_{i=1}^4 \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i.})^2 / \sigma^2 \sim \chi^2(4(J-1)).$$

Tikrinamają hipotezę galima užrašyti taip $H : \theta = \mathbf{0}$, kai $\theta = (\theta_1, \theta_2)^T$, $\theta_1 = \mu_1 - 2\mu_2$, $\theta_2 = \mu_1 - 3\mu_3$. Parametru θ NMD įvertinys

$$\hat{\theta} = \begin{pmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{pmatrix} = \begin{pmatrix} \hat{\mu}_1 - 2\hat{\mu}_2 \\ \hat{\mu}_1 - 3\hat{\mu}_3 \end{pmatrix} \sim N_2(\theta, \Sigma),$$

čia $\Sigma = [\sigma_{ij}]_{2 \times 2}$, $\sigma_{11} = 5\sigma^2/J$, $\sigma_{12} = \sigma^2/J$, $\sigma_{22} = 10\sigma^2/J$. Jeigu hipotezė H teisinga, tai kvadratinė forma

$$\hat{\theta}^T \Sigma^{-1} \hat{\theta} = J(10\hat{\theta}_1^2 - 2\hat{\theta}_1\hat{\theta}_2 + 5\hat{\theta}_2^2)/(49\sigma^2) \sim \chi^2(2).$$

Hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F = \frac{2\hat{\theta}^T \Sigma^{-1} \hat{\theta}(J-1)}{SS_E/\sigma^2} > F_\alpha(2, 4(J-1)).$$

Uždavinį galima išspręsti kitu būdu remiantis **II.1.21** pratimo p. d). Randame kvadratinės formos $SS(\beta)$ sąlyginį minimumą SS_{EH} , kai $\mu_1 = 2\mu_2$, $\mu_1 = 3\mu_3$. Pažymėjė $\mu_2 = \mu_1/2$, $\mu_3 = \mu_1/3$, gausime tiesinį modelį, priklausantį tik nuo dviejų parametrų μ_1 ir μ_4 . Plano matrica turi 2 stupelius ir $4J$ eilučių: pirmosios J eilučių yra $(0, 1)$, antriosios J eilučių yra $(1/2, 0)$, po to J eilučių $(1/3, 0)$ ir paskutinės J eilučių yra $(0, 1)$. Gauname parametrų μ_1 ir μ_4 įvertinius

$$\tilde{\mu}_1 = (\hat{\mu}_1 + \hat{\mu}_2/2 + \hat{\mu}_3/3)/(1 + 1/4 + 1/9) = \frac{36}{49}(\mu_1)_1 + \frac{\hat{\mu}_2}{2} + \frac{\hat{\mu}_3}{3}, \quad \tilde{\mu}_4 = \hat{\mu}_4$$

ir liekamają kvadratų sumą

$$SS_{EH} = \sum_i (Y_{1j} - \tilde{\mu}_1)^2 + \sum_i (Y_{2j} - \tilde{\mu}_1/2)^2 + \sum_i (Y_{3j} - \tilde{\mu}_1/3)^2 + \sum_i (Y_{4j} - \tilde{\mu}_4)^2.$$

Skirtumas

$$(SS_{EH} - SS_E)/\sigma^2 = [(\hat{\mu}_1 - \tilde{\mu}_1)^2 + (\hat{\mu}_2 - \tilde{\mu}_1/2)^2 + (\hat{\mu}_3 - \tilde{\mu}_1/3)^2]/\sigma^2 \sim \chi^2(2),$$

kai hipotezė teisinga. Hipotezė atmetama, kai

$$\frac{2(SS_{EH} - SS_E)(J-1)}{SS_E} > F_\alpha(2, 4(J-1)).$$

Nesunku patikrinti, kad abu kriterijai ekvivalentūs.

b) Stjudento kriterijus atmeta hipotezė, kai

$$|t| = \sqrt{\frac{J}{2}} \frac{|\bar{Y}_{1.} - \bar{Y}_{2.}|}{s} > t_{\alpha/2}(2(J-1)), \quad s^2 = \frac{SS_E}{2(J-1)}.$$

Kadangi $SS_A = J(\bar{Y}_{1\cdot} - \bar{Y}_{2\cdot})^2/2$, tai F kriterijus atmeta hipotezę, kai

$$F = \frac{J}{2} \frac{(\bar{Y}_{1\cdot} - \bar{Y}_{2\cdot})^2}{s^2} > F_\alpha(1, 2(J-1)).$$

Akivaizdu, kad šie kriterijai ekvivalentūs.

II.2.9. Dispersinės analizės lentelė:

Faktorius	SS	ν	MS	F	$Pr > F$
A	$SS_A = 4,23214$	3	1,41071	3,21143	0,0359
E	$SS_E = 14,05691$	32	0,39047		
T	$SS_T = 18,28905$				

Statistika F_A (II.2.3 pratimas), kuri esant teisingai hipotezei turi Fišerio skirstinį su 3 ir 32 laisvės laipsniais, įgijo reikšmę 3,21143; P reikšmė $pv = \mathbf{P}\{F_{3,32} > 3,21143\} = 0,0369$. Hipotezė atmetama kriterijumi, kurio reikšmingumo lygmuo viršija 0,0359.

II.2.10. Atlikę analizę analogišką II.2.9 pratimui, gauname, kad statistika F_A įgijo reikšmę 9,9285; hipotezė atmetama kriterijumi, kurio reikšmingumo lygmuo $\alpha > pv = \mathbf{P}\{F_{3,20} > 9,9285\} = 0,00032$.

II.2.11. Statistika F_A įgijo reikšmę 1,3574; $\mathbf{P}\{F_{3,16} > 1,3574\} = 0,2950$; atmesti hipotezę nėra pagindo.

II.2.12. Statistika F_A , kuri esant teisingai hipotezei turi Fišerio skirstinį su 2 ir 321 laisvės laipsniu, įgijo atitinkamai reikšmes: 1,538; 72,507; 31,009; 18,312; 23,904; 27,724. Duomenys neprieštarauja prielaidai, kad vario koncentracija yra vienoda; kitų elementų koncentracijų vienodumo hipotezės atmetamos kriterijais su aukštais reikšmingumo lygmenimis.

II.2.13. Tarkime, i -ojo gaminio požymis nusakomas a.d. X_i , o jį matuojant j -ąjį kartą prisideda paklaida e_{ij} . Tarkime, kad paklaidos e_{ij} nepriklausomos ir normaliosios $e_{ij} \sim N(0, \sigma^2)$. Kadangi reikia apibūdinti visą gaminijų aibę, o ne tik palyginti tarpusavyje kelis eksperimente dalyvaujančius gaminius, tai tarsime, kad X_1, \dots, X_I yra paprastoji imtis, gauta stebint a.d. X . Tarsime, kad X_i nepriklauso nuo e_{ij} ir $X_i \sim N(\mu, \sigma_A^2)$. Pažymėję $a_i = X_i - \mu$ gausime, kad matavimai Y_{ij} turi tokią struktūrą

$$Y_{ij} = X_i + e_{ij} = \mu + a_i + e_{ij}, \quad i = 1, \dots, I, \quad j = 1, \dots, J.$$

Tai vienfaktorių dispersinės analizės modelis su atsitiktiniu faktoriu. Modelį visiškai nusako parametrai $\mu, \sigma_A^2, \sigma^2$.

II.2.14. Nagrinėkime nepriklausomus a.v. $\mathbf{Y}_i = (Y_{i1}, Y_{i2}, \dots, Y_{iJ}) \sim N_J(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, $i = 1, \dots, I$; čia $\boldsymbol{\mu} = (\mu, \mu, \dots, \mu)^T$, $\boldsymbol{\Sigma} = [\sigma_{kl}]_{J \times J}$, $\sigma_{kk} = \sigma_A^2 + \sigma^2$, $k = 1, \dots, J$, $\sigma_{kl} = \sigma_A^2$, kai $k \neq l = 1, \dots, J$.

Atlikime vektoriaus \mathbf{Y}_i ortonormuotą transformaciją $\mathbf{Z}_i = \mathbf{C}\mathbf{Y}_i = (Z_{i1}, \dots, Z_{iJ})^T$ pasinaudodami matrica $\mathbf{C} = [c_{kl}]_{J \times J}$. Tegu matricos \mathbf{C} pirmoji eilutė $(c_{11}, \dots, c_{1J}) = (1/\sqrt{J}, \dots, 1/\sqrt{J})$. Tada iš ortogonalumo sąlygos gauname

$$\sum_{j=1}^J c_{ij} = 0, \quad i = 2, \dots, J; \quad \sum_{j=1}^J c_{ij}^2 = 1, \quad \sum_{j=1}^J c_{ij} c_{i'j} = 0 \quad i \neq i'.$$

Gauname

$$Z_{i1} = \sqrt{J}\bar{Y}_{i.}, \quad \mathbf{E}Z_{i1} = \sqrt{J}\mu, \quad \mathbf{E}Z_{il} = 0, \quad l = 2, \dots, J;$$

$$\mathbf{V}(\mathbf{Z}_i) = \mathbf{V}(C\mathbf{Y}_i) = C\Sigma C^T = \sigma_A^2 CUC^T + \sigma^2 CIC^T,$$

čia \mathbf{U} – matrica, kurios visi elementai yra vienetai.

Pirmojo dėmens matricos tik pirmos eilutės pirmasis elementas yra $J\sigma_A^2$, o visi kiti elementai nuliai; antrojo dėmens matrica diagonali su diagonaliniai elementais σ^2 . Galutinai turime

$$\mathbf{V}(\mathbf{Z}_i) = \Lambda = [\lambda_{rs}]_{J \times J}, \quad \lambda_{11} = \sigma^2 + J\sigma_A^2, \quad \lambda_{rr} = \sigma^2, \quad r = 2, \dots, J, \lambda_{rs} = 0, \quad r \neq s.$$

Atlikę tą pačią transformaciją su visais vektoriais $\mathbf{Y}_1, \dots, \mathbf{Y}_I$, gauname nepriklausomų a. v. sistemą $\mathbf{Z}_1, \dots, \mathbf{Z}_I$, kurių ir koordinatės nepriklausomos; pirmosios koordinatės $Z_{i1} \sim N(\sqrt{J}\mu, \sigma^2 + J\sigma_A^2)$, visos kitos koordinatės $Z_{il} \sim N(0, \sigma^2)$, $l = 2, \dots, J$.

Tikėtinumo funkcija Z_{ij} terminais yra

$$L(\mu, \sigma_A^2, \sigma^2) = \exp\left\{-\frac{1}{2(\sigma^2 + J\sigma_A^2)} \sum_{i=1}^I (Z_{i1} - \sqrt{J}\mu)^2 - \frac{1}{2\sigma^2} \sum_{i=1}^I \sum_{j=2}^J Z_{ij}^2 - b(\mu, \sigma_A^2, \sigma^2)\right\} = \\ \exp\left\{\left(\frac{1}{2\sigma^2} - \frac{1}{2(\sigma^2 + J\sigma_A^2)}\right) \sum_{i=1}^I Z_{i1}^2 + \frac{\mu\sqrt{J}}{\sigma^2 + \sigma_A^2} \sum_{i=1}^I Z_{i1} - \frac{1}{2\sigma^2} \sum_{i=1}^I \sum_{j=1}^J Z_{ij}^2 - B(\mu, \sigma_A^2, \sigma^2)\right\},$$

priklauso triparametrei eksponentinio tipo skirstinių šeimai. Statistika

$$(\sum_i Z_{i1}^2, \sum_i Z_{i1}, \sum_i \sum_j Z_{ij}^2)^T$$

yra pilnoji ir pakankamoji. Grįžę prie pradinių kintamųjų Y_{ij} įsitikiname, kad statistika \mathbf{T} irgi yra pilnoji ir pakankamoji.

II.2.15. Statistika \mathbf{T} yra pilnoji ir pakankamoji, todėl bet kuri \mathbf{T} funkcija yra jos vidurkio NMD įvertinys. Imkime tokias \mathbf{T} funkcijas

$$\hat{\mu} = \bar{Y}_{..} = \mu + \bar{a}_{..} + \bar{e}_{..} \sim N(\mu, \tau^2/(IJ));$$

$$SS_E = \sum_i \sum_j (Y_{ij} - \bar{Y}_{..})^2 = \sum_i \sum_j (e_{ij} - \bar{e}_{..})^2 \sim \sigma^2 \chi_{I(J-1)}^2,$$

$$\hat{\sigma}^2 = s^2 = \frac{SS_E}{I(J-1)} = MS_E, \quad \mathbf{E}s^2 = \mathbf{E}(MS_E) = \sigma^2;$$

$$SS_A = J \sum_i (\bar{Y}_{i.} - \bar{Y}_{..})^2 = J \sum_i (a_{i.} + \bar{e}_{i.} - \bar{a}_{..} - \bar{e}_{..})^2 = J \sum_i (U_i - \bar{U}_{..})^2,$$

čia U_1, \dots, U_I yra vienodai pasiskirstę n. a. d. ir $U_i \sim N(0, \sigma_A^2 + \sigma^2/J)$. Taigi

$$SS_A \sim (\sigma^2 + J\sigma_A^2) \chi_{I-1}^2, \quad \hat{\tau}^2 = SS_A/(I-1) = MS_A,$$

$$\mathbf{E}(\hat{\tau}^2) = \tau^2 = \sigma^2 + J\sigma_A^2.$$

Parametru σ_A^2 NMD įvertinys

$$\hat{\sigma}_A^2 = (MS_A - MS_E)/J, \quad \mathbf{E}(\hat{\sigma}_A^2) = \sigma_A^2.$$

II.2.16. Šie a. d. sudaryti iš tokiu a. d. $\{\bar{a}_{..}\}$, $\{a_i - \bar{a}_{..}\}$, $\{\bar{e}_{..} - \bar{e}_{..}\}$, $\{\bar{e}_{ij} - \bar{e}_{..}\}$. A. d. sistemos, pažymėtos skirtingomis raidėmis, yra nepriklausomos, taigi reikia tik patikrinti, kad nepriklausomos sistemos žymimos vienodomis raidėmis. Kadangi a. d. yra normalieji, tai pakanka patikrinti, kad jie nekoreliuoti. Gauname

$$\mathbf{Cov}(\bar{a}_{..}, a_i - \bar{a}_{..}) = \frac{1}{J}\sigma_A^2 - \frac{J}{J^2}\sigma_A^2 = 0;$$

$$\mathbf{Cov}(e_{ij} - \bar{e}_{..}, \bar{e}_{..} - \bar{e}_{..}) = \frac{1}{J}\sigma^2 - \frac{J}{J^2}\sigma^2 + \frac{J}{J^2}\sigma^2 - \frac{J}{J^2}\sigma^2 = 0.$$

II.2.17. Remiantis **II.2.13**, **II.2.14** pratimais

$$\sqrt{IJ} \frac{\bar{Y}_{..} - \mu}{\sqrt{MS_A}} \sim S(I-1).$$

Parametru μ lygmens $Q = 1 - 2\alpha$ pasiklivimo intervalas

$$(\underline{\mu}; \bar{\mu}) = (\bar{Y}_{..} - t_\alpha(I-1)\sqrt{MS_A}/\sqrt{IJ}; \bar{Y}_{..} + t_\alpha(I-1)\sqrt{MS_A}/\sqrt{IJ}).$$

Parametrų τ^2 ir σ^2 pasiklivimo intervalai gaunami standartiniu būdu naudojant sąryšius

$$\frac{\hat{\tau}^2(I-1)}{\tau^2} \sim \chi^2(I-1), \quad \frac{\hat{\sigma}^2 I(J-1)}{\sigma^2} \sim \chi^2(I(J-1)).$$

Parametru σ_A^2 įvertinio skirstinys tiesiogiai nesuvedamas prie žinomo skirstinio. Remdamiesi SS_A ir SS_E nepriklausomumu gauname

$$\mathbf{V}(\hat{\sigma}_A^2) = \frac{2}{J^2} \left[\frac{(\sigma^2 + J\sigma_A^2)^2}{(I-1)^2} + \frac{\sigma^4}{I^2(J-1)^2} \right] \rightarrow 0, \quad I \rightarrow \infty.$$

Jeigu I pakankamai didelis, tai apytikslį parametru σ_A^2 pasiklivimo intervalą galima gauti aproksimuojant a. d. $(\hat{\sigma}_A^2 - \sigma_A^2)/\sqrt{\hat{\mathbf{V}}(\hat{\sigma}_A^2)}$ skirstinį standartiniu normaliuoju. Stogelis virš \mathbf{V} reiškia, kad dispersijos išraiškoje parametrai pakeisti jų įvertiniai.

Kriterijai dėl šių parametrų reikšmių sudaromi standartiniu būdu (pavyzdžiui, suformuluojant juos pasiklivimo intervalų terminais).

II.2.18. Kadangi SS_A ir SS_E nepriklausomi ir

$$MS_A/(\sigma^2 + J\sigma_A^2) \sim \chi_{I-1}^2/(I-1), \quad MS_E/\sigma^2 \sim \chi_{I(J-1)}^2/(I(J-1)),$$

tai santykis

$$\frac{MS_A}{MS_E(1 + J\Delta^2)} \sim F(I-1, I(J-1)), \quad \Delta^2 = \frac{\sigma_A^2}{\sigma^2}.$$

Iš čia standartiniu būdu galime surasti parametru Δ^2 pasiklivimo intervalus ar kriterijus tikrinant hipotezes dėl šio parametru reikšmių. Atskiru atveju hipotezė $H : \Delta^2 = 0$ yra

ekvivalenti hipotezei $H_A : \sigma_A^2 = 0$. Hipotezė H_A atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_A = \frac{MS_A}{MS_E} > F_\alpha(I - 1, I(J - 1)).$$

Gauname tokį pat kriterijų, kaip ir schema su pastoviu faktoriumi. Tačiau kriterijaus galia išreiškiama centrinio Fišerio skirstinio pasiskirstymo funkcija:

$$\beta(\sigma_A^2/\sigma^2) = \beta(\Delta^2) = P\{F_{I-1, I(J-1)} > F_\alpha(I-1, I(J-1))/(1+J\Delta^2)\} \rightarrow 1, \quad \Delta^2 \rightarrow \infty.$$

Dispersinės analizės lentelė yra tokia pati, kaip ir **II.2.3** pratime, tik parametru σ_A^2 prasmė kitokia.

II.2.19. a) Kai faktorius atsitiktinis, gauname tokio pat pavidalo dispersinės analizės lentelę, kaip ir pratime **II.2.9**; $MS_A = 8,156$, $MS_E = 0,0504$. Statistika $F_A = 161,81$; P reikšmė $pv = P\{F_{3,36} > 161,81\} = 0,00032$. b) $\hat{\mu} = 5,82$; $(\underline{\mu}; \bar{\mu})(4,38; 7,26)$; $\hat{\sigma}^2 = 0,0504$; $(\underline{\sigma^2}; \bar{\sigma^2}) = (0,033; 0,085)$; $\hat{\sigma}_A^2 = 0,8105$; $(\underline{\sigma^2}_A; \bar{\sigma^2}_A) = (0,257; 11,33)$; c) $(4,5; 227,3)$.

II.2.20. Pagal pirmos eilutės duomenis: $\hat{\mu} = 53,17$; $\hat{\sigma}^2 = 1,144$; $\hat{\sigma}_A^2 = 11,715$; pagal antros eilutės duomenis: $\hat{\mu} = 52,26$; $\hat{\sigma}^2 = 2,537$; $\hat{\sigma}_A^2 = 13,133$; pagal trečios eilutės duomenis: $\hat{\mu} = 47,32$; $\hat{\sigma}^2 = 4,926$; $\hat{\sigma}_A^2 = 14,807$.

II.2.21. Kriterijus išliks toks pat, tačiau kriterijaus galia bus išreiškiama centrinio Fišerio skirstinio pasiskirstymo funkcija.

II.2.2 skyrelis

II.2.22. a) Tikėtinumo funkcija

$$L(\boldsymbol{\theta}) = C \exp\left\{-\frac{1}{2\sigma^2} \sum_i \sum_j \sum_k (Y_{ijk} - \mu_{ij})^2 - \frac{IJK}{2} \ln \sigma^2\right\} = \\ C \exp\left\{-\frac{1}{2\sigma^2} \sum_i \sum_j \sum_k Y_{ijk}^2 + \frac{K}{\sigma^2} \sum_i \sum_j \mu_{ij} \bar{Y}_{ij.} - B(\boldsymbol{\theta})\right\}$$

priklauso $(IJ + 1)$ -parametrei eksponentinio tipo skirstinių šeimai. Remiantis faktorizacijos kriterijumi \mathbf{T} yra pakankamoji statistika. Kadangi parametru kitimo sritis turi vidinių taškų, tai \mathbf{T} yra pilnoji statistika.

b) Bet kuri pilnosios ir pakankamosios statistikos \mathbf{T} funkcija yra jos vidurkio NMD jvertinys. Kadangi $\mathbf{E}(\bar{Y}_{ij.}) = \mu_{ij}$, tai $\hat{\mu}_{ij} = \bar{Y}_{ij.}$ yra parametru μ_{ij} NMD jvertinys. Liekamoji kvadratų suma

$$SS_E/\sigma^2 = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{ij.})^2 / \sigma^2 \sim \chi^2(IJ(K-1)).$$

Taigi

$$s^2 = \frac{SS_E}{IJ(K-1)} = MS_E, \quad \mathbf{E}s^2 = \sigma^2,$$

yra parametru σ^2 NMD jvertinys.

II.2.23. Parametrai $\mu, \alpha_i, \beta_j, \gamma_{ij}$ yra tiesinės parametrų μ_{ij} funkcijos. Nepaslinktieji (kartu pačiu ir NMD) įvertiniai gaunami imant tokias pačias tiesines įvertinių $\hat{\mu}_{ij}$ funkcijas:

$$\begin{aligned}\hat{\mu} &= \bar{Y}_{...}, \quad \hat{\alpha}_i = \bar{Y}_{i..} - \bar{Y}_{...}, \quad \hat{\beta}_j = \bar{Y}_{.j.} - \bar{Y}_{...}, \\ \hat{\gamma}_{ij} &= \bar{Y}_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...}.\end{aligned}$$

Šie įvertiniai tenkina analogiškas sąlygas, kaip ir parametrai

$$\sum_i \hat{\alpha}_i = 0, \quad \sum_j \hat{\beta}_j = 0, \quad \sum_i \hat{\gamma}_{ij} \equiv 0, \quad \sum_j \hat{\gamma}_{ij} \equiv 0.$$

II.2.24. Hipotezes galima suformuluoti **II.1.21** pratime nurodytu būdu $H : \mathbf{H}\boldsymbol{\beta} = \boldsymbol{\theta}_0$, kai matricos \mathbf{H} ranga yra atitinkamai $I-1, J-1, (I-1)(J-1)$. Remiantis **II.1.21** pratimo p. d) hipotezė H_A atmetama, kai

$$F_A = \frac{(SS_{EH_A} - SS_E)IJ(K-1)}{(I-1)SS_E} = \frac{SS_A IJ(K-1)}{(I-1)SS_E} = \frac{MS_A}{MS_E} > F_\alpha(I-1, IJ(K-1)),$$

čia SS_E liekamoji kvadratų suma (žr. **II.2.22** pratimą); SS_{EH_A} yra sąlyginis kvadratinės formos $SS(\boldsymbol{\beta})$ minimumas, surastas esant sąlygai, kad H_A teisinga.

Sąlyginį kvadratinės formos minimumą lengva surasti tokiu būdu. Tapatybės

$$Y_{ijk} - \mu_{ij} = (Y_{ijk} - \hat{\mu}_{ij}) + (\hat{\alpha}_i - \alpha) + (\hat{\beta}_j - \beta) + (\hat{\gamma}_{ij} - \gamma_{ij}) + (\hat{\mu} - \mu)$$

abi puses pakelkime kvadratu ir susumuokime pagal i, j, k . Gauname

$$S(\boldsymbol{\beta}) = SS_E + JK \sum_i (\hat{\alpha}_i - \alpha)^2 + IK \sum_j (\hat{\beta}_j - \beta)^2 + K \sum_i \sum_j (\hat{\gamma}_{ij} - \gamma_{ij})^2 + IJK(\hat{\mu} - \mu)^2,$$

nes visos mišrios sandaugos lygios nuliui. Tada

$$SS_{EH_A} = \min_{\alpha_i=0} SS(\boldsymbol{\beta}) = SS_E + JK \sum_i \hat{\alpha}_i^2,$$

$$SS_A = JK \sum_i \hat{\alpha}_i^2 = JK \sum_i (\bar{Y}_{i..} - \bar{Y}_{...})^2.$$

Analogiškai

$$SS_B = IK \sum_j \hat{\beta}_j^2 = IK \sum_j (\bar{Y}_{.j.} - \bar{Y}_{...})^2,$$

$$SS_{AB} = K \sum_i \sum_j (\bar{Y}_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2.$$

Hipotezės H_B, H_{AB} atmetamos, kai atitinkamai

$$F_B = \frac{MS_B}{MS_E} > F_\alpha(J-1, IJ(K-1)), \quad F_{AB} = \frac{MS_{AB}}{MS_E} > F_\alpha((I-1)(J-1), IJ(K-1)).$$

Skaičiavimo rezultatai analizė atliekant kompiuteriu pateikiami tokioje lentelėje.

Dispersinės analizės lentelė

Faktorius	SS	ν	$MS = SS/\nu$	$E(MS)$
A	SS_A	$I - 1$	MS_A	$\sigma^2 + JK\sigma_A^2$
B	SS_B	$J - 1$	MS_B	$\sigma^2 + IK\sigma_B^2$
$A \times B$	SS_{AB}	$(I - 1)(J - 1)$	MS_{AB}	$\sigma^2 + K\sigma_{AB}^2$
E	SS_E	$IJ(K - 1)$	MS_E	σ^2
T	SS_T			

Parametrai $\sigma_A^2, \sigma_B^2, \sigma_{AB}^2$ pateikti **II.2.26** pratime.

II.2.25. a) Pakanka patikrinti, kad bet kuris sistemų $\{\bar{Y}_{...}\}$, $\{\bar{Y}_{i..} - \bar{Y}_{...}\}$, $\{\bar{Y}_{.j} - \bar{Y}_{...}\}$, $\{\bar{Y}_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j} + \bar{Y}_{...}\}$, $\{Y_{ijk} - \bar{Y}_{ij.}\}$ a. d. yra nekoreliuotas su bet kuriuo kitos sistemos a. d. Pavyzdžiu,

$$\text{Cov}(\bar{Y}_{i..} - \bar{Y}_{...}, \bar{Y}_{.j} - \bar{Y}_{...}) = \frac{K\sigma^2}{JKIK} - \frac{JK\sigma^2}{JKIJK} - \frac{IK\sigma^2}{IJKIK} + \frac{IJK\sigma^2}{(IJK)^2} = 0.$$

- b) Reikia daugianarį pakelti kvadratu ir sutraukti panašiuosius narius.
c) Užrašę kvadratų sumas p. b) nurodytu būdu ir sudejė, gausime pateiktą lygybę.

II.2.26. a) Remiantis **II.1.21** pratimu

$$SS_A/\sigma^2 \sim \chi^2(I - 1; \lambda_A), \quad \lambda_A = JK \sum_i \alpha_i^2/\sigma^2.$$

Gauname

$$E(MS_A) = E\left(\frac{SS_A}{I - 1}\right) = \frac{\sigma^2}{I - 1}(I - 1 + \lambda_A) = \sigma^2 + \frac{JK}{I - 1} \sum_i \alpha_i^2,$$

taigi **II.2.24** pratime $\sigma_A^2 = \sum_i \alpha_i^2/(I - 1)$. Analogiskai gauname

$$E(MS_B) = \sigma^2 + \frac{IK}{J - 1} \sum_j \beta_j^2, \quad E(MS_{AB}) = \sigma^2 + \frac{K}{(I - 1)(J - 1)} \sum_i \sum_j \gamma_{ij}^2.$$

b) Kriterijų galios išreiškiamos necentrinio Fišerio skirstinio pasiskirstymo funkcijomis. Pavyzdžiu, hipotezės H_A tikrinimo kriterijaus galia

$$\beta_A(\lambda_A) = P\{F_{I-1, IJ(K-1); \lambda_A} > F_\alpha(I - 1, IJ(K - 1))\}.$$

Analogiskai hipotezių H_B ir H_{AB} atvejais.

II.2.27. Imdami kvadratinės formos

$$SS(\boldsymbol{\beta}) = \sum_i \sum_j (Y_{ij} - \mu - \alpha_i - \beta_j)^2$$

išvestines pagal μ, α_i, β_j prilyginę nuliui, gausime įvertinius

$$\hat{\mu} = \bar{Y}_{..}, \quad \hat{\alpha}_i = \bar{Y}_{i..} - \bar{Y}_{..}, \quad i = 1, \dots, I; \quad \hat{\beta}_j = \bar{Y}_{.j} - \bar{Y}_{..}, \quad j = 1, \dots, J.$$

Gautieji įvertiniai tenkina sąlygas

$$\sum_i \hat{\alpha}_i = 0, \quad \sum_j \hat{\beta}_j = 0.$$

Liekamoji kvadratų suma

$$\begin{aligned} SS_{AB} &= \sum_i \sum_j (Y_{ij} - \hat{\mu} - \hat{\alpha}_i - \hat{\beta}_j)^2 = \sum_i \sum_j (Y_{ij} - \bar{Y}_{i\cdot} - \bar{Y}_{\cdot j} + \bar{Y}_{..})^2 = \\ &\sum_i \sum_j (e_{ij} - \bar{e}_{i\cdot} - \bar{e}_{\cdot j} + \bar{e}_{..})^2 \sim \sigma^2 \chi^2_{(I-1)(J-1)}. \end{aligned}$$

Dispersijos σ^2 nepaslinktasis įvertinys

$$s^2 = \frac{SS_{AB}}{(I-1)(J-1)} = MS_{AB}, \quad \mathbf{E}s^2 = \sigma^2.$$

b) Išreiškė $\alpha_I = -\alpha_1 - \dots - \alpha_{I-1}$ ir $\beta_J = -\beta_1 - \dots - \beta_{J-1}$, gausime tiesinį modelį

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e},$$

kai nežinomų parametru vektorius $\boldsymbol{\beta} = (\mu, \alpha_1, \dots, \alpha_{i-1}, \beta_1, \dots, \beta_{J-1})^T$. Plano matrica \mathbf{A} turi IJ eilučių ir $1 + (I-1) + (J-1) = I + J - 1$ stulpelių. Pirmojo matricos \mathbf{A} stulpelio elementai lygūs 1. Tolimesni $I-1$ stulpelių yra tokie: pirmosios J eilučių turi pavidalą $(1, 0, \dots, 0)$, paskui J eilučių turi pavidalą $(0, 1, \dots, 0)$, pagaliau J eilučių turi pavidalą $(0, 0, \dots, 1)$; paskutinės J eilučių turi pavidalą $(-1, -1, \dots, -1)$. Aptarsime paskutinius $J-1$ matricos \mathbf{A} stulpelius: pirmoji eilutė yra $(1, 0, \dots, 0)$, antroji $(0, 1, \dots, 0)$, $(J-1)$ -oji $(0, 0, \dots, 1)$, o J -oji $(-1, -1, \dots, -1)$. Po to šios J eilučių pakartojomos dar $I-1$ kartą.

Remiantis II.1.26 pratimu statistika

$$\mathbf{T} = ((\mathbf{A}^T \mathbf{Y})^T, \mathbf{Y}^T \mathbf{Y}) = (IJ\bar{Y}_{..}, J(\bar{Y}_{1\cdot} - \bar{Y}_{I\cdot}), \dots, J(\bar{Y}_{I-1\cdot} - \bar{Y}_{I\cdot}),$$

$$I(\bar{Y}_{\cdot 1} - \bar{Y}_{\cdot J}), \dots, I(\bar{Y}_{\cdot, J-1} - \bar{Y}_{\cdot J}), \mathbf{Y}^T \mathbf{Y})^T$$

yra pilnoji ir pakankamoji parametru $\boldsymbol{\beta}$ statistika.

Kadangi p. a) surasti įvertiniai yra nepaslinktieji ir yra statistikos T funkcijos, tai jie yra NMD įvertiniai.

II.2.28. Analogiškai kaip II.2.22 pratime, gausime, kad hipotezės H_A, H_B atmetamos reikšmingumo lygmens α kriterijais, kai atitinkamai

$$F_A = \frac{MS_A}{MS_{AB}} > F_\alpha(I-1, (I-1)(J-1)), \quad F_B = \frac{MS_B}{MS_{AB}} > F_\alpha(J-1, (I-1)(J-1)),$$

čia

$$MS_A = \frac{SS_A}{I-1} = \frac{J}{I-1} \sum_i (\bar{Y}_{i\cdot} - \bar{Y}_{..})^2, \quad MS_B = \frac{SS_B}{J-1} = \frac{I}{J-1} \sum_j (\bar{Y}_{\cdot j} - \bar{Y}_{..})^2,$$

o SS_{AB} liekamoji kvadratų suma iš II.2.27 pratimo. Lyginant su II.2.24 pratimo kriterijais skirtumas yra tas, kad statistikų vardiklyje vietoje SS_E yra SS_{AB} .

II.2.29. Irodyta, kad esant teisingai hipotezei H_γ (žr. [3], 2.2.5 skyrelj) statistika

$$SS_\gamma = \frac{\sum_i \sum_j \hat{\alpha}_i \hat{\beta}_j Y_{ij}}{\sum_i \hat{\alpha}_i^2 \sum_j \hat{\beta}_j^2} \sim \sigma^2 \chi_1^2,$$

čia $\hat{\alpha}_i = \bar{Y}_{i\cdot} - \bar{Y}_{..}$, $\hat{\beta}_j = \bar{Y}_{\cdot j} - \bar{Y}_{..}$, ir nepriklauso nuo

$$SS_L = SS_{AB} - SS_\gamma \sim \sigma^2 \chi_{IJ-I-J}^2.$$

Tjukio kriterijus atmeta hipotezę H_γ reikšmingumo lygmens α kriterijumi, kai

$$F_\gamma = \frac{SS_\gamma(IJ - I - J)}{SS_L} > F_\alpha(1, IJ - I - J).$$

II.2.30. Stjudento kriterijus atmeta hipotezę H_A , kai

$$|t| = \sqrt{J(J-1)} \frac{|\bar{Y}_{1\cdot} - \bar{Y}_{2\cdot}|}{\sqrt{\sum_j (Z_j - \bar{Z}_{\cdot})^2}} > T_{\alpha/2}(J-1).$$

Randame

$$\begin{aligned} SS_A &= J \sum_{i=1}^2 (\bar{Y}_{i\cdot} - \bar{Y}_{..})^2 = J[(\bar{Y}_{1\cdot} - \frac{\bar{Y}_{1\cdot} + \bar{Y}_{2\cdot}}{2})^2 + (\bar{Y}_{2\cdot} - \frac{\bar{Y}_{1\cdot} + \bar{Y}_{2\cdot}}{2})^2] = \\ &\quad J(\bar{Y}_{1\cdot} - \bar{Y}_{2\cdot})^2 / 2; \\ SS_{AB} &= \sum_j (Y_{1j} - \bar{Y}_{1\cdot} - \bar{Y}_{\cdot j} + \bar{Y}_{..})^2 + \sum_j (Y_{2j} - \bar{Y}_{2\cdot} - \bar{Y}_{\cdot j} + \bar{Y}_{..})^2 = \\ &\quad \sum_j (Z_j - \bar{Z}_{\cdot})^2 / 2. \end{aligned}$$

Gauname

$$F_A = \frac{MS_A}{MS_{AB}} = \frac{SS_A(J-1)}{SS_{AB}} = J(J-1) \frac{(\bar{Y}_{1\cdot} - \bar{Y}_{2\cdot})^2}{\sum_j (Z_j - \bar{Z}_{\cdot})^2} = t^2.$$

Kriterijus

$$F_A > F_\alpha(1, J-1),$$

akivaizdu, ekvivalentus Stjudento kriterijui.

II.2.31. a) Statistika, kuri esant teisingai hipotezei turi Fišerio skirstinį su 1 ir 9 laisvės laipsniais, įgijo reikšmę 21,824; hipotezė atmetama kriterijumi, kurio reikšmingumo lygmuo $\alpha > \mathbf{P}\{F_{1,9} > 21,824\} = 0,0012$; b) $n \geq 32$.

II.2.32. Atlikę skaičiavimus gauname dispersinės analizės lentelę

Faktorius	SS	ν	MS	F	Pr>F
A	3.649	3	1.216	2.48	0.0980
B	0.331	1	0.331	0.68	0.4228
$A \times B$	0.043	3	0.014	0.03	0.9930
E	7.835	16	0.490		
T	11.859	23			

Gauname statistikų realizacijas $F_A = 2,48$, $F_B = 0,68$, $F_{AB} = 0,03$, kurias atitinka P reikšmės 0,0980, 0,4228, 0,9930.

II.2.33. Tjukio statistika F_γ įgijo reikšmę 0,7234; $\mathbf{P}\{F_{1,5} > 0,7234\} = 0,4339$; atmesti hipotezė nėra pagrindo. Gauname statistikų realizacijas $F_A = 9,01$, $F_B = 4,61$, kurias atitinka P reikšmės 0,0122, 0,0613.

II.2.34. Tjukio statistika F_γ įgijo reikšmę 2,2754; $\mathbf{P}\{F_{1,34} > 2,2754\} = 0,1407$; atmesti hipotezė nėra pagrindo. Gauname statistikų realizacijas $F_A = 9,11$, $F_B = 15,31$. Hipotezės atmestinos.

II.2.35. Kvadratų suma

$$SS_B/\sigma^2 \sim \chi^2(J-1; \lambda_B), \quad \lambda_B = I \sum_{i=1}^8 \beta_j^2.$$

Vidurkis $\bar{\mu} = \mu + 10$; $\beta_6 = \beta_7 = \beta_8 = -10$, $\beta_1 = \beta_2 = \beta_6 = 2$, $\beta_3 = \beta_4 = 12$ ir $\lambda_B = 3600/\sigma^2$ (σ^2 iš **2.34** pratimo). Statistika F_B turi necentrinį Fišerio skirstinį su 7 ir 35 laisvės laipsniais ir necentriškumo parametru λ_B . Randame $\mathbf{P}\{F_{7,35;\lambda_B} > F_{0,05}(7, 35)\}$.

II.2.36. Tarkime, $\mu_5 = \mu_7 = \mu$, $\mu_8 = \mu + 10$. Tada

$$SS_B/\sigma^2 \sim \chi^2(2; \lambda_B), \quad \lambda_B = n \sum_j \beta_j^2.$$

Vidurkis $\bar{\mu} = \mu + 10/3$; $\beta_5 = \beta_7 = 10/3$, $\beta_8 = -20/3$, ir $\lambda_B = 200n/(3\sigma^2)$ (σ^2 iš **II.2.34** pratimo).

Imties didumui rasti turime nelygybę

$$\mathbf{P}\{F_{2,2(n-1);\lambda_B} > F_{0,05}(2, 2(n-1))\} \geq 0,8.$$

II.2.37. Gauname statistikų realizacijas $F_A = 8,31$, $F_B = 5,94$, $F_{AB} = 1,29$, kurias atitinka P reikšmės 0,000021, 0,0002, 0,2206.

II.2.38. Statistika F_{AB} įgijo reikšmę 1,92; P reikšmė 0,0807; a) Gauname statistikų realizacijas $F_A = 4,54$, $F_B = 0,42$, kurias atitinka P reikšmės 0,0066, 0,7362; b) Gauname statistikų realizacijas $F_A = 4,40$, $F_B = 0,26$, kurias atitinka P reikšmės 0,0085, 0,8546.

II.2.39. Randame

$$SS_A = JK[(\bar{Y}_{1..} - \frac{\bar{Y}_{1..} + \bar{Y}_{2..}}{2})^2 + (\bar{Y}_{2..} - \frac{\bar{Y}_{1..} + \bar{Y}_{2..}}{2})^2] = \\ JK(\bar{Y}_{1..} - \bar{Y}_{2..})^2/2;$$

$$SS_{AB} = K[\sum_j (\bar{Y}_{1j.} - \bar{Y}_{1..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2 + \sum_j (\bar{Y}_{2j.} - \bar{Y}_{2..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2] = \\ K \sum_j (\bar{Y}_{1j.} + \bar{Y}_{2j.})^2/2 - JK(\bar{Y}_{1..} + \bar{Y}_{2..})^2/2.$$

Jeigu $K = 2$, tai

$$SS_E = \sum_i \sum_j [(Y_{ij1} - \bar{Y}_{ij.})^2 + (Y_{ij2} - \bar{Y}_{ij.})^2] = \sum_i \sum_j (Y_{ij1} - Y_{ij2})^2/2.$$

II.2.40. a) Gauname

$$SS_E = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{ij.})^2 = \sum_i \sum_j \sum_k (e_{ijk} - \bar{e}_{ij.})^2 \sim \sigma^2 \chi^2_{IJ(K-1)}$$

ir $\mathbf{E}(MS_E) = \sigma^2$.

$$SS_A = JK \sum_i (\bar{Y}_{i..} - \bar{Y}_{...})^2 = JK \sum_i (a_i + \bar{c}_{i..} + \bar{e}_{i..} - (\bar{a}_{..} + \bar{c}_{..} + \bar{e}_{...}))^2 =$$

$$JK \sum_i (Z_i - \bar{Z}_{..})^2 \sim (\sigma^2 + K\sigma_{AB}^2 + JK\sigma_A^2) \chi^2_{I-1},$$

nes vienodai pasiskirstę n. a. d. $Z_i = a_i + \bar{c}_{i..} + \bar{e}_{i..} \sim N(0, \sigma_A^2 + \sigma_{AB}^2/J + \sigma^2/(JK))$. Taigi $\mathbf{E}(MS_A) = \sigma^2 + K\sigma_{AB}^2 + JK\sigma_A^2$.

Analogiškai gauname, kad

$$\mathbf{E}(MS_B) = \sigma^2 + K\sigma_{AB}^2 + IK\sigma_B^2, \quad \mathbf{E}(MS_{AB}) = \sigma^2 + K\sigma_{AB}^2.$$

Dispersinės analizės lentelė skirsis nuo **II.2.24** pratimo lentelės tik paskutiniuoju stupeliu, kuriame reikia išrašyti šiame pratime gautas $\mathbf{E}(MS)$ išraiškas.

b) Parametru μ NMD įvertinys

$$\hat{\mu} = \bar{Y}_{...} = \mu + \bar{a}_{..} + \bar{b}_{..} + \bar{c}_{..} + \bar{e}_{...} \sim N(\mu, \sigma_A^2/I + \sigma_B^2/J + \sigma_{AB}^2/(IJ) + \sigma^2/(IJK)).$$

Kitų parametrų NMD įvertiniai randami remiantis gautomis $\mathbf{E}(MS)$ išraiškomis.

$$\hat{\sigma}_A^2 = \frac{MS_A - MS_{AB}}{JK}, \quad \hat{\sigma}_B^2 = \frac{MS_B - MS_{AB}}{IK},$$

$$\hat{\sigma}_{AB}^2 = \frac{MS_{AB} - MS_E}{K}, \quad \hat{\sigma}^2 = MS_E.$$

II.2.41. a) Kvadratų sumos sudarytos iš tokiu a. d. sistemų $\{a_i - \bar{a}_i\}$, $\{b_j - \bar{b}_j\}$, $\{c_{ij} - \bar{c}_{i..} - \bar{c}_{.j} + \bar{c}_{..}\}$, $\{\bar{c}_{i..} + \bar{c}_{..}\}$, $\{\bar{e}_{i..} + \bar{e}_{...}\}$, $\{\bar{r}_{.j..} + \bar{e}_{...}\}$, $\{\bar{e}_{ij.} - \bar{e}_{i..} - \bar{e}_{.j..} + \bar{e}_{...}\}$, $\{e_{ijk} - \bar{e}_{ij.}\}$. Kadangi a. d., žymimi skirtinomis raidėmis, yra nepriklausomi, tai reikia tik įsitikinti, kad a. d. sistemos, sudarytos iš vienodomis raidėmis žymimų a. d., yra nepriklausomos. Tarkime, kad schemaje su pastoviais faktoriais kintamuosius Y_{ijk} atitinka e_{ijk} . Tada remdamiesi **II.2.25** pratimu gauname, kad a. d., žymimų raidėmis e, sistemos yra nepriklausomos. Analogiškai tarę, kad schemaje su vienu stebėjime langelyje kintamuosius Y_{ij} atitinka c_{ij} , gausime, kad a. d. sistemos, žymimos raidėmis c, yra nepriklausomos.

b) Remdamiesi p. a) ir **II.2.40** pratimu gaume

$$\mathbf{V}(\hat{\sigma}_A^2) = \frac{1}{J^2 K^2} [\mathbf{V}(MS_A) + \mathbf{V}(MS_{AB})] = \frac{2}{J^2 K^2} \left[\frac{(\mathbf{E}(MS_A))^2}{I-1} + \frac{(\mathbf{E}(MS_{AB}))^2}{(I-1)(J-1)} \right],$$

$$\mathbf{V}(\hat{\sigma}_B^2) = \frac{2}{I^2 K^2} \left[\frac{(\mathbf{E}(MS_B))^2}{J-1} + \frac{(\mathbf{E}(MS_{AB}))^2}{(I-1)(J-1)} \right], \quad \mathbf{V}(\hat{\sigma}^2) = \frac{2\sigma^4}{IJ(K-1)},$$

$$\mathbf{V}(\hat{\sigma}_{AB}^2) = \frac{2}{K^2} \left[\frac{(\mathbf{E}(MS_{AB}))^2}{(I-1)(J-1)} + \frac{(\mathbf{E}(MS_E))^2}{IJ(K-1)} \right].$$

c) Remiantis **II.2.40** pratimu santykiai $SS/\mathbf{E}(MS) \sim \chi^2(\nu)$. Pasirinkę bet kurių dviejų skirtingų trupmenų $MS/\mathbf{E}(MS)$ santykius gausime Fišerio skirstinį su atitinkamais laisvės laipsniais. Tikrinant hipotezę $H_A : \sigma_A^2 = 0$, reikia imti santykį trupmenų $MS_A/\mathbf{E}(MS_A)$ ir $MS_{AB}/\mathbf{E}(MS_{AB})$, nes esant teisingai hipotezei H_A vidurkiai $\mathbf{E}(MS_A)$ ir $\mathbf{E}(MS_{AB})$ sutampa. Gauname statistiką $F_A = MS_A/MS_{AB}$. Hipotezė H_A atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_A = \frac{MS_A}{MS_{AB}} > F_\alpha(I - 1, (I - 1)(J - 1)).$$

Analogiškai hipotezės H_B ir H_{AB} atmetamos, kai

$$F_B = \frac{MS_B}{MS_{AB}} > F_\alpha(J - 1, (I - 1)(J - 1)),$$

$$F_{AB} = \frac{MS_{AB}}{MS_E} > F_\alpha((I - 1)(J - 1), IJ(K - 1)).$$

Matome, kad, skirtingai nuo schemos su pastoviais faktoriais, tikrinant hipotezes H_A ir H_B statistikos vardiklyje vietoje MS_E yra MS_{AB} .

Jeigu hipotezės neteisingos, tai statistikos skiriiasi nuo Fišerio a. d. tik daugikliu. Todėl galios funkcijos išreiškiamos centrinio Fišerio skirstinio pasiskirstymo funkcija. Pavyzdžiui, tikrinant hipotezę $H_A : \sigma^2 = 0$, kriterijaus galios funkcija

$$\begin{aligned} \beta(\sigma_A^2) &= \mathbf{P}\left\{\frac{MS_A}{MS_{AB}} > F_\alpha(I - 1, (I - 1)(J - 1)) | \sigma_A^2\right\} = \\ &= \mathbf{P}\left\{F_{I-1, (I-1)(J-1)} > \frac{\sigma^2 + K\sigma_{AB}^2}{\sigma^2 + K\sigma_{AB}^2 + JK\sigma_A^2} F_\alpha(I - 1, (I - 1)(J - 1))\right\} \end{aligned}$$

artėja prie vieneto, kai santykis $JK\sigma_A^2/(\sigma^2 + K\sigma_{AB}^2)$ didėja.

II.2.42. a) Hipotezė atmetama α lygmens kriterijumi, kai $F_A = MS_A/MS_{AB} > (1 + JK\Delta)F_\alpha(I - 1, (I - 1)(J - 1))$; b) Hipotezė atmetama α lygmens kriterijumi, kai $F_{AB} = MS_{AB}/MS_E > (1 + K\Delta)F_\alpha((I - 1)(J - 1), IJ(K - 1))$.

II.2.43. a) Gauname $F_A = 21,196$, $F_B = 2439,686$, $F_{AB} = 28,846$; visos trys hipotezės atmetamos. b) $\hat{\sigma}^2 = 0,221$; $\hat{\sigma}_{AB}^2 = 0,559$; $\hat{\sigma}_A^2 = 2,926$; $\hat{\sigma}_B^2 = 56,533$; $\hat{\mathbf{V}}(\hat{\sigma}^2) = 0,000089$; $\hat{\mathbf{V}}(\hat{\sigma}_{AB}^2) = 0,00933$; $\hat{\mathbf{V}}(\hat{\sigma}_A^2) = 0,7865$; $\hat{\mathbf{V}}(\hat{\sigma}_B^2) = 2132,415$. c) Taikydami normaliajų aproksimaciją gauname parametrų $\sigma_A^2, \sigma_B^2, \sigma_{AB}^2, \sigma^2$ pasikliovimo intervalus: $(1, 188; 4, 664)$, $(0; 147, 042)$, $(0, 370; 0, 748)$, $(0, 203; 0, 239)$.

II.2.44. Gauname statistikų realizacijas $F_A = 9,01$, $F_B = 4,61$, kurias atitinka P reikšmės $0,0122$, $0,0613$.

II.2.45. Gaume statistikų realizacijas $F_A = 6,44$, $F_B = 4,60$, $F_{AB} = 1,29$, kurias atitinka P reikšmės $0,0017$, $0,0059$, $0,2206$.

II.2.46. Kvadratų suma

$$SS_E = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{ij.})^2 = \sum_i \sum_j \sum_k (e_{ijk} - \bar{e}_{ij.})^2 \sim \sigma^2 \chi^2_{IJ(K-1)}$$

turi tokias pačias savybes, kaip ir ankstesnėse schemose; $\mathbf{E}(MS_E) = \sigma^2$. Kvadratų suma

$$SS_B = IK \sum_j (\bar{Y}_{j\cdot} - \bar{Y}_{\dots})^2 = IK \sum_j (b_j + \bar{e}_{j\cdot} - \bar{b}_{\cdot} - \bar{e}_{\dots})^2 \sim (\sigma^2 + IK\sigma_B^2)\chi_{J-1}^2,$$

$$\mathbf{E}(MS_B) = \sigma^2 + IK\sigma_B^2,$$

nes vienodai pasiskirstę n. a. d. $b_j + \bar{e}_{j\cdot} \sim N(0, \sigma_B^2 + \sigma^2/(IK))$.

Likusių kvadratų sumų

$$SS_A = JK \sum_i (\bar{Y}_{i..} - \bar{Y}_{\dots})^2 = JK \sum_i (\alpha_i + \bar{c}_{i\cdot} + \bar{e}_{i..} - \bar{e}_{\dots})^2,$$

$$SS_{AB} = K \sum_i \sum_j (c_{ij} - \bar{c}_{i\cdot} + \bar{e}_{ij\cdot} - \bar{e}_{i..} - \bar{e}_{j\cdot} + \bar{e}_{\dots})^2$$

skirstiniai bendru atveju nesuvedamai į χ^2 skirstinius. Adityviuoju atveju ($c_{ij} \equiv 0$) SS_A suvedama į necentrinį χ^2 , o SS_{AB} – į centrinį χ^2 skirstinį. Rasime vidurkius

$$\mathbf{E}(SS_A) = JK \sum_i \alpha_i^2 + JK \sum_i \mathbf{E}(\bar{c}_{i\cdot})^2 + JKE(\sum_i (\bar{e}_{i..} - \bar{e}_{\dots})^2) =$$

$$JK \sum_i \alpha_i^2 + K \sum_i \sigma_{AB;i}^2 + \sigma^2(I-1),$$

$$\mathbf{E}(MS_A) = \sigma^2 + K\sigma_{AB}^2 + JK\sigma_A^2; \quad \sigma_A^2 = \frac{1}{I-1} \sum_i \alpha_i^2, \quad \sigma_{AB}^2 = \frac{1}{I-1} \sum_i \sigma_{AB;i}^2.$$

$$\mathbf{E}(SS_{AB}) = K\mathbf{E}(\sum_i \sum_j (c_{ij} - \bar{c}_{i\cdot})^2) + K\mathbf{E}(\sum_i \sum_j (\bar{e}_{ij\cdot} - \bar{e}_{i..} - \bar{e}_{j\cdot} + \bar{e}_{\dots})^2) =$$

$$K(J-1) \sum_i \sigma_{AB;i}^2 + (I-1)(J-1)\sigma^2; \quad \mathbf{E}(MS_{AB}) = \sigma^2 + K\sigma_{AB}^2.$$

Dispersinės analizės lentelė skirsis nuo **II.2.24** pratimo lentelės tik paskutiniu stulpeliu, kuriam reikia išrašyti šiame pratime surastas $\mathbf{E}(MS)$ išraiškas.

II.2.47. a) Naudodami surastas $\mathbf{E}(MS)$ išraiškas gauname

$$\hat{\sigma}_A^2 = \frac{MS_A - MS_{AB}}{JK}, \quad \hat{\sigma}_B^2 = \frac{MS_B - MS_{AB}}{IK},$$

$$\hat{\sigma}_{AB}^2 = \frac{MS_{AB} - MS_E}{K}, \quad \hat{\sigma}^2 = MS_E.$$

b) Hipotezė H_B atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_B = \frac{MS_B}{MS_E} > F_\alpha(J-1, IJ(K-1));$$

kriterijaus galia išreiškiama centrinio Fišerio skirstinio pasiskirstymo funkcija. Atkreipime dėmesį, kad tikrinama hipotezė apie atsitiktinio faktoriaus įtakos nebuviną, tačiau statistikos vardiklyje yra MS_E (kaip schemaje su pastoviais faktoriais).

Jeigu hipotezė H_{AB} teisinga (t. y. $c_{ij} \equiv 0$), tai santykis

$$F_{AB} = \frac{MS_{AB}}{MS_E} \sim F((I-1)(J-1), IJ(K-1)).$$

Hipotezė H_{AB} atmetama, kai

$$F_{AB} > F_\alpha((I-1)(J-1), IJ(K-1)),$$

t. y. kaip ir ankstesnėse schemose. Tačiau kriterijaus galia žinomais skirstiniai neišreiškiamas.

Kai teisinga hipotezė $H_A : \alpha_1 = \dots = \alpha_I = 0$, statistikos

$$F_A = \frac{MS_A}{MS_{AB}}$$

skaitiklio ir vardiklio vidurkiai vienodi, tačiau jų skirstiniai nėra χ^2 skirstiniai. Todėl kriterijus: atmeti H_A , kai teisinga nelygybė

$$F_A > F_\alpha(I-1, (I-1)(J-1)),$$

yra apytikslis. Jeigu faktorių sąveikos nėra ($c_{ij} \equiv 0$), tai F_A turi centrinį Fišerio skirstinį, kai H_A teisinga, ir necentrinį Fišerio skirstinį, kai H_A neteisinga. Taigi šiuo atveju kriterijus yra tikslus.

II.2.48. a) Gauname statistikų realizacijas $F_A = 4,04, F_B = 2,63, F_{AB} = 2,46$, kurias atitinka P reikšmės 0,0613, 0,0537, 0,0534; b) Gauname statistikų realizacijas $F_A = 9,92, F_B = 2,63, F_{AB} = 2,46$, kurias atitinka P reikšmės 0,0005, 0,0537, 0,0534.

II.2.49. Gauname statistikų realizacijas $F_A = 6,29, F_B = 1,05, F_{AB} = 2,39$, kurias atitinka P reikšmės 0,0097, 0,4116, 0,0087.

II.2.50. Gauname statistikų realizacijas $F_A = 1,94, F_B = 0,49$, kurias atitinka P reikšmės 0,0801, 0,7813.

II.2.51. Gauname statistikų realizacijas $F_A = 2,48, F_B = 23,21, F_{AB} = 0,03$, kurias atitinka P reikšmės 0,0980, 0,0170, 0,9930.

II.2.52. Gauname statistikų realizacijas $F_A = 9,11, F_B = 15,312, F_{AB} = 2,46$. Hipotezes atmetame.

II.2.3 skyrelis

II.2.53. Reikia patikrinti, kad su visais i, j, l galioja lygypės

$$\mu_{ijl} - \bar{\mu}_{ij.} - \bar{\mu}_{i.l} - \bar{\mu}_{.jl} + \bar{\mu}_{i..} + \bar{\mu}_{.j.} + \bar{\mu}_{..l} - \bar{\mu}_{...} = 0.$$

II.2.54. $\hat{\mu} = \bar{Y}_{...}$, $\hat{\alpha}_i = \bar{Y}_{i..} - \bar{Y}_{...}$, $\hat{\beta}_{ij} = \bar{Y}_{ij.} - \bar{Y}_{i..}$, $\hat{\gamma}_k = \bar{Y}_{..k} - \bar{Y}_{...}$; hipotezė H_A atmetama α lygmens kriterijumi, kai $(SS_{EH_A} - SS_E)(IJK - IJ - K + 1)/(I-1)SS_E > F_\alpha(I-1, (IJ-1)(K-1))$; $SS_E = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{ij.} + \bar{Y}_{..k} - \bar{Y}_{...})^2$; $SS_{EH_A} = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{i..} - \bar{Y}_{..k} + \bar{Y}_{...})^2$.

II.2.55. Formalios daugiafaktorės dispersinės analizės lentelės sudarymo taisyklės subalansuotų planų atveju pateiktos [3], 2.7 skyrelyje. Tos lentelės skiriasi paskutiniuoju stulpeliu, kuriami pateikiami vidutinių kvadratų sumų vidurkiai. Trijų atsitiktinių faktorių atveju gauname

$$\mathbf{E}(MS_E) = \sigma^2, \quad \mathbf{E}(MS_{ABC}) = \sigma^2 + K\sigma_{ABC}^2, \quad \mathbf{E}(MS_{AB}) = \sigma^2 + K\sigma_{ABC}^2 + LK\sigma_{AB}^2,$$

$$\mathbf{E}(MS_{AC}) = \sigma^2 + K\sigma_{ABC}^2 + jK\sigma_{AC}^2, \quad \mathbf{E}(MS_{BC}) = \sigma^2 + K\sigma_{ABC}^2 + IK\sigma_{BC}^2,$$

$$\mathbf{E}(MS_A) = \sigma^2 + K\sigma_{ABC}^2 + LK\sigma_{AB}^2 + JK\sigma_{AC}^2 + JLK\sigma_A^2,$$

$$\mathbf{E}(MS_B) = \sigma^2 + K\sigma_{ABC}^2 + LK\sigma_{AB}^2 + IK\sigma_{BC}^2 + ILK\sigma_B^2,$$

$$\mathbf{E}(MS_C) = \sigma^2 + K\sigma_{ABC}^2 + JK\sigma_{AC}^2 + IK\sigma_{BC}^2 + IJK\sigma_C^2.$$

Hipotezė H_{ABC} atmetama, kai $MS_{ABC}/MS_E > F_\alpha((I-1)(J-1)(L-1), IJL(K-1))$; hipotezė H_{AB} atmetama, kai $MS_{AB}/MS_{ABC} > F_\alpha((I-1)(J-1), (I-1)(J-1)(L-1))$: analogiškai hipotezių H_{AC} ir H_{BC} atvejais; neegzistuoja tokie du MS , kad jų vidurkiai sutaptų esant teisingai hipotezei H_A ; remiantis [3], 2.7 skyreliu hipotezė H_A atmetama apytiksliu Fišerio kriterijumi, kai $MS_A/(MS_{AB} - MS_{AC} - MS_{BC}) > F_\alpha(I-1, \tilde{\nu})$; čia $\tilde{\nu} = (MS_{AB} + MS_{AC} - MS_{BC})^2 / [(MS_{AB})^2 / ((I-1)(J-1)) + (MS_{AC})^2 / ((I-1)(L-1)) + (MS_{BC})^2 / ((I-1)(J-1)(L-1))]$; analogiškai tikrinamos hipotezės H_B ir H_C .

II.2.56. Gauname

$$\begin{aligned} \sum_{i=1}^I (Y_i - \bar{Y}_.)^2 &= \sum_{i=1}^{I_1} (Y_i - \bar{Y}^{(1)} + \bar{Y}^{(1)} - \bar{Y}_.)^2 + \sum_{i=I_1+1}^I (Y_i - \bar{Y}^{(2)} + \bar{Y}^{(2)} - \bar{Y}_.)^2 = \\ &= \sum_{i=1}^{I_1} (Y_i - \bar{Y}^{(1)})^2 + \sum_{i=I_1+1}^I (Y_i - \bar{Y}^{(2)})^2 + I_1(\bar{Y}^{(1)} - \bar{Y}_.)^2 + I_2(\bar{Y}^{(2)} - \bar{Y}_.)^2. \end{aligned}$$

Kadangi $\bar{Y}_. = (I_1\bar{Y}^{(1)} + I_2\bar{Y}^{(2)}) / (I_1 + I_2)$, tai paskutinių dviejų dėmenų suma yra

$$\frac{I_1 I_2}{I_1 + I_2} (\bar{Y}^{(1)} - \bar{Y}^{(2)})^2.$$

II.2.57. Tegu $I = I_1 + I_2 + I_3$. Tada analogiškai **II.2.56** pratimui

$$\begin{aligned} \sum_{i=1}^I (Y_i - \bar{Y}_.)^2 &= \sum_{i=1}^{I_1} (Y_i - \bar{Y}^{(1)})^2 + \sum_{i=I_1+1}^{I_1+I_2} (Y_i - \bar{Y}^{(2)})^2 + \sum_{i=I_1+I_2+1}^I (Y_i - \bar{Y}^{(3)})^2 + \\ &\quad I_1(\bar{Y}^{(1)} - \bar{Y}_.)^2 + I_2(\bar{Y}^{(2)} - \bar{Y}_.)^2 + I_3(\bar{Y}^{(3)} - \bar{Y}_.)^2, \quad \bar{Y}_. = \sum_{i=1}^3 I_i \bar{Y}^{(i)} / I. \end{aligned}$$

II.2.58. Gauname, kad statistikos F_A, F_B, F_C įgijo reikšmes 480,47, 903,91, 786,43; hipotezės atmetamos. Statistikos F_{AB} ir F_{AC} įgijo reikšmes 17,48 ir 17,91; hipotezės atmetamos. Statistikos F_{BC} ir F_{ABC} įgyja reikšmes 2,62 ir 4,72, kurias atitinka P reikšmės 0,0571 ir 0,0011.

II.2.59. Gauname statistikų realizacijas $F_A = 9,12$, $F_B = 5,72$, $F_C = 46,50$, $F_D = 0,54$, kurias atitinka P reikšmės $0,0002$, $0,0227$, $8,85 \times 10^{-8}$, $0,6560$. Gauname statistikų realizacijas $F_{AB} = 1,44$, $F_{AC} = 0,79$, $F_{AD} = 0,34$, kurias atitinka P reikšmės $0,2475$, $0,5070$, $0,9539$. Gauname statistikų realizacijas $F_{BC} = 10,32$, $F_{BD} = 0,82$, $F_{CD} = 1,82$, kurias atitinka P reikšmės $0,0029$, $0,4897$, $0,1627$.

II.2.4 skyrelis

II.2.60. Statistikos F_A ir $F_{B(A)}$ (žr. [3], 2.9 skyrelį) įgijo reikšmes $0,60$ ir $1,76$, kurias atitinka P reikšmės $0,6700$ ir $0,0625$.

II.2.61. Statistikos F_A ir $F_{B(A)}$ (žr. [3], 2.9 skyrelį) įgijo reikšmes $3,39$ ir $4,45$, kurias atitinka P reikšmės $0,0798$ ir $0,0016$.

II.2.62. Statistikos F_A ir $F_{B(A)}$ (žr. [3], 2.9 skyrelį) įgijo reikšmes $46,78$ ir $1,27$, kurias atitinka P reikšmės $0,0002$ ir $0,3590$.

II.2.63. Hierarchinės klasifikacijos modelis. Faktoriaus B (pelė) lygmenys sugrupuoti pagal faktoriaus A (dieta) lygmenis. Abu faktoriai pastovūs. Statistikos F_A ir $F_{B(A)}$ (žr. [3], 2.9 skyrelį) įgijo reikšmes $28,67$ ir $1,08$, kurias atitinka P reikšmės $0,0007$ ir $0,3838$.

II.2.64. Apie blokuotujų duomenų analizę žr. [3], 2.10.2 skyrelį. Pagal turimus duomenis gauname statistikos F_A realizaciją $1301,7$. Hipotezė H_A atmetama.

II.2.65. Gauname statistikų realizacijas $F_A = 157,92$, $F_B = 30,42$. Hipotezės H_A ir H_B atmetinos.

II.2.66. Apie duomenų analizę, kai eksperimentas atliktas pagal nepilnų subalan-suotų blokų planą, žr. [3], 2.10.3 skyrelį. Pagal turimus duomenis gauname, kad gumos mišiniui įtaka padangų atsparumui yra statistiškai reikšminga (P reikšmė $0,0034$).

II.2.67. Gauname statistikų realizacijas $F_A = 0,17$ (operatorius) ir $F_B = 10,61$ (diena), kurias atitinka P reikšmės $0,9131$, $0,0132$.

II.2.68. Gauname statistikos realizaciją $27,24$. Hipotezė, kad skalbimo priemonės vienodos, atmetama kriterijumi su aukštu reikšmingumo lygmeniu.

II.2.69. Apie duomenų analizę, kai eksperimentas atliekamas pagal lotyniškųjų kvadratų schemą, žr. [3], 2.11 skyrelį. Pagal turimus duomenis gauname statistikos F_A realizaciją $15,83$. Hipotezė, kad elektrodų tipai vienodi, atmetama kriterijumi su aukštu reikšmingumo lygmeniu.

II.2.70. Gauname statistikos F_A realizaciją $19,63$. Hipotezė, kad veislų derlingumas vienodas, atmetama kriterijumi su aukštu reikšmingumo lygmeniu.

II.3. Regresinė analizė

II.3.1. Prognozavimo uždaviniai

II.3.1. Tarkime, reikia prognozuoti a. d. Y remiantis a. v. $\mathbf{X} = (X_1, \dots, X_m)^T$. Prognoze vadina mačiąjų funkciją $\hat{Y} = h(\mathbf{X})$, $V(h(\mathbf{X})) < \infty$, o skirtuma $Y - h(\mathbf{X})$

vadiname prognozės paklaida. Prognozė $\hat{Y} = h(\mathbf{X})$ vadinama optimaliaja, jeigu ji minimizuoja vidutinę kvadratinę paklaidą $\mathbf{E}(Y - h(\mathbf{X}))^2$. a) Irodykite, kad a. d. Y regresija a. v. \mathbf{X} atžvilgiu $\mu(\mathbf{X}) = \mathbf{E}(Y|\mathbf{X})$ yra optimalioji prognozė. b) Irodykite, kad koreliacijos koeficientas tarp Y ir prognozės $\hat{Y} = h(\mathbf{X})$ yra maksimalus, kai $\hat{Y} = \mu(\mathbf{X})$.

II.3.2. (II.3.1 pratimo tēsinys). Koreliacijos koeficiente $\rho(Y, \mu(\mathbf{X}))$ kvadratas vadinamas koreliaciniu savykiu ir žymimas

$$\eta_{Y\mathbf{X}}^2 = \eta_{Y(X_1, \dots, X_m)}^2 = \rho^2(Y, \mu(\mathbf{X})) = \mathbf{V}(\mu(\mathbf{X}))/\mathbf{V}(Y).$$

Pateikite koreliacinių savykių $\eta_{Y\mathbf{X}}^2$ interpretaciją.

II.3.3. (II.3.1 pratimo tēsinys). Suskaidykime a. v. \mathbf{X} į dvi komponentes $\mathbf{X}^{(1)} = (X_1, \dots, X_k)^T$ ir $\mathbf{X}^{(2)} = (X_{k+1}, \dots, X_m)^T$. Tada prognozės paklaidos dispersijos savykinis sumažėjimas papildžius vektorių $\mathbf{X}^{(1)}$ komponente $\mathbf{X}^{(2)}$ yra

$$\eta_{Y\mathbf{X}^{(2)}|\mathbf{X}^{(1)}}^2 = \frac{\eta_{Y\mathbf{X}}^2 - \eta_{Y\mathbf{X}^{(1)}}^2}{1 - \eta_{Y\mathbf{X}^{(1)}}^2}.$$

Dydis $\eta_{Y\mathbf{X}^{(2)}|\mathbf{X}^{(1)}} = \sqrt{\eta_{Y\mathbf{X}^{(2)}|\mathbf{X}^{(1)}}^2} \geq 0$ vadinamas daliniu koreliaciniu savykiu. Irodykite lygybę

$$1 - \eta_{Y(X_1, \dots, X_m)}^2 = \prod_{j=2}^m (1 - \eta_{YX_j|(X_1, \dots, X_{j-1})}^2)(1 - \eta_{YX_1}^2).$$

II.3.4. Prognozuodami a. d. Y apsiribokime tiesinėmis a. v. $\mathbf{X} = (X_1, \dots, X_m)^T$ funkcijomis $l(\mathbf{X}) = \alpha + \beta^T \mathbf{X}$. Optimali tiesinė prognozė $l^* = \alpha^* + (\beta^*)^T \mathbf{X}$ minimizuoja vidurki

$$SS(\alpha, \beta) = \mathbf{E}(Y - \alpha - \beta^T \mathbf{X})^2.$$

a) Irodykite, kad optimali tiesinė prognozė gaunama, kai

$$\beta^* = \Sigma^{-1} \sigma_{Y\mathbf{X}}, \quad \alpha^* = \mathbf{E}Y - (\beta^*)^T \mathbf{E}(\mathbf{X}),$$

čia $\Sigma = \mathbf{V}(\mathbf{X})$, o $\sigma_{Y\mathbf{X}} = \text{Cov}(Y, \mathbf{X})$. b) Irodykite, kad koreliacijos koeficientas tarp Y ir tiesinės prognozės $l = \alpha + \beta^T \mathbf{X}$ yra maksimalus, kai $l = l^*$.

II.3.5. (II.3.4 pratimo tēsinys). Pateikite dauginio koreliacinių koeficiente interpretaciją.

II.3.6. (II.3.4 pratimo tēsinys). Suskaidykime a. v. \mathbf{X} į dvi komponentes $\mathbf{X}^{(1)} = (X_1, \dots, X_k)^T$ ir $\mathbf{X}^{(2)} = (X_{k+1}, \dots, X_m)^T$. Tada optimalios tiesinės prognozės paklaidos dispersijos savykinis sumažėjimas papildžius vektorių $\mathbf{X}^{(1)}$ komponente $\mathbf{X}^{(2)}$ yra

$$\rho_{Y\mathbf{X}^{(2)}|\mathbf{X}^{(1)}}^2 = \frac{\rho_{Y\mathbf{X}}^2 - \rho_{Y\mathbf{X}^{(1)}}^2}{1 - \rho_{Y\mathbf{X}^{(1)}}^2}.$$

Dydis $\rho_{Y\mathbf{X}^{(2)}|\mathbf{X}^{(1)}} = \sqrt{\rho_{Y\mathbf{X}^{(2)}|\mathbf{X}^{(1)}}^2} \geq 0$ vadinamas daliniu dauginiu koreliacijos koeficientu. Irodykite, kad

$$1 - \rho_{Y(X_1, \dots, X_m)}^2 = \prod_{j=2}^m (1 - \rho_{YX_j|(X_1, \dots, X_{j-1})}^2)(1 - \rho_{YX_1}^2).$$

II.3.7. Vektorius $(X, Y)^T$ pasiskirstęs pagal dvimatį normalųjį skirstinį su nuliniaisiais vidurkiais, vienetinėmis dispersijomis ir koreliacijos koeficientu ρ . Raskite regresijos kreives: a) a. d. X atžvilgiu Y ; b) a. d. X atžvilgiu Y^2 ; c) a. d. X^2 atžvilgiu Y^2 ; d) a. d. X^2 atžvilgiu Y .

Apskaičiuokite koreliacinus santykius ir palyginkite juos su koreliacijos koeficientų kvadratais.

II.3.8. Atsitiktinis vektorius $(X, Y)^T$ turi tolygųjį skirstinį viduje elipsės

$$ax^2 + 2hxy + by^2 = c, \quad h \neq 0, \quad h^2 < ab; \quad a, b > 0.$$

Įrodykite, kad a. d. X ir Y regresija kito kintamojo atžvilgiu yra tiesinė.

II.3.9. Atsitiktinis vektorius $(X, Y)^T$ tolygiai pasiskirstęs lygiagretainyje, apribo- tame tiesėmis $x = 3(y+1)$, $x = 3(y-1)$, $x = y+1$, $x = y-1$. Įrodykite, kad atsitiktinio dydžio Y regresija X atžvilgiu yra tiesinė, o X regresija Y atžvilgiu yra kreivė, susidedanti iš trijų atkarpu.

II.3.10. Atsitiktinis vektorius $(X, Y)^T$ tolygiai pasiskirstęs ant pusapskritimio $y = +\sqrt{1-x^2}$, $0 \leq x \leq 1$. Įrodykite, kad $\eta_{YX}^2 = 1$, o $\rho_{YX}^2 = 0$.

II.3.11. Atsitiktinis vektorius $(X, Y)^T$ tolygiai pasiskirstęs skritulyje $(x-a)^2 + (y-b)^2 \leq r^2$. Įrodykite, kad $\eta_{YX}^2 = \rho_{YX}^2 = 0$.

II.3.12. Tegu $\rho = [\rho_{ij}]_{k \times k}$ yra koreliacijos koeficientų matrica. Įrodykite, kad dauginius koreliacijos koeficientas ir daliniai koreliacijos koeficientai susieti lygybėmis:

$$1 - \rho_{1.(2\dots k)}^2 = (1 - \rho_{12}^2)(1 - \rho_{13.2}^2)\dots(1 - \rho_{1k.2\dots k-1}^2);$$

$$\rho_{12.3} = \frac{(\rho_{12} - \rho_{13}\rho_{23})}{(1 - \rho_{13}^2)^{1/2}(1 - \rho_{23}^2)^{1/2}};$$

$$\rho_{12} = \frac{(\rho_{12.3} - \rho_{13.2}\rho_{23.1})}{(1 - \rho_{13.2}^2)^{1/2}(1 - \rho_{23.1}^2)^{1/2}};$$

$$\rho_{12.(3\dots k-1)} = \frac{(\rho_{12.(3\dots k)} - \rho_{1k.(2\dots k-1)}\rho_{2k.(13\dots k-1)})}{(1 - \rho_{1k.(2\dots k-1)}^2)^{1/2}(1 - \rho_{2k.(13\dots k-1)}^2)^{1/2}};$$

$$\rho_{12.(3\dots k)} = \frac{(\rho_{12.(3\dots k-1)} - \rho_{1k.(3\dots k-1)}\rho_{2k.(3\dots k-1)})}{(1 - \rho_{1k.(3\dots k-1)}^2)^{1/2}(1 - \rho_{2k.(3\dots k-1)}^2)^{1/2}}.$$

II.3.2. Tiesinė vieno kintamojo regresija

II.3.13. Prognozuojamas a. d. Y remiantis vienmate kovariante X . Fiksavus kovariantės reikšmes x_1, \dots, x_n gauta imtis Y_1, \dots, Y_n . Tarkime, kad Y sąlyginis vidurkis yra x_i tiesinė funkcija, o dispersija nuo fiksujotosios kovariantės reikšmės nepriklauso. Imties elementai turi tokią struktūrą

$$Y_i = \alpha + \beta(x_i - \bar{x}) + e_i, \quad i = 1, \dots, n, \quad \bar{x} = \sum_i x_i/n.$$

Turime tiesinį modelį (žr. **II.1.1** pratimą)

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}, \quad \mathbf{E}(\mathbf{Y}) = \mathbf{A}\boldsymbol{\beta}, \quad \mathbf{E}(\mathbf{e}) = \mathbf{0}, \quad \mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I},$$

čia $\beta = (\alpha, \beta)^T$, $\mathbf{Y} = (Y_1, \dots, Y_n)^T$, $\mathbf{e} = (e_1, \dots, e_n)^T$; plano matrica \mathbf{A} turi n eilučių ir du stulpelius, i -oji eilutė yra $(1, x_i - \bar{x})$. a) Raskite parametrų α, β mažiausiuju kvadratų įvertinius ir jų pirmuosius momentus. b) Raskite nepaslinktajį dispersijos σ^2 įvertinį.

II.3.14. (II.3.13 pratimo tēsinys). Tarkime, kad paklaidų vektorius \mathbf{e} turi normalujį skirstinį $\mathbf{e} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I})$. a) Įrodykite, kad II.3.13 pratime surasti įvertiniai yra NMD įvertiniai. b) Raskite parametrų $\alpha, \beta, \theta = c_1\alpha + c_2\beta, \sigma^2$ įvertinių skirstinius.

II.3.15. (II.3.14 pratimo tēsinys). a) Raskite parametrų $\sigma^2, \alpha, \beta, \mu(x) = \alpha + \beta(x - \bar{x})$ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalus. b) Raskite kriterijus hipotezėms dėl šių parametru reikšmių tikrinti.

II.3.16. Tarkime, kad turime n_i a.d. Y stebėjimų, kai kovariantės reikšmė yra $x_i, i = 1, \dots, k$. Tegu paklaidų vektorius $\mathbf{e} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}), n = n_1 + \dots + n_k$. Raskite kriterijų regresijos tiesiškumo hipotezei $H : \mathbf{E}(Y|X = x) = \beta_0 + \beta_1(x - \bar{x})$ tikrinti.

II.3.17. (II.3.16 pratimo tēsinys). Raskite kriterijų hipotezei $H : \mathbf{E}(Y|X = x) = \alpha + \beta_1(x - \bar{x}) + \beta_2(x - \bar{x})^2 + \dots + \beta_r(x - \bar{x})^r, r < k$, tikrinti.

II.3.18. (II.3.14 pratimo tēsinys). Tarkime, pagal II.3.14 pratimo duomenis įvertinta regresija $\hat{\mu}(x) = \hat{\alpha} + \hat{\beta}(x - \bar{x})$. Tegu gautas tolimesnis nepriklausomas stebėjimas Y_{n+1} , kuris gaunamas, kai kovariantės X reikšmė yra x . Raskite lygmens $Q = 1 - \alpha$ a.d. Y_{n+1} prognozės intervalą.

II.3.19. (II.3.18 pratimo tēsinys). Tarkime, kad stebėjimas Y_{n+1} žinomas. Raskite kovariantės reikšmės x , kurią atitinka Y_{n+1} , pasiklovimo intervalą.

II.3.20. Pagal didumo n imtį $Y_i = \alpha + \beta(X_i - \bar{X}) + e_i, i = 1, \dots, n$, kai a.d. $\{e_i\}$ nepriklausomi ir $e_i \sim N(0, \sigma^2)$ gauti įvertiniai $\hat{\alpha}$ ir $\hat{\beta}$. Sukurkite TGN kriterijų hipotezei $H : \theta = a\alpha + b\beta = \theta_0$, kai alternatyva $\bar{H} : \theta \neq \theta_0$, tikrinti; čia a, b, θ_0 – žinomi.

II.3.21. Pagal dvi nepriklausomas didumo n_1 ir n_2 imtis įvertinti tiesinės vieno kintamojo regresijos koeficientai $\hat{\alpha}_1, \hat{\beta}_1$ ir $\hat{\alpha}_2, \hat{\beta}_2$. Tarkime, kad visi stebėjimai yra nepriklausomi ir normalieji, turi vienodas dispersijas σ^2 . Raskite kriterijus: a) hipotezei $H : \beta_1 = \beta_2$ tikrinti; b) hipotezei $H : \alpha_1 = \alpha_2$ tikrinti; c) hipotezei $H : \alpha_1 = \alpha_2, \beta_1 = \beta_2$ tikrinti; d) hipotezei, kad regresijos tiesės susikerta taške, kurio abscisė $x = c$, tikrinti.

II.3.22. Raskite parametrų α, β ir σ^2 įverčius naudodami šiuos stebėjimus:

$$0,15 = \alpha - 3\beta + e_1,$$

$$2,07 = \alpha - \beta + e_2,$$

$$4,31 = \alpha + \beta + e_3,$$

$$6,49 = \alpha + 3\beta + e_4,$$

čia e_1, \dots, e_4 – nepriklausomi vienodai pasiskirstę atsitiktiniai dydžiai $e_i \sim N(0, \sigma^2), i = 1, \dots, 4$.

II.3.23. Taškas tolygiai juda tiese. Laiko momentais $t = 0, 1, 2, 3, 4$ buvo užfiksuotos tokios jo koordinacijų reikšmės: $S_t = 12, 98; 13, 05; 13, 35; 13, 97; 14, 22$. Tegu visų matavimų paklaidos nepriklausomos ir turi normalujį skirstinį $N(0, \sigma^2)$. Raskite greičio v ir dispersijos σ^2 taškinius ir intervalinius įverčius, kai pasiklovimo lygmuo $Q = 0, 95$.

II.3.24. Matuojant gauti stebėjimai, kurie yra tiesinės parametru α funkcijos:

$$Y_1 = e_1,$$

$$Y_2 = \alpha + e_1 + e_2,$$

$$Y_3 = 2\alpha + e_1 + e_2 + e_3,$$

$$Y_4 = 3\alpha + e_1 + e_2 + e_3 + e_4,$$

$$Y_5 = 4\alpha + e_1 + e_2 + e_3 + e_4 + e_5,$$

čia e_1, \dots, e_5 – nepriklausomi vienodai pasiskirstę atsitiktiniai dydžiai $e_i \sim N(0, \sigma^2)$, $i = 1, \dots, 5$. Raskite parametru α NMD jvertį, jeigu atsitiktinio vektoriaus $\mathbf{Y} = (Y_1, \dots, Y_5)^T$ realizacija yra $(-0,42, 0,30, 1,30, 2,56, 3,26)^T$. Sudarykite parametrų α ir σ^2 pasiklovimo intervalus, kai pasiklovimo lygmuo $Q = 0,95$.

II.3.25. Atsitiktinis vektorius $\mathbf{Y} = (Y_1, \dots, Y_5)^T$ turi normalųjį skirstinį su parametrais $\mathbf{E}Y_i = (i-1)\alpha$, $i = 1, \dots, 5$; $\mathbf{V}Y_i = \mathbf{Cov}(Y_i, Y_j) = i$, $j > i$, $i = 1, \dots, 5$. Raskite parametru α pasiklovimo intervalą, kai pasiklovimo lygmuo $Q = 0,95$, pagal atsitiktinio vektoriaus \mathbf{Y} realizaciją $\mathbf{y} = (-0,42; 0,30; 1,30; 2,56; 3,26)^T$.

II.3.26. Išmatuotas grunto atsparumas poslinkiui Y , veikiant įvairiems slėgiams P kg/cm^2 , ir gauti šitokie rezultatai:

P_i	Y_{i1}	Y_{i2}	Y_{i3}	Y_{i4}	Y_{i5}	Y_{i6}	Y_{i7}	Y_{i8}	Y_{i9}
1	0,962	0,612	0,612	0,888	1,038	1,188	0,812	0,988	0,875
2	0,962	0,688	0,662	1,112	1,118	1,325	0,988	1,025	1,075
3	1,125	0,800	0,700	0,900	1,475	1,400	1,150	1,175	1,300
4	1,412	0,850	0,650	1,075	1,312	1,425	1,250	1,175	1,162
5	1,125	0,900	0,675	1,225	1,225	1,650	1,025	1,075	1,500
6	1,138	0,950	0,625	1,500	1,375	1,588	1,025	1,150	1,100

- a) patikrinkite Y regresijos P atžvilgiu tiesiškumo hipotezę;
- b) laikydami Y regresiją P atžvilgiu tiesine, jvertinkite jos koeficientus;
- c) sudarykite regresijos koeficientų pasiklovimo intervalus ($Q = 0,95$).

II.3.27. Salyginis Y skirstinys, kai X reikšmės fiksujotos, yra normalusis su dispersija $\sigma^2 = 0,1$. Tarkime, kad taškuose $x = 0,0; 0,1; \dots; 1,0$ turimos vienodo didumo n nepriklausomos imtys. Koks turi būti n , kad regresijos tiesiškumo hipotezė $H : \mathbf{E}(Y|X = x) = x$, $x = 0,0, 0,1, \dots 1,0$ būtų atmesta su tikimybe, ne mažesne už 0,95, jeigu $\mathbf{E}(Y|X = x) = x^2$ (kriterijaus reikšmingumo lygmuo $P = 0,05$).

II.3.28. Tarkime, kad pagal nepriklausomus stebėjimus $Y_i = \alpha + \beta(x_i - \bar{x}) + e_i$, $i = 1, \dots, n$, kai a. d. $\{e_i\}$ nepriklausomi ir normalūs $e_i \sim N(0, \sigma^2)$, jvertinta regresijos tiesė $\hat{\alpha} + \hat{\beta}(x - \bar{x})$. Tegu taške x yra gauta k nepriklausomų Y_{n+1} matavimų $Y_{n+1}^{(1)}, \dots, Y_{n+1}^{(k)}$. Sukonstruokite stebėjimo Y_{n+1} prognozės intervalą ir argumento x pasiklovimo intervalą.

II.3.29. Pasiūlykite, kaip modelį

$$y = \frac{\alpha\beta}{\alpha \sin^2 x + \beta \cos^2 x}$$

pertvarkyti į tiesinį pavidala.

II.3.30. Kalibruojamas pieno rūgšties koncentracijos kraujuje matavimo prietaisas. Tuo tikslu gauti $n = 20$ pavyzdžių matavimai $Y_i, i = 1, 2, \dots, 20$, kai koncentracija X tiksliai žinoma [1].

X	1	1	1	1	3	3	3	3	3	5
Y	1,1	0,7	1,8	0,4	3,0	4,4	4,9	4,4	4,5	7,3
X	5	5	10	10	10	15	15	15	15	15
Y	8,2	6,2	12,0	13,1	12,6	13,2	18,7	19,7	17,4	17,1

Tardami, kad paklaidos normaliosios, įvertinkite tiesinės regresijos parametrus. Patikrinkite regresijos tiesiškumo hipotezę. Raskite tolesnių nepriklausomų Y matavimų prognozės intervalus, kai pasikliovimo lygmuo $Q = 0,95$, jei žinoma, kad matavimai bus atliekami taškuose $X = 12$, $X = 18$.

II.3.31. Pamatavus $n = 108$ pacientų arterinį PH (kintamasis Y) ir veninį PH (kintamasis X) gauti vidurkių ir kovariacijų matricos elementų įverčiai: $\bar{X} = 7,373$, $\bar{Y} = 7,413$, $s_X^2 = 0,1253$, $s_Y^2 = 0,1184$, $s_{XY} = 0,1101$ [1]. Priėmę prielaidą dėl a. v. $(X, Y)^T$ normalumo, įvertinkite a. d. Y regresijos tiesę a. d. X atžvilgiu. Patikrinkite hipotezę $H : \beta = 0$. Kokią dalį a. d. Y sklaidos paaškina regresijos lygtis?

II.3.32. Kintamasis Y reiškia tam tikro cheminio proceso savybę priklausomai nuo laiko t [1]:

t	0,0	1,0	1,5	2,0	2,5	3,0	3,5	4,0
Y	0,000	0,025	0,035	0,045	0,055	0,065	0,075	0,082
t	4,5	5,0	5,5	6,0	6,5	7,0	7,5	8,0
Y	0,088	0,094	0,100	0,105	0,110	0,115	0,120	0,125

a) Įvertinkite tiesinės regresijos parametrus. Panagrinėkite prognozės paklaidas ir aptarkite regresijos tiesinio pavidalo priimtinumą. b) Tarkime, kad iš teorinių samprotavimų gauta, jog regresijos kreivė turėtų būti tokio pavidalo: $Y = \alpha(1 - e^{-\beta t})$. Įvertinkite netiesinio modelio parametrus ir raskite jų apytikslius pasikliovimo intervalus.

II.3.33. Farmakinetikoje vertinant vaisto koncentracijos Y priklausomybę nuo laiko t dažnai naudojamas dvikomponentis matematinis modelis $Y = \alpha_1 e^{\alpha_2 t} + \beta_1 e^{\beta_2 t}$. Pagal pateikiamus duomenis [1]

t	0,10	0,25	0,50	1,00	1,50	2,00	4,00	8,00	12,00	24,00	48,00
Y	18,7	16,9	14,5	11,1	8,9	7,5	5,2	3,6	2,6	1,0	0,2

Įvertinkite regresijos parametrus. Nagrinėdami prognozės paklaidas aptarkite prognozės tiksluma.

II.3.3. Tiesinė keleto kintamųjų regresija

II.3.34. Tarkime, prognozuojame a. d. Y remdamiesi kovariantėmis X_1, \dots, X_m . Tegu $\mathbf{X} = (X_0, X_1, \dots, X_m)^T$ yra kovariančių vektorius, papildytas koordinate $X_0 \equiv 1$. Fiksavus kovariantės reikšmes $\mathbf{x}^{(i)} = (1, x_{1i}, \dots, x_{mi})^T$ gauti nepriklausomi stebėjimai $Y_i, i = 1, \dots, n$. Tarsime, kad imties $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ elementai turi tokią struktūrą

$$Y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_m x_{mi} + e_i, \quad i = 1, \dots, n.$$

Tegu paklaidos e_i nepriklausomos ir normaliosios $e_i \sim N(0, \sigma^2)$. Pažymėję $\boldsymbol{\beta} = (\beta_1, \dots, \beta_m)^T$ ir $\mathbf{e} = (e_1, \dots, e_n)^T$, gauname tiesinį modelį

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\beta} + \mathbf{e}, \quad \mathbf{E}(\mathbf{Y}) = \mathbf{A}\boldsymbol{\beta}, \quad \mathbf{E}(\mathbf{e}) = \mathbf{0}, \quad \mathbf{V}(\mathbf{e}) = \sigma^2 \mathbf{I},$$

kai plano matricos i -oji eilutė yra $(1, x_{1i}, \dots, x_{mi})$.

- a) Raskite parametruo $\boldsymbol{\theta} = (\beta_0, \beta_1, \dots, \beta_m, \sigma^2)^T$ pilnają ir pakankamają statistiką.
- b) Raskite parametruo $\boldsymbol{\theta}$ elementų NMD įvertinius.

II.3.35. (II.3.34 pratimo tēsinys). Raskite parametrų $\beta_i, \theta = \mathbf{L}^T \boldsymbol{\beta}, \sigma^2$ lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalus.

II.3.36. (II.3.34 pratimo tēsinys). Raskite kriterijus hipotezėms $H_{j_1, \dots, j_k} : \beta_{j_1} = \dots = \beta_{j_k} = 0$ tikrinti. Jei ši hipotezė teisinga, tai kovariantės X_{j_1}, \dots, X_{j_k} nėra reikšmingos prognozuojant Y .

II.3.37. (II.3.34 pratimo tēsinys). Tarkime, kad $\mathbf{x}^{(i)} = (1, x_{1i}, \dots, x_{mi})^T, i = 1, \dots, k$, yra skirtinės kovariantės reikšmės ir, kai yra reikšmė $\mathbf{x}^{(i)}$, gauta n_i nepriklausomų Y stebėjimų $Y_{ij}, j = 1, \dots, n_i, n = n_1 + \dots + n_k$. Raskite kriterijų hipotezei $H : \mathbf{E}(Y|\mathbf{X} = \mathbf{x}) = \boldsymbol{\beta}^T \mathbf{x}$ apie regresijos tiesinį pavidalą tikrinti.

II.3.38. (II.3.34 pratimo tēsinys). Tarkime, pagal II.3.34 pratimo duomenis įvertinta regresija

$$\hat{\mu}(\mathbf{x}) = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_m x_m$$

Raskite tolesnio nepriklausomo stebėjimo Y_{n+1} prognozės intervalą, jei žinoma, kad jis bus atliktas taške $\mathbf{x} = (1, x_1, \dots, x_m)$.

II.3.39. Noradrenalino kiekio Y priklausomybė nuo gaunamo su maistu natrio kiekio X yra arba polinominio, arba eksponentinio tipo. Pagal pateikiamus duomenis

X	2	10	5	6	20	3	14	21
Y	31,66	19,20	45,03	13,30	23,44	20,61	18,46	11,98
X	103	122	136	80	196	196	224	245
Y	5,58	15,21	7,58	9,77	13,60	10,01	3,68	7,03
X	97	86	56	127	171	257	157	
Y	13,90	14,00	14,61	15,26	14,12	7,30	10,32	

a) parinkite polinominę regresiją ir aptarkite prognozės tikslumą; b) parinkite eksponentinio tipo priklausomybę, įvertinkite parametrus ir aptarkite prognozės tikslumą.

II.3.40. Tarkime, kad įvertinome regresiją $\mathbf{E}(Y) = \beta_0 + \beta_1 x$, o tikroji regresijos lygtis yra $\mathbf{E}(Y) = \beta_0 + \beta_1 x + \beta_2 x^2 + \beta_3 x^3$ pavidalo. Koks bus įvertinių $\hat{\beta}_0$ ir $\hat{\beta}_1$ poslinkis, kai jie įvertinti pagal nepriklausomus stebėjimus taškuose $x = -3, -2, -1, 0, +1, +2, +3$?

II.3.41. Tegu $Y_1 = \theta_1 + \theta_2 + e_1, Y_2 = 2\theta_2 + e_2, Y_3 = -\theta_1 + \theta_2 + e_3$; čia $\{e_i\}$ nepriklausomi ir $e_i \sim N(0, \sigma^2)$. Sudarykite kriterijų hipotezei $H : \theta_1 = 2\theta_2$ tikrinti.

II.3.42. Tegu Y_1, Y_2, Y_3, Y_4 yra keturkampio kampų $\varphi_1, \varphi_2, \varphi_3, \varphi_4$ matavimai. Tarkime, kad matavimo paklaidos yra normalieji nepriklausomi a. d., turintys nulinius vidurkius ir vienodas dispersijas. Patikrinkite hipotezę, kad keturkampis yra lygiagretainis, t. y. $H : \varphi_1 = \varphi_3, \varphi_2 = \varphi_4$.

II.3.43. Tarkime, $\mathbf{E}(Y_t) = \beta_0 + \beta_1 \cos(2\pi k_1 t/n) + \beta_2 \sin(2\pi k_2 t/n)$; čia $t = 1, \dots, n$, o k_1 ir k_2 – žinomas teigiamos konstantos. Raskite parametrų $\beta_0, \beta_1, \beta_2$ mažiausiuju kvadratų įvertinius.

II.3.44. Nagrinėjamas benzino oktaninis skaičius Y priklausomai nuo priedų A ir B koncentracijų X_1 ir X_2 . Pateikiami tokie duomenys [1]

X_1	2	2	2	2	3	3	3	3
X_2	2	3	4	5	2	3	4	5
Y	96,3	95,7	99,9	99,4	95,1	97,8	99,3	104,9
X_1	4	4	4	4	5	5	5	5
X_2	2	3	4	5	2	3	4	5
Y	96,2	100,1	103,2	104,3	97,8	102,2	104,7	108,8

a) Įvertinkite regresijos parametrus tardami, kad a. d. Y regresija X_1 ir X_2 atžvilgiu yra tiesinė. b) Tarę, kad paklaidos normaliosios, patikrinkite regresijos koeficientų lygybės 0 hipotezes. c) Raskite a. d. Y tolesnio nepriklausomo stebėjimo, kuris atliktas taške $(X_1, X_2) = (4, 5, 3, 5)$, prognozės intervalą, kai pasiklivimo lygmuo $Q = 0,95$.

II.3.45. Dviem skirtingais būdais buvo matuojamas 141 paciento arterinis kraujo spaudimas. Pirmu būdu matuojant sistolinę X_1 , diastolinę X_2 ir vidutinę X_3 kraujo spaudimą buvo naudojamas kateteris. Antru būdu buvo matuojamas sistolinis X_4 ir diastolinis X_5 kraujo spaudimas naudojant kompresinę manžetę. Atlikus pradinę analizę gauti šie rezultatai.

i	\bar{X}_i	s_i	r_{ij}					
1	112,2	28,6	1,000	0,839	0,927	0,871	0,753	
2	59,4	17,1		1,000	0,967	0,778	0,828	
3	76,8	21,0			1,000	0,845	0,852	
4	107,0	28,9				1,000	0,837	
5	66,8	19,3					1,000	

Šioje lentelėje \bar{X}_i – aritmetiniai vidurkiai, o s_i – vidutinių kvadratiniai nuokrypių įvertiniai, $i = 1, \dots, 5$; r_{ij} – koreliacijos koeficientų įvertiniai.

Naudodami pažingsniinės regresijos metodą, parinkite vektoriaus $(X_1, X_2, X_3)^T$ koordinates kintamiesiems X_4 ir X_5 prognozuoti ($P' = 0,01$, $P = 0,05$). Raskite regresijos koeficientus ir dauginius koreliacijos koeficientus.

II.3.46. Lentelėje pateikti Velso gyventojų surašymo duomenys Y (mln.)

Metai	Y	Metai	Y	Metai	Y
1811	10,16	1861	20,07	1901	32,53
1821	12,00	1871	22,71	1911	36,07
1831	13,90	1881	25,97	1921	37,89
1841	15,91	1891	29,00	1931	39,95
1851	17,93				

a) Parinkite polinominį regresijos modelį.

b) Apskaičiuokite liekamosios kvadratinės formos sumažėjimą didindami polinomo laipsnį. Kokio mažiausiojo laipsnio polinomas priimtinias?

II.3.47. Reikia parinkti tokio pavidalo regresijos modelį:

$$\mathbf{E}(Y_i) = \beta_0 + \beta_1 X_i + \beta_2 \varphi(X_i), \quad i = 1, 2, 3;$$

čia $\varphi(x)$ – antrojo laipsnio polinomas. Parinkite $\varphi(x)$ taip, kad plano matrica turėtų ortogonalius stulpelius, kai $X_1 = -1, X_2 = 0, X_3 = +1$.

II.3.4. Kovariacinė analizė

II.3.48. Atliekant dispersinę analizę, kai tiriamą a. d. Y skirstinio priklausomybė nuo tam tikrų faktorių ar jų sąveikų, Y skirstinys gali priklausyti ir nuo tam tikrų tolydžių kovariančių, kurios gali iškreipti išvadas. Jeigu kartu su a. d. Y stebėjimais galima gauti ir tokius kovariančių stebėjimus, tai atliekant analizę jų įtaką galima eliminuoti. Kovariacinėje analizėje imties $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ vidurkis užrašomas dviejų dėmenų suma (žr. [3], 4.1–4.3 skyreliaus)

$$\mathbf{E}(\mathbf{Y}) = \mathbf{A}\boldsymbol{\beta} + \mathbf{C}\boldsymbol{\gamma}.$$

Pirmasis dėmuo apibūdina kokį nors dispersinės analizės modelį, antrasis aprašo tiesinę Y regresiją trukdančiųjų kovariančių atžvilgiu. Rango m dimensijos $n \times m$ matrica \mathbf{A} yra dispersinės analizės plano matrica; rango k dimensijos $n \times k$ matricos \mathbf{C} i -asis stupelis susideda iš i -osios kovariantės matavimų. Imties \mathbf{Y} elementai turi tokią struktūrą

$$Y_i = a_{i1}\beta_1 + \dots + a_{im}\beta_m + \gamma_1x_{1i} + \dots + \gamma_kx_{ki} + e_i, \quad i = 1, \dots, n.$$

Irodykite, kad parametru mažiausiuju kvadratų įvertiniai ir liekamoji kvadratų suma gali būti surasta tokiu būdu.

Tegu $\hat{\boldsymbol{\beta}}_0$ ir $\hat{\boldsymbol{\beta}}_i, i = 1, \dots, k$, yra lygčių sistemų

$$\mathbf{A}^T \mathbf{A} \hat{\boldsymbol{\beta}}_0 = \mathbf{A}^T \mathbf{Y}, \quad \mathbf{A}^T \mathbf{A} \hat{\boldsymbol{\beta}}_i = \mathbf{A}^T \mathbf{C}_i, \quad i = 1, \dots, k,$$

sprendiniai; čia \mathbf{C}_i yra matricos \mathbf{C} i -asis stupelis. Tegu

$$R_{yy} = (\mathbf{Y} - \mathbf{A} \hat{\boldsymbol{\beta}}_0)^T (\mathbf{Y} - \mathbf{A} \hat{\boldsymbol{\beta}}_0) = \mathbf{Y}^T \mathbf{Y} - \hat{\boldsymbol{\beta}}_0^T \mathbf{A}^T \mathbf{Y},$$

$$R_{yx_i} = (\mathbf{Y} - \mathbf{A} \hat{\boldsymbol{\beta}}_0)^T (\mathbf{C}_i - \mathbf{A} \hat{\boldsymbol{\beta}}_i), \quad i = 1, \dots, k,$$

$$R_{x_i x_j} = (\mathbf{C}_i - \mathbf{A} \hat{\boldsymbol{\beta}}_i)^T (\mathbf{C}_j - \mathbf{A} \hat{\boldsymbol{\beta}}_j), \quad i, j = 1, \dots, k.$$

Tarkime, $\hat{\boldsymbol{\gamma}} = (\hat{\gamma}_1, \dots, \hat{\gamma}_k)$ yra lygčių sistemas

$$R_{x_1 x_i} \hat{\gamma}_1 + \dots + R_{x_k x_i} \hat{\gamma}_k = R_{yx_i}, \quad i = 1, \dots, k,$$

sprendinys ir $\hat{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}}_0 - \hat{\gamma}_1 \hat{\boldsymbol{\beta}}_1 - \dots - \hat{\gamma}_k \hat{\boldsymbol{\beta}}_k$. Tada $(\hat{\boldsymbol{\gamma}}^T, \hat{\boldsymbol{\beta}}^T)^T$ yra mažiausiuju kvadratų įvertinys, o liekamoji kvadratų suma

$$SS_E = R_{yy} - \hat{\gamma}_1 R_{yx_1} - \dots - \hat{\gamma}_k R_{yx_k} \sim \sigma^2 \chi^2_{n-m-k}.$$

II.3.49. (II.3.48 pratimo tésinys). a) Raskite kriterijų hipotezei $H_{\boldsymbol{\gamma}} : \boldsymbol{\gamma} = \mathbf{0}$, kad kovariantės X_1, \dots, X_k nedaro įtakos Y skirstiniui, tikrinti. b) Raskite kriterijų hipotezei $H_{i_1, \dots, i_l} : \gamma_{i_1} = \dots = \gamma_{i_l} = 0$, kad kovariantės X_{i_1}, \dots, X_{i_l} nedaro įtakos Y skirstiniui, tikrinti.

II.3.50. (II.3.48 pratimo tésinys). Raskite kriterijų kuriai nors dispersinės analizės hipotezei tikrinti eliminuodami kovariančių X_1, \dots, X_k įtaką. Tarkime, tikrinamą hipotezę galima suformuluoti tokiu būdu $H : \beta_{i_1} = \dots = \beta_{i_s}$.

II.3.51. Pakartokite II.3.48 – II.3.50 pratimus imdami vienfaktorių vieno kintamojo kovariacinės analizės modelį.

II.3.52. Tegu $Y_{ij} = \mu_i + \gamma_1 X_{ij}^{(1)} + \gamma_2 X_{ij}^{(2)} + e_{ij}$, $i = 1, \dots, I$, $j = 1, \dots, J$, o a. d. $\{e_{ij}\}$ nepriklausomi ir normalieji $e_{ij} \sim N(0, \sigma^2)$.

- Raskite parametru γ_1 ir γ_2 mažiausiuju kvadratų įvertinius $\hat{\gamma}_1$ ir $\hat{\gamma}_2$.
- Raskite įvertinių $\hat{\gamma}_1$ ir $\hat{\gamma}_2$ kovariacijų matricą. Kokiomis sąlygomis įvertiniai $\hat{\gamma}_1$ ir $\hat{\gamma}_2$ nekoreliuoti?

II.3.53. Tegu $Y_{ijk} = \mu_{ij} + \gamma_{ij} X_{ijk} + e_{ijk}$, $i = 1, \dots, I$, $j = 1, \dots, J$, $k = 1, \dots, K$, o a. d. $\{e_{ijk}\}$ nepriklausomi ir normalieji $e_{ijk} \sim N(0, \sigma^2)$. a) Raskite kriterijų hipotezei $H : \gamma_{ij} = \gamma$ tikrinti. b) Tardami, kad hipotezė H teisinga, sudarykite parametru γ pasiklivimo intervalą.

II.3.54. Tegu $Y_{ijk} = \mu + \alpha_i + \beta_{ij} + \gamma X_{ijk} + e_{ijk}$, $i = 1, \dots, I$, $j = 1, \dots, J$, $k = 1, \dots, K$, o a. d. $\{e_{ijk}\}$ nepriklausomi ir normalieji $e_{ijk} \sim N(0, \sigma^2)$; $\sum_i \alpha_i = 0$, $\sum_j \beta_{ij} = 0$, $i = 1, \dots, I$. a) Raskite kriterijų hipotezei $H : \gamma = 0$ tikrinti. b) Raskite kriterijų hipotezei $H_A : \alpha_i = 0$, $i = 1, \dots, I$, tikrinti.

II.3.55. Tegu $Y_{ij} = \mu_i + \gamma_i X_j + e_{ij}$, $i = 1, 2$, $j = 1, \dots, J$, o a. d. $\{e_{ij}\}$ nepriklausomi ir normalieji $e_{ij} \sim N(0, \sigma^2)$. Remdamiesi kovariacine analize raskite kriterijų hipotezei $H : \gamma_1 = \gamma_2$ tikrinti. Išsitinkite, kad gautasis kriterijus yra ekvivalentus dviejų regresijos tiesių lygiagretumo kriterijui.

II.3.56. Lentelėje pateiktos bandelių, iškeptų iš 100 (g) tešlos, apimtis Y priklausomai nuo 17 miltų rūšių ir nuo juose esančio bromistinio kalio kiekio X (g), kai $X = 0, 1, 2, 3, 4$ (žr. [16]).

X	0	1	2	3	4	X	0	1	2	3	4
A_1	950	1075	1055	975	880	A_{10}	885	1000	1015	960	895
A_2	890	980	955	865	825	A_{11}	895	935	965	950	920
A_3	830	850	820	770	735	A_{12}	685	835	870	875	880
A_4	770	815	765	725	700	A_{13}	615	665	650	680	660
A_5	860	1040	1065	975	945	A_{14}	885	910	890	835	785
A_6	835	960	985	915	845	A_{15}	985	1075	1070	1015	1005
A_7	795	900	905	880	785	A_{16}	710	750	740	725	720
A_8	800	860	870	850	850	A_{17}	785	845	865	825	820
A_9	750	940	1000	960	960						

- Atlikite vienfaktorių dispersinę analizę neatsižvelgdami į kintamajį X .
- Atlikite kovariacinę analizę, tarę, kad X yra kiekybinis kintamas, ir pasirinkdami pirmojo, antrojo ir trečiojo laipsnio polinomus kintamojo X atžvilgiu.

II.3.57. Lentelėje pateiki duomenys, gauti atlikus eksperimentą pagal keturfaktorių dispersinės analizės pilną kryžminės klasifikacijos schema. Registruojanas tam tikro maisto produkto drėgnumas priklausomai nuo druskos rūšies (faktorius A), druskos kiekio (faktorius B), rūgšties lygio (faktorius C) ir dviejų skirtingu priemaišų (faktorius D) [16].

		A_1			A_2			A_3		
		B_1	B_2	B_3	B_1	B_2	B_3	B_1	B_2	B_3
C_1	D_1	8	17	22	7	26	34	10	24	39
C_1	D_2	5	11	16	3	17	32	5	14	33
C_2	D_1	8	13	20	10	24	34	9	24	36
C_2	D_2	4	10	15	5	19	29	4	16	34

- Atlikite keturfaktorių dispersinę analizę.
- Atlikite kovariacinę analizę tarę, kad

faktorius B kiekybinis, ir parinkdami priklausomybei nuo jo apibūdinti pirmojo ir antrojo laipsnio polinomus.

II.3.58. Lentelėje pateikti duomenys apie krakmolo plėvelės tvirtumą Y priklausomai nuo krakmolo tipo (faktorius A); A_1 – iš kviečių; A_2 – iš ryžių; A_3 – iš kukurūzų; A_4 – iš bulvių; A_5 – iš saldžiųjų bulvių) ir nuo plėvelės storio X [16].

A_1		A_2		A_3		A_4		A_5	
Y	X	Y	X	Y	X	Y	X	Y	X
263,7	5,0	556,7	7,1	731,0	8,0	983,3	13,0	837,1	9,4
130,8	3,5	552,5	6,7	710,0	7,3	958,8	13,3	901,2	10,6
382,9	4,7	397,5	5,6	604,7	7,2	747,8	10,7	595,7	9,0
302,5	4,3	532,3	8,1	508,8	6,1	866,0	12,2	510,0	7,6
213,3	3,8	587,8	8,7	393,0	6,4	810,8	11,6		
132,1	3,0	520,9	8,3	416,0	6,4	950,0	9,7		
292,0	4,2	574,3	8,4	400,0	6,9	1282,0	10,8		
315,5	4,5	505,0	7,3	335,6	5,8	1233,8	10,1		
262,4	4,3	604,6	8,5	306,4	5,3	1660,0	12,7		
314,4	4,1	522,5	7,8	426,0	6,7	746,0	9,8		
310,8	5,5	555,0	8,0	382,5	5,8	650,0	10,0		
280,8	4,8	561,1	8,4	340,8	5,7	992,5	13,8		
331,7	4,8			436,7	6,1	896,5	13,3		
672,5	8,0			333,3	6,2	873,9	12,4		
496,0	7,4			382,3	6,3	924,4	12,2		
311,9	5,2			397,7	6,0	1050,0	14,1		
276,7	4,7			619,1	6,8	973,3	13,7		
325,7	5,4			857,3	7,9				
310,8	5,4			592,5	7,2				
288,0	5,4								
269,3	4,9								

- a) Atlikite kintamojo Y vienfaktorių dispersinę analizę priklausomai nuo faktoriaus A ; b) Atlikite kintamojo Y regresinę analizę neatsižvelgdami į faktorių A . c) Atlikite kovariacinę analizę ir palyginkite gautus rezultatus.

II.3.59. Lentelėje pateiktas trejų metų kviečių derlingumas Y (faktorius A) šešiose skirtingose Anglijos žemės ūkio stotyse (faktorius B). Kartu užregistruotas augalo aukštis varpų atsiradimo metu (kintamasis X_1) ir vidutinis augalų iš vieno kelmanlio skaičius (kintamasis Z) [16].

Metai	Kintamasis	B_1	B_2	B_3	B_4	B_5	B_6
1933	Y	19,0	22,2	35,3	32,8	25,3	35,8
	X	25,6	25,4	30,8	33,0	28,5	28,0
	Z	14,9	13,3	4,6	14,7	12,8	7,5
1934	Y	32,4	32,2	43,7	35,7	28,3	35,2
	X	25,4	28,3	35,3	32,4	25,9	24,2
	Z	7,2	9,5	6,8	9,7	9,2	7,5
1935	Y	26,2	34,7	40,0	29,6	20,6	47,2
	X	27,2	34,4	32,5	27,5	23,7	32,9
	Z	18,6	22,2	10,0	17,6	14,4	7,9

a) Ar yra derlingumo priklausomybė nuo metų, kuri nėra paaiškinama Y regresija X ir Z atžvilgiu? b) Ar yra derlingumo priklausomybė nuo stoties, kuri nėra paaiškinama Y regresija X ir Z atžvilgiu? c) Patikrinkite hipotezę, kad nėra regresijos Y kintamojo Z atžvilgiu. d) 1934 metais stoties B_5 apylinkėje užregistruotas vidutinis augalų aukštis $X = 27$ ir augalų iš vieno krūmelio skaičius $Z = 10$. Gaukite taškinį numatomo derliaus ivertį.

II.3.60. Lyginami keturi vaistai (faktorius A), mažinantys kraujo spaudimą. Registruijamas kraujo spaudimas po gydymo Y . Kartu užregistruotas kraujo spaudimas prieš gydymą X [1].

A	X	Y	A	X	Y
A_1	194	157	A_3	172	136
	162	136		196	182
	183	145		158	134
	180	153			
A_2	154	124	A_4	158	124
	184	123		165	124
	173	143		186	132
	170	136		182	133

- a) Atlikite dispersinę analizę, neatsižvelgdami į kintamąjį X .
 b) Atlikite vienfaktorių vieno kintamojo kovariacinię analizę.
 c) Palyginkite a) ir b) gautus rezultatus.

II.3.61. Lentelėje pateikta 30 kiaulių svorio priaugis Y priklausomai nuo fermos (faktorius A), maitinimo tipo (faktorius B), lyties (faktorius C). Eksperimentas suplanuotas pagal trifaktorių dispersinės analizės kryžminės klasifikacijos schemą su vienu stebėjimu langelyje. Daroma prielaida, kad svorio priaugis gali priklausti nuo tolydžios kovariantės – pradinio svorio X , kurio reikšmės taip pat pateiktos lentelėje [15].

Reikia įvertinti faktorių A, B, C poveikį svorio priaugui eliminuojant kovariantės X įtaką.

A	B	C	X	Y	A	B	C	X	Y
A_1	B_1	C_1	48	9,94	A_3	B_3	C_1	33	7,63
A_1	B_2	C_1	48	10,00	A_3	B_1	C_1	35	9,32
A_1	B_3	C_1	48	9,75	A_3	B_2	C_1	41	9,34
A_1	B_3	C_2	48	9,11	A_3	B_2	C_2	46	8,43
A_1	B_2	C_2	39	8,51	A_3	B_3	C_2	42	8,90
A_1	B_1	C_2	38	9,52	A_3	B_1	C_2	41	9,32
A_2	B_2	C_1	32	9,24	A_4	B_3	C_1	50	10,37
A_2	B_3	C_1	28	8,66	A_4	B_1	C_2	48	10,56
A_2	B_1	C_1	32	9,48	A_4	B_2	C_1	46	9,68
A_2	B_3	C_2	37	8,50	A_4	B_1	C_1	46	10,98
A_2	B_1	C_2	35	8,21	A_4	B_2	C_2	40	8,86
A_2	B_2	C_2	38	9,95	A_4	B_3	C_2	42	9,51
A_5	B_2	C_1	37	9,67	A_5	B_2	C_2	40	9,20
A_5	B_1	C_1	32	8,82	A_5	B_3	C_2	40	8,76
A_5	B_3	C_1	30	8,57	A_5	B_1	C_2	43	10,42

- a) Tarę, kad nėra faktorių sąveikos, atlikite stebėjimų trifaktorę dispersinę analizę.
 b) Atlikite trifaktorę analizę eliminuodami kintamojo X įtaką.
 c) Palyginkite a) ir b) punktuose gautus rezultatus.

II.3.5. Faktoriniai eksperimentai 2^k

II.3.62. Faktoriniame eksperimente 2^2 su trimis stebėjimais langelyje gauti rezultatai pateikti lentelėje eksperimentus žymint kodiniu pavidalu (žr. [3], 4.5.1 skyrelj).

Kodas	(1)	a	b	ab
Y	0; 2; 1	4; 6; 2	-1; -3; 1	-1; -3; -7

Įvertinkite Y tiesinės regresijos parametrus kintamujų Z_1 ir Z_2 atžvilgiu. Priėmę normalumo prielaidą, patikrinkite regresijos koeficientų lygybės 0 hipotezes.

II.3.63. Tiriamos galingumo sanaudos Y pjaustant metalą keraminiu instrumentu priklausomai nuo instrumento tipo (kintamasis X_1), rėžiklio briaunelės kampo (kintamasis X_2) ir nuo pjovimo tipo (kintamasis X_3). Atlirkas visas faktorinius eksperimentus 2^3 (žr. [3], 4.5.2 skyrelj). Rezultatai (salyginiai vienetais), eksperimentus žymint kodiniu pavidalu, pateikti lentelėje [8].

Kodas	(1)	a	b	ab	c	bc	ac	abc
Y	2	-5	15	13	-12	-2	-17	-7

a) Įvertinkite Y tiesinės regresijos parametrus kintamujų Z_1, Z_2, Z_3 atžvilgiu. Priėmę normalumo prielaidą, patikrinkite šių parametru lygybės 0 hipotezes. b) Papildomai įvertinkite regresijos koeficientus β_{ij} prie sandaugų $Z_i Z_j$, $i \neq j$. Patikrinkite šių koeficientų lygybės 0 hipotezes.

II.3.64. Lentelėje pateikti tam tikro cheminio eksperimento duomenys. Atlirkas visas faktorinius eksperimentus 2^3 (žr. [3], 4.5.2 skyrelj) su dviem stebėjimais langelyje.

Kodas	(1)	a	b	ab	c	bc	ac	abc
Y	1595	1573	1835	1700	1745	1838	2184	1717
	1578	1592	1823	1815	1689	1614	1538	1806

Atlikite duomenų analizę.

II.3.65. Lentelėje pateikti tam tikro faktorinio eksperimento 2^4 (žr. [3], 4.5.3 skyrelj) su dviem stebėjimais langelyje rezultatai.

Kodas	(1)	a	b	ab	c	bc	ac	abc
Y	1985	1595	1765	1835	1694	1806	2243	1614
	1592	2067	1700	1823	1712	1758	1745	1838
Kodas	d	ad	bd	abd	cd	bcd	acd	$abcd$
Y	2156	1578	1923	1863	2184	1957	1745	1917
	2032	1733	2007	1910	1921	1717	1818	1922

a) Atlirkite duomenų analizę, tare, kad regresijos koeficientai prie trijų ir keturių kovariančių sandaugų lygūs 0. b) Priėmę normalumo prielaidą, patikrinkite regresijos koeficientų lygybės 0 hipotezes. c) Raskite tolesnio nepriklausomo Y stebėjimo prognozės intervalą, jeigu žinoma, kad jis bus atlirkas taške $z = (z_1, \dots, z_4)^T$, kurio koordi-

natės tenkina sąlygą

$$\sum_i z_i^2 + \sum_{i \neq j} z_i^2 z_j^2 = \rho^2.$$

II.3.66. Atliekamas visas faktorinis eksperimentas 3^2 , kai kiekviena kovariantė Z_i (jeigu reikia atlikus transformavimą) įgyja reikšmes $-1; 0; +1$, t. y. eksperimentas atliktas kvadrato viršūnėse, centre ir kraštinių vidurio taškuose. Patikrinkite, kad regresijos lygties

$$Y_j = \beta_0 + \beta_1 Z_{1j} + \beta_2 Z_{2j} + \beta_{11} U_{1j}^2 + \beta_{22} U_{2j}^2 + \beta_{12} U_{1j}^2 U_{2j}^2 + \\ + \beta_{211} Z_{2j} U_{1j}^2 + \beta_{122} Z_{1j} U_{2j}^2 + e_j, \quad U_{ij}^2 = Z_{ij}^2 - \bar{Z}^2, \quad i = 1, 2; \quad j = 1, \dots, 9.$$

plano matrica turi ortogonalius stulpelius. Raskite regresijos parametru įvertinius ir jų dispersijas. Tardami, kad a. d. $\{e_j\}$ yra nepriklausomi ir normalieji $e_j \sim N(0, \sigma^2)$, raskite kriterijus regresijos koeficientų lygibės 0 hipotezėms tikrinti.

II.3.67. (II.3.66 pratimo tēsinys). Norint įvertinti regresijos koeficientus prie kovariantų sandaugų ir kvadratų, eksperimentas 2^2 atliktas kvadrato viršūnėse, papildomas stebėjimais keturiuose taškuose $(\pm a, 0), (0, \pm a)$. Norėdami įvertinti dispersiją, eksperimentą du kartus pakartojame eksperimento centre, t. y. taške $(0, 0)$. Parinkite a taip, kad regresijos lygties plano matrica turėtų ortogonalius stulpelius.

II.3.68. (II.3.67 pratimo tēsinys.) Apibendrinkite II.3.67 pratimą 3 kovariančių atveju.

II.3.69. Lentelėje pateiktos jėgos Y , reikalingos nustumti gaminį nuo konvejerio juostos priklausomai nuo temperatūros (kovariantė X_1) ir nuo drėgumo (kovariantė X_2). Eksperimentas atliktas pagal visą faktorinio eksperimento 3^2 planą su dviem stebėjimais langelyje. Pateikiameis lentelės pirmoje eilutėje yra transformuotos kovariantės X_1 reikšmės, o pirmajame stulpelyje – kovariantės X_2 reikšmės.

	-1	-1	0	0	+1	+1
-1	0,8;	2,8	1,5;	3,2	2,5;	4,2
0	1,0;	1,6	1,6;	1,8	1,8;	1,0
+1	2,0;	2,2	1,5;	0,8	2,5;	4,0

Įvertinkite regresijos lygties parametrus. Priėmę normalumo prielaidą patikrinkite regresijos koeficientų lygibės 0 hipotezes.

II.3.70. Tarkime, kad vienu metu galime atlikti tik keturis II.3.63 pratimo eksperimentus. Sudalinkite eksperimentus į dvi replikas (žr. [3], 4.5.4 skyrelį) su tarpblokiniu efektu sumaišydam i) visų trijų faktorių sąveiką; b) faktorių A_1 ir A_3 sąveiką.

II.3.6. Apibendrintieji tiesiniai modeliai

II.3.71. Firmoje užregistruoti klientų telefono skambučių skaičiai per kiekvieną iš 7 darbo valandų (kovariantė X_1) kiekvienai iš 5 savaitės darbo dienų (kovariantė X_2). Toks pat eksperimentas pakartotas kitą savaitę. Skambučių skaičiaus Y_{ijk} , $i = 1, \dots, 7, j = 1, \dots, 5, k = 1, 2$ stebiniai pateikti lentelėje.

$Z_{1i}Z_{2j}$	-2	-1	0	1	2	\sum
-3	30 44	30 36	26 30	31 31	18 43	325
-2	29 34	31 36	22 35	18 30	25 31	291
-1	28 41	22 24	23 26	21 29	26 28	268
0	23 24	19 24	23 31	20 25	21 31	241
1	30 30	32 40	26 33	26 34	26 36	313
2	30 38	28 40	36 37	23 25	20 24	301
3	34 39	24 41	25 34	21 26	25 41	310
\sum	454	427	407	366	395	2049

Lentelėje pateiktos centruotos kovariančių reikšmės $Z_{1i} = X_{1i} - 4, i = 1, \dots, 7; Z_{2j} = X_{2j} - 3, j = 1, \dots, 5$.

Tarkime, kad skambučių srautas yra puasoninis su pastoviui intensyvumu valandos intervale, t. y. $Y_{ijk} \sim \mathcal{P}(\lambda_{ij})$.

Atlikite imties

$$(Y_{111}, Z_{11}, Z_{21}), (Y_{112}, Z_{11}, Z_{21}), \dots, (Y_{771}, Z_{17}, Z_{27}), (Y_{772}, Z_{17}, Z_{27})$$

puasoninę regresinę analizę (žr. [3], 5.2.1 skyrelį). Iš paskutinio lentelės stulpelio matyti, kad skambučių skaičiaus kitimas dienos metu néra tiesinis, todėl Y_{ijk} priklausomybei nuo kovariančių apibūdinti naudokite tokį modelį:

$$\mathbf{E}Y_{ijk} = \dot{B}(\boldsymbol{\beta}^T \mathbf{Z}_{ij}) = e^{\boldsymbol{\beta}^T \mathbf{Z}_{ij}} = e^{\beta_0 + \beta_1 Z_{1i} + \beta_2 Z_{1i}^2 + \beta_3 Z_{2j}},$$

$$i = 1, \dots, 7, \quad j = 1, \dots, 5, \quad k = 1, 2.$$

a) Raskite parametru $\boldsymbol{\beta} = (\beta_0, \beta_1, \beta_2, \beta_3)^T$ DT įvertij $\hat{\boldsymbol{\beta}}$ ir kovariacinės matricos $\mathbf{V}(\hat{\boldsymbol{\beta}})$ įvertij $\hat{\mathbf{V}}(\hat{\boldsymbol{\beta}})$.

b) Patikrinkite hipotezę $H : \beta_1 = \beta_2 = \beta_3 = 0$ ir hipotezes $H_j : \beta_j = 0, j = 1, 2, 3$.

c) Raskite trečios savaitės darbo dienos pirmos ir ketvirtos valandos vidutinio skambučių skaičiaus taškinius ir intervalinius ($Q = 0, 95$) įverčius.

II.3.72. (II.3.71 pratimo tēsinys). Atlikite II.3.71 pratimo užduotis a), b), c) tardami, kad teisingas normaliosios teorijos tiesinis regresijos modelis:

$$Y_{ijk} = \alpha_0 + \alpha_1 Z_{1i} + \alpha_2 Z_{1i}^2 + \alpha_3 Z_{2i} + e_{ijk},$$

čia e_{ijk} nepriklausomi normalieji a. d. $e_{ijk} \sim N(0, \sigma^2)$. Palyginkite II.3.71 ir II.3.72 pratimų atsakymus.

II.3.73. (II.3.71 pratimo tēsinys). Atlikite II.3.71 pratimo stebinių dispersiją stabilizuojančią transformaciją $U_{ijk} = \sqrt{4Y_{ijk} - 1}$. Kai λ_{ij} didelis, a. d. U_{ijk} skirtinys aproksimuojamas normaliuoju su vienetine dispersija. Atlikite II.3.71 pratimo užduotis a), b), c) tardami, kad teisingas tiesinis regresijos modelis:

$$U_{ijk} = \gamma_0 + \gamma_1 Z_{1i} + \gamma_2 Z_{1i}^2 + \gamma_3 Z_{2i} + e_{ijk},$$

čia e_{ijk} nepriklausomi normalieji a. d. $e_{ijk} \sim N(0, 1)$. Palyginkite II.3.71, II.3.72 ir II.3.73 pratimų atsakymus.

II.3.74. Tiriant gaminių patikimumą iš 4 įmonių (kovariantė X) pagamintos produkcijos atsitiktinai atrinkta ir išbandyta po 20 gaminių. Gaminių darbo laiko iki gedimo Y_{ij} stebiniai pateikti lentelėje.

X	Y_{ij}									
I	65,10	74,80	25,11	69,89	28,73	13,27	49,60	26,96	30,03	16,46
II	7,98	31,27	29,81	51,75	18,61	7,07	13,60	27,30	5,56	17,50
III	27,17	13,64	10,66	15,59	26,56	17,76	26,11	13,32	14,40	20,80
IV	15,55	30,47	14,16	24,02	9,09	13,82	18,68	16,73	19,69	21,54

X	Y_{ij}									
I	38,72	59,69	80,03	86,27	19,77	37,36	36,30	37,98	60,31	51,45
II	19,99	53,88	21,94	32,27	32,34	7,28	17,87	7,42	17,17	11,66
III	20,82	30,93	29,28	15,57	35,78	33,10	32,44	15,84	17,11	16,04
IV	27,46	42,90	11,62	13,66	11,54	16,33	18,75	13,14	36,04	24,92

Tarkime, kad gaminio darbo laikas Y_{ij} turi gama skirstinį $Y_{ij} \sim G(\lambda_j, 3)$. Kadangi kovariantė X nominali, tai ją koduokime keisdami vektoriumi $\mathbf{Z} = (Z_1, Z_2, Z_3)^T$, kuris įgyja reikšmes $(0, 0, 0)^T, (1, 0, 0)^T, (0, 1, 0)^T$ ir $(0, 0, 1)^T$ atitinkamai pirmajai, antrajai, trečiajai ir ketvirtajai įmonei.

Atlikite imties

$$(Y_{11}, \mathbf{Z}_{11}), \dots, (Y_{20,4}, \mathbf{Z}_{20,4})$$

gama regresinę analizę (žr. [3], 5.2.2 skyrelį). Priklausomybei nuo kovariantės X apibūdinti naudokite tokį modelį:

$$\mathbf{E}Y_{ij} = 3e^{\beta_0 + \beta_1 Z_{i1} + \beta_2 Z_{i2} + \beta_3 Z_{i3}}, \quad i = 1, \dots, 20, \quad j = 1, \dots, 4.$$

- a) Raskite parametru $\boldsymbol{\beta} = (\beta_0, \beta_1, \beta_2, \beta_3)^T$ DT įvertij $\hat{\boldsymbol{\beta}}$ ir kovariacinių matricą $\mathbf{V}(\hat{\boldsymbol{\beta}})$.
- b) Patikrinkite hipotezę $H : \beta_1 = \beta_2 = \beta_3 = 0$, hipotezes $H_j : \beta_j = 0, j = 1, 2, 3$ ir hipotezę $H_{23} : \beta_2 = \beta_3$.
- c) Raskite trečios įmonės pagaminto gaminio darbo laiko vidurkio taškinį ir intervalinį ($Q = 0,95$) įverčius.

II.3.75. Turime 24 studentų įskaitos duomenis. Priklausomas kintamasis $Y = 1$, jeigu studentas gavo įskaitą, ir $Y = 0$ – jeigu negavo. Kiek valandų studentas dirbo pratybų metu, rodo kintamasis X_2 . Ar studentas prieš pat sesiją ko nors klausė dėstytojo, rodo kintamasis X_1 ($X_1 = 1$, jeigu klausė, ir $X_1 = 0$, jeigu neklausė). Duomenys pateikti lentelėje ([8], II dalis).

Y	0	0	0	0	0	0	0	0	0	0	1
X_1	0	0	0	0	0	1	1	1	1	1	0
X_2	19	17	13	15	19	21	17	18	23	15	13
Y	1	1	1	1	1	1	1	1	1	1	1
X_1	0	0	1	1	1	1	1	1	0	0	0
X_2	30	19	22	21	24	28	30	27	21	24	20

- a) Įvertinkite logistinės regresijos parametrus. b) Įvertinkite kovariančių X_1 ir X_2 šansų santykius. c) Įvertinkite tikimybę gauti įskaitą, kai $X_2 = 20$, $X_1 = 0$ ir kai $X_2 = 20$, $X_1 = 1$. d) Sudarykite klasifikacinę lentelę, kai objektas priskiriamas tai klasei, kurios tikimybės įvertis didesnis.

II.3.76. Gimdymo namuose surinkti duomenys apie gimdyvės amžių X_1 , rūkymą ($X_2 = 1$ – rūko, $X_2 = 0$ – nerūko), hipertoniją X_3 ($X_3 = 1$ – serga, $X_3 = 0$ – neserga), moters svorį X_4 ir naujagimio svorį Z . Naujagiminis sveria nepakankamai, jeigu jo svoris nesiekia 2500 g ([8], II dalis).

X_1	X_2	X_3	X_4	Z	X_1	X_2	X_3	X_4	Z
24	0	0	64,0	1703	29	0	0	75,0	2922
21	1	1	82,5	1792	26	1	0	84,0	2922
21	0	0	100,0	1930	17	0	0	56,5	2922
19	0	0	51,0	2084	35	1	0	60,5	2950
24	0	0	69,0	2102	33	1	0	54,5	3035
17	1	0	55,0	2227	21	1	0	92,5	3044
18	0	0	74,0	2284	19	0	0	94,5	3064
15	0	0	57,5	2383	21	0	0	80,0	3064
17	0	0	60,0	2440	19	0	0	57,5	3177
20	0	0	52,5	2452	28	0	0	70,0	3236
14	1	0	50,5	2468	16	1	0	67,5	3376
14	0	0	50,0	2497	22	0	0	65,5	3462
21	1	1	65,0	2497	32	0	0	85,0	3475
33	0	0	77,5	2553	19	0	0	52,5	3574
32	0	0	60,5	2837	24	0	0	55,0	3730
28	0	0	83,5	2879	25	0	1	60,0	3985

a) Tarkime, $Y = 1$, jeigu naujagimio svoris mažesnis už 2500 g, ir $Y = 0$ – priešingu atveju. Įvertinkite logistinės regresijos parametrus prognozuodami kintamajį Y pagal X_1, X_2, X_3, X_4 .

b) Įvertinkite šansų santykius.

c) Patikrinkite hipotezes dėl regresijos parametrų reikšmingumo.

d) Įvertinkite tikimybę, kad 30 metų amžiaus motina, kuri rūko, serga hipertoniija ir sveria 85 kg, pagimdys nepakankamo svorio kūdikį. Palyginkite šią prognozę su ta, kurią gautume prognozuodami kintamajį Z tiesine regresija kintamujų X_1, X_2, X_3, X_4 atžvilgiu.

II.3.77. Ar galima pagal pajamas (kintamasis X_1) ir darbo prestižukumo indeksą (kintamasis X_2) atpažinti, kad respondentas turi aukštąjį išsilavinimą ($Y = 1$ – jeigu turi ir $Y = 0$ – jeigu neturi)? Duomenys pateikti lentelėje ([8], II dalis).

X_1	3670	1923	3067	3811	3494	2012	1637	1265	2722
X_2	60	65	70	105	70	55	55	35	105
Y	1	0	1	1	1	0	0	0	0
X_1	3125	4050	3458	2219	3781	2736	2568	3408	3298
X_2	95	115	95	95	90	85	135	110	60
Y	0	1	0	0	1	0	0	0	1
X_1	4050	1501	3340	3193	3043	3536	3780	3798	
X_2	135	50	65	60	95	80	94	78	
Y	1	0	1	1	1	1	1	1	

Atlikite duomenų logistinę regresiją.

II.3.78. Lentelėje pateikti dviejų futbolo lygų (kintamasis Z) duomenys: atstumas iki vartų (X), bandymų įmušti žvartį skaičius (N), sėkmų skaičius (M).

a) Nagrinėdami lygas atskirai, parinkite logistinės regresijos modelį, kuriame kovariantė yra atstumas.

b) Parinkite logistinės regresijos modelį, kuriame kovariantės yra atstumas ir lyga.

Lyga Z	Atstumas X	Sėkmių skaičius M	Bandymų skaičius N
0	14,5	68	77
0	24,5	74	95
0	34,5	61	113
0	44,5	38	138
0	52,0	2	38
1	14,5	62	67
1	24,5	49	70
1	34,5	43	79
1	44,5	25	82
1	52,0	7	24

II.3.7. Sprendimai, atsakymai, nurodymai

II.3.1 skyrelis

II.3.1. a) Pažymėję $h = h(\mathbf{X})$, $\mu = \mu(\mathbf{X})$, gauname

$$\mathbf{E}(Y - h)^2 = \mathbf{E}((Y - \mu) + (\mu - h))^2 = \mathbf{E}(Y - \mu)^2 + \mathbf{E}(\mu - h)^2 \geq \mathbf{E}(Y - \mu)^2,$$

nes

$$\mathbf{E}((Y - \mu)(\mu - h)) = \mathbf{E}\{(\mu - h)\mathbf{E}[(Y - \mu)|\mathbf{X}]\} = 0.$$

b) Randame

$$\mathbf{Cov}(Y, h) = \mathbf{E}\{(h - \mathbf{E}h)\mathbf{E}[(Y - \mathbf{E}Y)|\mathbf{X}]\} = \mathbf{Cov}(h, \mu);$$

kai $h = \mu$, tai $\mathbf{Cov}(Y, \mu) = \mathbf{Cov}(\mu, \mu) = \mathbf{V}\mu$. Tada

$$\rho^2(Y, h) = \frac{\mathbf{Cov}^2(Y, h)}{\mathbf{V}Y\mathbf{V}h} \frac{\mathbf{V}\mu}{\mathbf{V}\mu} = \rho^2(\mu, h)\rho^2(Y, \mu) \leq \rho^2(Y, \mu).$$

II.3.2. Kadangi

$$\mathbf{Cov}(\mu, Y - \mu) = \mathbf{V}\mu - \mathbf{V}\mu = 0,$$

tai

$$\mathbf{V}Y = \mathbf{V}\mu + \mathbf{V}(Y - \mu) = \mathbf{V}Y\eta_{Y|\mathbf{X}}^2 + \mathbf{V}Y(1 - \eta_{Y|\mathbf{X}}^2).$$

Koreliacinis santykis $\eta_{Y|\mathbf{X}}^2$ rodo, kurią dalį Y dispersijos $\mathbf{V}Y$ sudaro optimalios prognozės $\mu(\mathbf{X})$ dispersija. Prognozės paklaidos $Y - \mu(\mathbf{X})$ dispersija sudaro $(1 - \eta_{Y|\mathbf{X}}^2)$ dispersijos $\mathbf{V}Y$ dalį. Jeigu $\eta_{Y|\mathbf{X}}^2 = 1$, tai Y ir \mathbf{X} susieti funkcinė priklausomybe, nes $\mathbf{V}(Y - \mu(\mathbf{X})) = 0$; jeigu $\eta_{Y|\mathbf{X}}^2 = 0$, tai prognozuoti Y pagal \mathbf{X} nėra prasmės, nes $\mathbf{V}(\mu(\mathbf{X})) = 0$ ir $\mu(\mathbf{X}) = \mathbf{E}Y$ neprieklauso nuo \mathbf{X} .

II.3.3. Atėmę $\eta_{Y|\mathbf{X}^{(2)}|\mathbf{X}^{(1)}}^2$ apibrėžime abi lygybės puses iš vieneto ir padauginę iš $1 - \eta_{Y|\mathbf{X}^{(1)}}^2$, gauname

$$1 - \eta_{Y|\mathbf{X}}^2 = (1 - \eta_{Y|\mathbf{X}^{(1)}}^2)(1 - \eta_{Y|\mathbf{X}^{(2)}|\mathbf{X}^{(1)}}^2).$$

Pakartotinai taikydami šią lygybę gausime pratime pateiktą lygybę.

II.3.4. a) Gauname

$$\begin{aligned}
SS(\alpha, \beta) &= \mathbf{E}(Y - \alpha - \beta^T \mathbf{X}) = \\
&= \mathbf{E}((Y - \mathbf{E}Y) + (\mathbf{E}Y + (\mathbf{E}Y - \alpha - \beta^T \mathbf{E}(\mathbf{X}))) - \beta^T(\mathbf{X} - \mathbf{E}(\mathbf{X})))^2 = \\
&= \mathbf{V}Y + (\mathbf{E}Y - \alpha - \beta^T \mathbf{E}(\mathbf{X}))^2 + \beta^T \Sigma \beta - 2\beta^T \sigma_{YX} \geq \mathbf{V}Y + \beta^T \Sigma \beta - 2\beta^T \sigma_{YX}.
\end{aligned}$$

Imdami dešinės pusės išvestinę pagal β ir prilyginę nuliui, gauname lygčių sistemą $\Sigma \beta = \sigma_{YX}$. Iš čia, jeigu Σ teigiamai apibrėžta matrica, gauname

$$\beta^* = \Sigma^{-1} \sigma_{YX}, \quad \alpha^* = \mathbf{E}Y - (\beta^*)^T \mathbf{E}(\mathbf{X}).$$

b) Pažymėsime, kad $\sigma_{YX} = \Sigma \beta^*$. Gauname

$$\begin{aligned}
\mathbf{Cov}(Y, \beta^T \mathbf{X}) &= \beta^T \sigma_{YX} = \beta^T \Sigma \beta^*, \quad \mathbf{Cov}(Y, (\beta^*)^T \mathbf{X}) = (\beta^*)^T \Sigma \beta^*; \\
\rho^2(Y, \beta^T \mathbf{X}) &= \frac{(\beta^T \Sigma \beta^*)^2}{\mathbf{V}Y \beta^T \Sigma \beta} \leq \frac{\beta^T \Sigma \beta (\beta^*)^T \Sigma \beta^*}{\mathbf{V}Y \beta^T \Sigma \beta} = \\
&\frac{((\beta^*)^T \Sigma \beta^*)^2}{\mathbf{V}Y (\beta^*)^T \Sigma \beta^*} = \rho^2(Y, (\beta^*)^T \mathbf{X}).
\end{aligned}$$

Koreliacijos koeficiente $\rho(Y, l^*)$ kvadratas yra

$$\rho_{YX}^2 = \frac{\mathbf{V}l^*}{\mathbf{V}Y} = \frac{\beta^{*T} \Sigma \beta^*}{\mathbf{V}Y} = \frac{\sigma_{YX} \Sigma^{-1} \sigma_{YX}}{\mathbf{V}Y},$$

o $\rho_{YX} = \sqrt{\rho_{YX}^2} \geq 0$ vadinamas dauginiu koreliacijos koeficientu.

II.3.5. Kadangi

$$\mathbf{Cov}(l^*, Y - l^*) = 0,$$

tai

$$\mathbf{V}Y = \mathbf{V}l^* + \mathbf{V}(Y_l^*) = \mathbf{V}Y \rho_{YX}^2 + \mathbf{V}Y (1 - \rho_{YX}^2).$$

Dauginio koreliacijos koeficiente kvadratas ρ_{YX}^2 rodo, kurią dalį Y dispersijos $\mathbf{V}Y$ sudaro optimalios tiesinės prognozės l^* dispersija. Prognozės paklaidos $Y - l^*$ dispersija sudaro $(1 - \rho_{YX}^2)$ dispersijos $\mathbf{V}Y$ dalį. Jeigu $\rho_{YX}^2 = 1$, tai Y ir \mathbf{X} susieti tiesine priklausomybe, nes $\mathbf{V}(Y - l^*) = 0$; jeigu $\rho_{YX}^2 = 0$, tai tiesiškai prognozuoti Y pagal \mathbf{X} nėra prasmės.

Pažymėsime, kad minimali tiesinė prognozė minimizuoja paklaidos dispersiją siauresnėje klasėje negu optimali nebūtinai tiesinė prognozė, tai galioja nelygybės

$$0 \leq \rho_{YX}^2 \leq \eta_{YX}^2 \leq 1.$$

Jeigu vektorius $(Y, X_1, \dots, X_m)^T$ turi daugiamati normalujį skirstinį, tai $\rho_{YX}^2 = \eta_{YX}^2$ (žr. [3], 7.4 skyrelį).

II.3.6. Atėmę $\rho_{YX^{(2)}|X^{(1)}}^2$ apibrėžime abi lygbybės puses iš vieneto ir padaugine iš $1 - \rho_{YX^{(1)}}^2$, gauname

$$1 - \rho_{YX}^2 = (1 - \rho_{YX^{(1)}}^2)(1 - \rho_{YX^{(2)}|X^{(1)}}^2).$$

Pakartotinai taikydami šią lygybę gausime pratime pateiktą lygybę.

II.3.7. a) A. d. X sąlyginis skirstinys, kai $Y = y$ fiksotas, yra normalusis

$$(X|Y = y) \sim N(\rho y, 1 - \rho^2), \quad \mathbf{E}(X|Y = y) = \rho y, \quad \eta_{X|Y}^2 = \rho^2.$$

b) A. d. X sąlyginis skirstinys, kai $Y^2 = y$ fiksotas, yra mišinys normaliuju skirstinių $N(-\rho \sqrt{y}, 1 - \rho^2)$ ir $N(\rho \sqrt{y}, 1 - \rho^2)$ su vienodais svoriais $1/2$.

$$\mathbf{E}(X|Y^2 = y) = \frac{1}{2}[-\rho \sqrt{y} + \rho \sqrt{y}] = 0, \quad \mathbf{E}(X|Y^2) = 0, \quad \eta_{X|Y^2}^2 = 0.$$

c) Remdamiesi p. b) gauname

$$\mathbf{E}(X^2|Y^2 = y^2) = 1 - \rho^2 + \rho^2 y^2, \quad \eta_{X^2|Y^2}^2 = \frac{\mathbf{Cov}^2(X^2, \rho^2 Y^2)}{V X^2 V(\rho^2 Y^2)} = \rho^4.$$

d) Kadangi $(X^2|Y = y) \sim N(\rho y, 1 - \rho^2)$, tai

$$\mathbf{E}(X^2|Y = y) = 1 - \rho^2 + \rho^2 y^2 \quad \eta_{X^2|Y^2}^2 = \frac{\mathbf{Cov}^2(X^2, \rho^2 Y^2)}{V X^2 V(\rho^2 Y^2)} = \rho^4.$$

II.3.8. Pradžioje tarkime, kad elipsė užrašyta kanoniniu pavidalu $x^2/a^2 + y^2/b^2 = 1$. Pažymėkime $|S| = \pi ab$ figūros, apribotos elipse, plotą, o S pačią figūrą. Tada tankio funkcija

$$f_{X,Y}(x, y) = \frac{1}{|S|}, \quad (x, y) \in S.$$

A. d. X tankis

$$f_X(x) = \int_{-b\sqrt{1-x^2/a^2}}^{b\sqrt{1-x^2/a^2}} f_{X,Y}(x, y) dy = \frac{2b}{|S|} \sqrt{1 - \frac{x^2}{a^2}}, \quad x \in (-a, a).$$

Sąlyginis tankis

$$f_{Y|X=x} = \frac{1}{2b\sqrt{1-x^2/a^2}}, \quad y \in (-b\sqrt{1-x^2/a^2}, b\sqrt{1-x^2/a^2}).$$

Sąlyginis vidurkis

$$\mathbf{E}(Y|X = x) = \frac{1}{2b\sqrt{1-x^2/a^2}} \int_{-b\sqrt{1-x^2/a^2}}^{b\sqrt{1-x^2/a^2}} y dy = 0.$$

Bendras atvejis. Naudojant tiesines transformacijas

$$y' = c_1 x + c_2 y, \quad x' = d_1 x,$$

elipsės lygtis suvedama į kanoninį pavidala (pakanka išskirti pilną kvadrata). Kanoninio pavidalo elipsei $\mathbf{E}(Y; |X'|) = 0$, nes tolygusis skirstinys po tiesinės transformacijos išlieka. Išreiškiame

$$X = a_1 X', \quad Y = b_1 X' + b_2 Y'$$

ir gauname, kad sąlyginis vidurkis

$$\begin{aligned}\mathbf{E}(Y|X) &= \mathbf{E}(b_1 X' + b_2 Y' | a_1 x') = \frac{b_1}{a_1} \mathbf{E}(a_1 X' | a_1 X') + \\ \mathbf{E}(g_1 Y' | a_1 X') &= \frac{b_1}{a_1} X\end{aligned}$$

yra tiesinė X funkcija.

II.3.9. Pažymėkime lygiagretainio viršūnes $A(-3, -2), B(0, -1), C(3, 2), D(0, -1)$; tiesės AB lygtis $x = y - 1$, tiesės BC lygtis $x = 3(y - 1)$, tiesės CD lygtis $x = y + 1$ ir tiesės AD lygtis $x = 3(y + 1)$.

Fiksuokime tašką x iš intervalo $(-3, 0)$. Tada a. d. Y turi tolygųjį skirstinį intervale $y_1 \leq y \leq y_2$; čia y_1 taškas ant tiesės AB , o y_2 – ant tiesės AD ; $y_1 = x + 1, y_2 = x/3 - 1$. Sąlyginis vidurkis $\mathbf{E}(Y|X = x) = (y_1 + y_2)/2 = 2x/3$. Taigi kai $x \in (-3, 0)$, tai $\mathbf{E}(Y|X = x)$ yra tiesės $y = 2x/3$ atkarpa. Analogiskai, imdami intervalą $0 \leq x < 3$, gausime, kad $\mathbf{E}(Y|X = x)$ yra tiesės $y = 2x/3$ atkarpa. A. d. Y regresija X atžvilgiu yra tiesinė.

Fiksuokime tašką y iš intervalo $(-2, -1)$. Tada a. d. X turi tolygųjį skirstinį intervale $x_1 < x < x_2$; čia x_1 taškas ant tiesės AB , o x_2 taškas ant tiesės AD ; $x_1 = y - 1, x_2 = 3(y - 1)$. Sąlyginis vidurkis $\mathbf{E}(X|Y = y) = (x_1 + x_2)/2 = 2y + 1$. Kai $-2 < y < -1$, tai regresija $\mathbf{E}(X|Y = y)$ yra tiesės $x = 2y + 1$ atkarpa. Fiksuokime tašką y iš intervalo $(-1, 1)$. Tada a. d. X turi tolygųjį skirstinį intervale $x_1 < x < x_2$; čia x_1 taškas ant tiesės AB , o x_2 taškas ant tiesės CD ; $x_1 = y - 1, x_2 = y + 1$. Sąlyginis vidurkis $\mathbf{E}(X|Y = y) = (x_1 + x_2)/2 = y$. Kai $-1 < y < 1$, tai regresija $\mathbf{E}(X|Y = y)$ yra tiesės $x = y$ atkarpa. Analogiskai gausime, kad intervale $1 < y < 2$ sąlyginis vidurkis $\mathbf{E}(X|Y = y)$ yra tiesės $x = 2y - 1$ atkarpa.

A. d. X regresija Y atžvilgiu yra kreivė, susidedanti iš trijų atkarpu.

II.3.2 skyrelis

II.3.13. a) Kadangi

$$\mathbf{A}^T \mathbf{A} = \begin{pmatrix} n & 0 \\ 0 & \sum_i (x_i - \bar{x})^2 \end{pmatrix},$$

tai parametru $\beta = (\alpha, \beta)^T$ mažiausijų kvadratų įvertinys

$$\hat{\beta} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y} = (\bar{Y}, \sum_i Y_i(x_i - \bar{x}) / \sum_i (x_i - \bar{x})^2)^T;$$

$$\mathbf{V} \hat{\alpha} = \sigma^2/n, \quad \mathbf{V} \hat{\beta} = \sigma^2 / \sum_i (x_i - \bar{x})^2, \quad \mathbf{Cov}(\hat{\alpha}, \hat{\beta}) = 0.$$

b) Liekamoji kvadratų suma

$$SS_E = \sum_i (Y_i - \hat{\alpha} - \hat{\beta}(x_i - \bar{x}))^2, \quad \mathbf{E}(SS_E) = \sigma^2(n - 2),$$

ir nepaslinktasis dispersijos σ^2 įvertinys

$$s^2 = \frac{SS_E}{n - 2}, \quad \mathbf{E}(s^2) = \sigma^2.$$

II.3.14. a) Tikėtinumo funkcija

$$L(\alpha, \beta, \sigma^2) = (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_i (Y_i - \alpha - \beta(x_i - \bar{x}))^2 - \frac{n}{2} \ln \sigma^2\right\} = \\ (2\pi)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_i Y_i^2 + \frac{\alpha}{\sigma^2} \sum_i Y_i + \frac{\beta}{\sigma^2} \sum_i Y_i(x_i - \bar{x}) - B(\alpha, \beta, \sigma^2)\right\}$$

priklauso triparametrei eksponentinio tipo skirstinių šeimai. Statistika

$$\mathbf{T} = \left(\sum_i Y_i, \sum_i Y_i^2, \sum_i Y_i(x_i - \bar{x}) \right)$$

yra pilnoji ir pakankamoji. Todėl bet kuri \mathbf{T} funkcija yra jos vidurkio NMD įvertinys. Kadangi $\hat{\alpha}, \hat{\beta}, \hat{\theta} = c_1\hat{\alpha} + c_2\hat{\beta}, s^2$ yra \mathbf{T} funkcijos ir nepaslinktieji įvertiniai, tai jie yra ir NMD įvertiniai.

b) Įvertiniai $\hat{\alpha}, \hat{\beta}, \hat{\theta}$ yra normaliuju a. d. $Y_i \sim N(\alpha + \beta(x_i - \bar{x}), \sigma^2)$ tiesinės funkcijos, tai jie turi normaliuosius skirstinius. Centravę ir normavę gauname

$$\sqrt{n} \frac{\hat{\alpha} - \alpha}{\sigma} \sim N(0, 1), \quad \frac{\hat{\beta} - \beta}{\sigma \sqrt{1/\sum_i (x_i - \bar{x})^2}} \sim N(0, 1), \\ \frac{\hat{\theta} - \theta}{\sigma \sqrt{1/n + 1/\sum_i (x_i - \bar{x})^2}} \sim N(0, 1).$$

Dispersijos σ^2 įvertinys s^2 nepriklauso nuo $\hat{\alpha}$ ir $\hat{\beta}$ ir

$$s^2 = SS_E/(n-2), \quad s^2(n-2)/\sigma^2 \sim \chi^2(n-2).$$

II.3.15. Remdamiesi sąryšiu $s^2(n-2)/\sigma^2 \sim \chi^2(n-2)$ gauname dispersijos σ^2 lygmens $Q = 1 - 2\alpha$ pasiklivimo intervalą

$$(\underline{\sigma^2}; \overline{\sigma^2}) = \left(\frac{s^2(n-2)}{\chi_\alpha^2(n-2)}; \frac{s^2(n-2)}{\chi_{1-\alpha}^2(n-2)} \right).$$

Remdamiesi **II.3.14** pratimu gauname sąryšius

$$\sqrt{n} \frac{\hat{\alpha} - \alpha}{s} \sim S(n-2), \quad \frac{\hat{\beta} - \beta}{s \sqrt{1/\sum_i (x_i - \bar{x})^2}} \sim S(n-2), \\ \frac{\hat{\mu}(x) - \mu(x)}{s \sqrt{1/n + (x - \bar{x})^2 / \sum_i (x_i - \bar{x})^2}} \sim S(n-2),$$

iš kurių standartiniu būdu gauname pasiklivimo intervalus.

b) Kriterijus dėl parametrų reikšmių sudarome standartiniu būdu (pavyzdžiui, su formulavus juos pasiklivimo intervalų terminais). Pateiksime kriterijų hipotezei dėl prognozavimo tikslumumo, t. y. hipotezei $H : \beta = 0$, tikrinti. Hipotezė H atmetama reikšmingumo lygmens α kriterijumi, kai

$$|t| = \frac{|\hat{\beta} - 0|}{s \sqrt{1/\sum_i (x_i - \bar{x})^2}} > t_{\alpha/2}(n-2).$$

II.3.16. Tegu regresija $\mu(x)$ yra bet kokio pavidalo. Pažymėkime $\mu_i = \mathbf{E}(Y|x_i)$, $i = 1, \dots, k$; $\boldsymbol{\mu} = (\mu_1, \dots, \mu_k)^T$. Turime tiesinį modelį

$$Y_{ij} = \mu_i + e_{ij}, \quad j = 1, \dots, n_i, \quad i = 1, \dots, k.$$

Parametru μ_i DT įvertiniai $\hat{\mu}_i = \bar{Y}_{i\cdot} = \sum_{j=1}^{n_i} Y_{ij}/n_i$, o liekamoji kvadratų suma

$$SS_E = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i\cdot})^2 \stackrel{d}{=} \sigma^2 \chi_{n-k}^2.$$

Tikrinamają hipotezę galima suformuluoti pavidalu $H : \mathbf{H}\boldsymbol{\mu} = \boldsymbol{\theta}_0$ (žr. **II.1.21** pratima), kai matricos \mathbf{H} rargas yra $k-2$. Iš tikrųjų

$$\mu_i = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, k, \quad \Rightarrow \mu_1 - \mu_i = \beta_1(x_1 - x_i), \quad i = 2, \dots, k, \quad \Rightarrow$$

$$\frac{\mu_1 - \mu_i}{x_1 - x_i} = \beta_1, \quad i = 2, \dots, k, \quad \frac{\mu_1 - \mu_i}{x_1 - x_i} - \frac{\mu_1 - \mu_2}{x_1 - x_2} = 0, \quad i = 3, \dots, k.$$

Gauname

$$\frac{x_i - x_2}{x_1 - x_2} \mu_1 + \frac{x_1 - x_i}{x_1 - x_2} \mu_2 - \mu_i = 0, \quad i = 3, \dots, k$$

Galime imti matricą \mathbf{H} , turinčią $k-2$ eilutes ir k stulpelių; i -oji matricos eilutė

$$\left(\frac{x_i - x_2}{x_1 - x_2}, \frac{x_1 - x_i}{x_1 - x_2}, 0, \dots, 0 - 1, 0, \dots, 0 \right);$$

čia -1 yra i -oje pozicijoje, $i = 3, \dots, k$. Hipotezė užrašoma pavidalu $\mathbf{H}\boldsymbol{\mu} = \mathbf{0}$; matricos \mathbf{H} rargas yra $k-2$. Hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F = \frac{(SS_{EH} - SS_E)(n - k)}{(k - 2)SS_E} > F_\alpha(k - 2, n - k),$$

čia

$$SS_{EH} = \min_{\mu_i = \beta_0 + \beta_1 x_i} SS(\boldsymbol{\mu}) = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \hat{\beta}_0 - \hat{\beta}_1(x_i - \bar{x}))^2,$$

$$SS_{EH} - SS_E = \sum_{i=1}^k n_i (\bar{Y}_{i\cdot} - \hat{\beta}_0 - \hat{\beta}_1(x_i - \bar{x}))^2.$$

II.3.17. Hipotezė H atmetama, kai

$$F = \frac{(SS_{EH} - SS_E)(n - k)}{(k - r)SS_E} > F_\alpha(k - r, n - k),$$

čia SS_E surasta **II.3.16** pratime, o

$$SS_{EH} - SS_E = \sum_{i=1}^k n_i (\bar{Y}_{i\cdot} - \hat{\beta}_0 - \hat{\beta}_1 x_i - \dots - \hat{\beta}_r x_i)^2,$$

parametras $\boldsymbol{\beta} = (\beta_0, \beta_1, \dots, \beta_r)^T$ įvertinys yra

$$\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y},$$

kai plano matricos \mathbf{A} i -oji eilutė turi pavidalą $(1, x_i, \dots, x_i^r)$, o jos rangas lygus r .

II.3.18. Kadangi

$$Y_{n+1} - \hat{\mu}(x) \sim N(0, \sigma^2(1 + b^2(x))), \quad b^2(x) = \frac{1}{n} + \frac{(x - \bar{x})^2}{\sum_i (x_i - \bar{x})^2},$$

tai

$$\frac{Y_{n+1} - \hat{\mu}(x)}{s\sqrt{1 + b^2(x)}} \sim S(n-2).$$

Gauame prognozés intervalą

$$(\underline{Y}_{n+1}; \bar{Y}_{n+1}) = (\hat{\mu}(x) - st_\alpha(n-2)\sqrt{1 + b^2(x)}; \hat{\mu}(x) + st_\alpha(n-2)\sqrt{1 + b^2(x)}).$$

II.3.19. Naudojame savybę

$$\mathbf{P}\left\{\frac{|Y_{n+1} - \hat{\mu}(x)|}{s\sqrt{1 + b^2(x)}} < t_\alpha(n-2)\right\} = Q = 1 - 2\alpha.$$

Skliaustuose turime antro laipsnio nelygybę x atžvilgiu. Išsprendę nelygybę gausime pasiklivimo intervalo rėžius

$$\bar{x} + (B \mp \sqrt{B^2 - AC})/A, \quad B = \hat{\beta}(Y_{n+1} - \hat{\alpha}),$$

$$A = \hat{\beta}^2 - \frac{s^2 t_\alpha^2(n-2)}{(n-1) \sum_i (x_i - \bar{x})^2}, \quad C = (Y_{n+1}^2 - \hat{\alpha})^2 - \frac{n+1}{n} s^2 t_\alpha^2(n-2).$$

II.3.20. Hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai $|\hat{\theta} - \theta_0|/(sc) > t_{\alpha/2}(n-2)$; $\hat{\theta} = a\hat{\alpha} + b\hat{\beta}$, $s^2 = \sum_i (Y_i - \hat{\alpha} - \hat{\beta}(x_i - \bar{x}))^2/(n-2)$; $c^2 = a^2/n + b^2/\sum_i (x_i - \bar{x})^2$.

II.3.21. Tegu pirmosios imties elementai yra (Y_{1i}, X_{1i}) , $i = 1, \dots, n_1$, o antrosios – (Y_{2i}, X_{2i}) , $i = 1, \dots, n_2$. Vertinamos regresijos tiesės pavidalo: $\alpha_1 + \beta_1(X_{1i} - \bar{X}_{1..})$ ir $\alpha_2 + \beta_2(X_{2i} - \bar{X}_{2..})$. a) Hipotezė atmetama α lygmens kriterijumi, kai $|\hat{\beta}_1 - \hat{\beta}_2|/(sc) > t_{\alpha/2}(n_1 + n_2 - 4)$; $s^2 = [\sum_i (Y_{1i} - \hat{\alpha}_1 - \hat{\beta}_1(X_{1i} - \bar{X}_{1..}))^2 + \sum_i (Y_{2i} - \hat{\alpha}_2 - \hat{\beta}_2(X_{2i} - \bar{X}_{2..}))^2]/(n_1 + n_2 - 4)$, $c^2 = 1/\sum_i (X_{1i} - \bar{X}_{1..})^2 + 1/\sum_i (X_{2i} - \bar{X}_{2..})^2$. b) Hipotezė atmetama α lygmens kriterijumi, kai $|\hat{\alpha}_1 - \hat{\alpha}_2|/(sb) > t_{\alpha/2}(n_1 + n_2 - 4)$; $b^2 = 1/n_1 + 1/n_2$. c) Hipotezė atmetama α lygmens kriterijumi, kai $(SS_{EH} - SS_E)(n_1 + n_2 - 4)/(2SS_E) > F_\alpha(2, n_1 + n_2 - 4)$; $SS_E = s^2(n_1 + n_2 - 4)$; $SS_{EH} = [\sum_i (Y_{1i} - \hat{\alpha} - \hat{\beta}(X_{1i} - \bar{X}_{..}))^2 + \sum_i (Y_{2i} - \hat{\alpha} - \hat{\beta}(X_{2i} - \bar{X}_{..}))^2]$, čia $\bar{X}_{..} = (n_1 \bar{X}_{1..} + n_2 \bar{X}_{2..})/(n_1 + n_2)$, o $\hat{\alpha}$ ir $\hat{\beta}$ yra regresijos tiesės $\alpha + \beta(x - \bar{X}_{..})$ parametrujų ivertiniai, gauti sujungus visus $n_1 + n_2$ stebėjimus. d) perkelkime koordinačių pradžią: $Z_{1i} = X_{1i} - c$, $i = 1, \dots, n_1$ ir $Z_{2j} = X_{2j} - c$, $j = 1, \dots, n_2$. Kintamujų (Y_{1i}, Z_{1i}) ir (Y_{2j}, Z_{2j}) terminais tikrinamoji hipotezė ekvivalenti p. b) hipotezei.

II.3.22. Plano matrica

$$\mathbf{A} = \begin{pmatrix} 1 & -3 \\ 1 & -1 \\ 1 & 1 \\ 1 & 3 \end{pmatrix}, \quad (\mathbf{A}^T \mathbf{A})^{-1} = \begin{pmatrix} 1/4 & 0 \\ 0 & 1/20 \end{pmatrix},$$

$$\mathbf{A}^T \mathbf{Y} = \begin{pmatrix} Y - 1 + Y_2 + Y_3 + Y_4 \\ -3Y_1 - Y_2 + Y_3 + 3Y_4 \end{pmatrix}.$$

Gauname parametrujų vertinius $\hat{\alpha} = (Y_1 + Y_2 + Y_3 + Y_4)/4; \hat{\beta} = (-3Y_1 - Y_2 + Y_3 + 3Y_4)/20$ ir jų realizacijas $\hat{\alpha} = 3,255, \hat{\beta} = 1,063, s^2 = SS_E/2 = 0,0121$.

II.3.23. Turime tiesinį modelį $S_t = S_0 + vt + \varepsilon_t, t = 0, 1, 2, 3, 4; \varepsilon_0, \dots, \varepsilon_4$ nepriklausomu ir normalieji $N(0, \sigma^2)$. Plano matrica

$$\mathbf{A}^T = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 2 & 3 & 4 \end{pmatrix}, \quad (\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{10} \begin{pmatrix} 6 & -2 \\ -2 & 1 \end{pmatrix}, \quad \mathbf{A}^T \mathbf{Y} = \begin{pmatrix} \sum_t S_t \\ \sum_t tS_t \end{pmatrix}.$$

Gauname parametrujų vertinių realizacijas $\hat{S}_0 = 12,834, \hat{v} = 0,340, s^2 = SS_E/3 = 0,0259$ ir pasiklovimo intervalus

$$(\underline{v}; \bar{v}) = (0,178; 0,502); (\underline{\sigma^2}; \bar{\sigma^2}) = (0,0083; 0,3601).$$

II.3.24. Parametro α jvertis $\hat{\alpha} = 0,92; s^2 = 0,0967; (\underline{\alpha}; \bar{\alpha}) = (0,5338; 1,3062); (\underline{\sigma^2}; \bar{\sigma^2}) = (0,0347; 0,7992)$. Nurodymas. A. d. $Z_1 = Y_1, Z_j = Y_j - Y_{j-1}, j = 2, 3, 4, 5$ yra nepriklausomi su dispersijomis σ^2 ir vidurkiai $\mathbf{E}Z_1 = 0, \mathbf{E}Z_2 = \dots = \mathbf{E}Z_5 = \alpha$.

II.3.25. Gauname taškinį jvertį $\hat{\alpha} = 0,92$ ir pasiklovimo intervalą

$$(\underline{\alpha}; \bar{\alpha}) = (0,5338; 1,3062).$$

A. d. $Z_1 = Y_1, Z_j = Y_j - Y_{j-1}, j = 2, 3, 4, 5$ yra nepriklausomi; jų dispersijos σ^2 , o vidurkiai $\mathbf{E}Z_1 = 0, \mathbf{E}Z_2 = \dots = \mathbf{E}Z_5 = \alpha$. Gauname situaciją, analogišką II.3.24 pratimui.

II.3.26. a) Statistika F (II.3.17 pratimas) įgijo reikšmę 0,3985; kadangi

$$pv = \mathbf{P}\{F_{4,48} > 0,3985\} = 0,8087,$$

tai atmesti tiesiškumo hipotezę nėra pagrindo; b) $\hat{\alpha} = 1,0762, \hat{\beta} = 0,0540, \hat{\sigma^2} = 0,06205; (\underline{\alpha}; \bar{\alpha}) = (1,0082; 1,1443); (\underline{\beta}; \bar{\beta}) = (-1,4982; 1,6062); (\underline{\sigma^2}; \bar{\sigma^2}) = (0,0437; 0,0950)$.

II.3.27. Modelyje

$$Y_{ij} = \mu_i + e_{ij}, \quad j = 1, \dots, n, \quad i = 1, \dots, 11,$$

liekamoji kvadratų suma

$$SS_E/\sigma^2 = \sum_{i=1}^{11} \sum_{j=1}^n (Y_{ij} - \bar{Y}_{i.})^2 / \sigma^2 \sim \chi^2(11(n-1)).$$

Jeigu hipotezė teisinga, tai

$$SS_{EH} = \sum_{i=1}^{11} \sum_{j=1}^n (Y_{ij} - xi)^2 = SS_E + n \sum_{i=1}^{11} (\bar{Y}_{i.} - x_i)^2;$$

$$(SS_{EH} - SS_E)/\sigma^2 = n \sum_{i=1}^{11} (\bar{Y}_{i.} - x_i)^2 / \sigma^2 \sim \chi^2(11).$$

Hipotezė H atmetama reikšmingumo lygmens α kriterijumi, kai

$$F + \frac{(SS_{EH} - SS_E)11(n-1)}{11SS_E} > F_\alpha(11, 11(n-1)).$$

Jeigu $\mathbf{E}(Y|X = x_i) = x_i^2$, tai

$$\sqrt{n} \frac{\bar{Y}_{i\cdot} - x_i}{\sigma} \sim N(\lambda_i, 1), \quad \lambda_i = \sqrt{n} \frac{x_i^2 - x_i}{\sigma}.$$

Todėl

$$(SS_{EH} - SS_E)/\sigma^2 \sim \chi^2(11; \lambda), \quad \lambda = \sum_{i=1}^{11} \lambda_i^2 = 3,333n.$$

Imties didumui n rasti turime nelygybę

$$\mathbf{P}\{F_{11,11(n-1);\lambda} > F_{0,05}(11, 11(n-1))\} \geq 0,95.$$

Iš šios nelygybės gauname, kad $n \geq 32$.

II.3.28. Pratime **3.18** reikia $b^2(x)$ apibrėžti tokiu būdu:

$$b^2(x) = k/n + (x - \bar{x})^2 / ((n-1)s_x^2).$$

II.3.29. Pažymėkime $u = 1/y, v = \sin^2 x$. Tada

$$u = \gamma + \delta v; \quad \gamma = 1/\alpha, \quad \delta = (\alpha - \beta)/(\alpha\beta).$$

II.3.30. $\hat{\alpha} = 8,535$, $\hat{\beta} = 1,2066$, $\hat{\sigma}^2 = 0,8115$; statistika F (**II.3.16** pratimas) įgijo reikšmę 1,9864; kadangi

$$pv = \mathbf{P}\{F_{3,15} > 1,9864\} = 0,1594,$$

tai atmeti tiesiškumo hipotezę nėra pagrindo; tolesnio matavimo prognozės intervalas yra (14,3215; 15,5385), kai $x = 12$, ir (21,1458; 23,1934), kai $x = 18$.

II.3.31. $\hat{\mu} = 0,9343 + 0,8787x$; hipotezė $H : \beta = 0$ atmetama: a. d., turintis Stjudento skirstinį su 106 laisvės laipsniais, kai hipotezė teisinga, įgijo reikšmę 21,7608; paaiškina 0,817 skliaudos dalį.

II.3.32. a) $\hat{\beta}_0 = 0,0144, \hat{\beta}_1 = 0,0149, \hat{\sigma}^2 = 0,00004$. Determinacijos koeficientas 0,9697. Sklaidos diagramoje prognozės paklaidos išsidėšiusios neatsitiktinai, todėl regresijos tiesinis pavidalas nepriimtinas. b) $\hat{\alpha} = 0,1758, \hat{\beta}_1 = 0,1531$. Esant pasikliovimo lygmeniui $Q = 0,95$ gauname $(\underline{\alpha}; \bar{\alpha}) = (0,1690; 0,1827)$, $(\underline{\beta}; \bar{\beta}) = (0,1437; 0,1626)$.

II.3.33. $\hat{\alpha}_1 = 13,2255, \hat{\alpha}_2 = 1,0158, \hat{\beta}_1 = 6,7978, \hat{\beta}_2 = 0,0798$. Esant pasikliovimo lygmeniui $Q = 0,95$ gauname $(\underline{\alpha}_1; \bar{\alpha}_1) = (13,0724; 13,3787)$, $(\underline{\alpha}_2; \bar{\alpha}_2) = (0,9915; 1,0402)$, $(\underline{\beta}_1; \bar{\beta}_1) = (6,6336; 6,9620)$, $(\underline{\beta}_2; \bar{\beta}_2) = (0,0767; 0,0825)$.

II.3.3 skyrelis

II.3.34. a) Remiantis **II.1.19** pratimu parametru $\boldsymbol{\theta}$ pilnoji ir pakankamoji statistika yra $\mathbf{T} = ((\mathbf{A}^T \mathbf{Y})^T, \mathbf{Y}^T \mathbf{Y})^T = (n\bar{Y}, \sum_i Y_i x_{1i}, \dots, \sum_i Y_i x_{mi}, \mathbf{Y}^T \mathbf{Y})^T$.

b) Jeigu plano matricos \mathbf{A} rangas lygus $m+1$, tai parametru $\boldsymbol{\beta}$ NMD įvertinys yra

$$\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}.$$

Kadangi šis įvertinys yra normaliojo a. v. \mathbf{Y} tiesinė funkcija, tai

$$\hat{\boldsymbol{\beta}} \sim N_{m+1}(\boldsymbol{\beta}, \sigma^2(\mathbf{A}^T \mathbf{A})^{-1}).$$

Liekamoji kvadratų suma

$$SS_E = \sum_i (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_m x_{mi})^2 \stackrel{d}{=} \sigma^2 \chi^2_{n-m-1}$$

ir dispersijos σ^2 NMD įvertinys

$$s^2 = \frac{SS_E}{n-m-1}, \quad \mathbf{E}s^2 = \sigma^2, \quad \frac{s^2(n-m-1)}{\sigma^2} \sim \chi^2(n-m-1).$$

II.3.35. Remdamies sąryšiu $s^2(n-m-1)/\sigma^2 \sim \chi^2(n-m-1)$ gauname parametru σ^2 lygmens $Q = 1 - 2\alpha$ pasiklovimo intervalą

$$(\underline{\sigma^2}; \overline{\sigma^2}) = \left(\frac{s^2(n-m-1)}{\chi^2_\alpha(n-m-1)}; \frac{s^2(n-m-1)}{\chi^2_{1-\alpha}(n-m-1)} \right).$$

Kadangi $\hat{\beta}_i \sim N(\beta_i, \sigma^2 c_{ii})$, čia c_{ij} yra matricos $(\mathbf{A}^T \mathbf{A})^{-1}$ elementai, tai

$$\frac{\hat{\beta}_i - \beta_i}{s\sqrt{c_{ii}}} \sim S(n-m-1), \quad \frac{\hat{\theta} - \theta}{sb(\mathbf{L})} \sim S(n-m-1),$$

čia $b^2(\mathbf{L}) = \mathbf{L}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{L}$, tai standartiniu būdu galime gauti parametrų pasiklovimo intervalus. Pavyzdžiui,

$$(\underline{\theta}; \overline{\theta}) = (\hat{\theta} - sb(\mathbf{L})t_\alpha(n-m-1); \hat{\theta} + sb(\mathbf{L})t_\alpha(n-m-1)).$$

II.3.36. Hipotezę H_{j_1, \dots, j_k} galima suformuluoti pavidalu $H_{j_1, \dots, j_k} : \mathbf{H}\boldsymbol{\beta} = \boldsymbol{\theta}_0$, kai matricos \mathbf{H} rangas lygus k . Hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_{j_1, \dots, j_k} = \frac{(SS_E^{(m-k)} - SS_E)(n-m-1)}{kSS_E} > F_\alpha(k, n-m-1),$$

čia $SS_E^{(m-k)}$ yra liekamoji kvadratų suma modelyje be kovariančių $(x_{j_1}, \dots, x_{j_k})$.

Tikrinant hipotezę $H_j : \beta_j = 0$ apie atskirios kovariantės x_j įtakos prognozei nebuvinamą, galima remiantis **II.3.36** pratimu kriterijus suformuluoti taip: hipotezė H_j atmetama reikšmingumo lygmens kriterijumi, kai

$$|t_j| = \frac{|\hat{\beta}_j|}{s\sqrt{c_{jj}}} > t_{\alpha/2}(n-m-1).$$

Hipotezės $H_{1, \dots, m}$ atveju

$$SS_E^{(0)} = \min_{\beta_0} \sum_i (Y_i - \beta_0)^2 = \sum_i (Y_i - \bar{Y})^2 = SS_T,$$

$SS_E^{(0)} - SS_E = SS_R$, ir $R^2 = SS_R/SS_T$ vadinamas determinacijos koeficientu. Jis yra dauginio koreliacijos koeficiente kvadrato $\rho_{Y(X_1, \dots, X_m)}^2$ ivertinys. Hipotezė $H_{1,\dots,m}$ atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_{1,\dots,m} = \frac{SS_R(n-m-1)}{mSS_E} > F_\alpha(m, n-m-1).$$

II.3.37. Tarkime, kad regresija yra bet kokio pavidalo. Pažymėkime $\mu_i = \mathbf{E}(Y|\mathbf{X} = \mathbf{x}^{(i)})$, $i = 1, \dots, k$, $\boldsymbol{\mu} = (\mu_1, \dots, \mu_k)^T$. Turime tiesinį modelį

$$Y_{ij} = \mu_i + e_{ij}, \quad j = 1, \dots, n_i, \quad i = 1, \dots, k.$$

Parametru μ_i DT ivertiniai $\hat{\mu}_i = \bar{Y}_{\cdot i} = \sum_{j=1}^{n_i} Y_{ij}/n_i$, o liekamoji kvadratų suma

$$SS_E = \min_{\boldsymbol{\mu}} SS(\boldsymbol{\mu}) = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{\cdot i})^2 \sim \sigma^2 \chi_{n-k}^2.$$

Tikrinamają hipotezę galima suformuluoti pavidalu $H : \mathbf{H}\boldsymbol{\mu} = \boldsymbol{\theta}_0$. Rasime matricos \mathbf{H} išraišką. Jeigu H teisinga, tai

$$\mu_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_m x_{mi}, \quad i = 1, \dots, k.$$

Imdami skirtumus

$$\mu_i - \mu_1 = \beta_1(x_{1i} - x_{11}) + \dots + \beta_m(x_{mi} - x_{m1}), \quad i = 2, \dots, k,$$

matome, kad parametras β_0 eliminuotas ir $\mu_i, i = 2, \dots, k$ tiesiškai priklauso nuo μ_1 ir β_1, \dots, β_m . Padalinę iš $x_{1i} - x_{11}$

$$\frac{\mu_i - \mu_1}{x_{1i} - x_{11}} = \beta_1 + \beta_2 \frac{x_{2i} - x_{21}}{x_{1i} - x_{11}} + \dots + \beta_m \frac{x_{mi} - x_{m1}}{x_{1i} - x_{11}}, \quad i = 2, \dots, k,$$

ir imdami skirtumus $(\mu_i - \mu_1)/(x_{1i} - x_{11}) - (\mu_2 - \mu_1)/(x_{1i} - x_{11})$, $i = 3, \dots, k$, eliminuojame parametrą β_1 ir $\mu_i, i = 3, \dots, k$ tiesiškai priklausys nuo μ_1, μ_2 ir β_2, \dots, β_m . Tęsiant šią procedūrą po $(m+1)$ -ojo žingsnio bus eliminuoti visi parametrai $\beta_0, \beta_1, \dots, \beta_m$ ir $\mu_i, i = m+2, \dots, k$ tiesiškai priklausys nuo parametru μ_1, \dots, μ_{m+1} :

$$\mu_i = c_{i1}\mu_1 + c_{i2}\mu_2 + \dots + c_{i,m+1}\mu_{m+1}, \quad i = m+2, \dots, k.$$

Imkime matricos \mathbf{H} i -ąją eilutę tokio pavidalo:

$$(c_{i1} \dots c_{i,m+1} \ 0 \dots 0 \ -1 \ 0 \dots 0), \quad i = m+2, \dots, k,$$

čia -1 yra i -oje pozicijoje. Matricos \mathbf{H} rangas yra $k - m - 1$. Tikrinamoji hipotezė užrašoma pavidalu $H : \mathbf{H}\boldsymbol{\mu} = \mathbf{0}$.

Remiantis **II.1.21** pratimu hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F = \frac{(SS_{EH} - SS_E)(n-k)}{(k-m-1)SS_E} > F_\alpha(k-m-1, n-k),$$

čia SS_{EH} yra kvadratinės formos $SS(\boldsymbol{\mu})$ sąlyginis minimums, kai teisinga hipotezė (jis surastas **II.3.34** pratime)

$$SS_{EH} - SS_E = \sum_{i=1}^k n_i (\bar{Y}_{i\cdot} - \hat{\beta}^T \mathbf{x}^{(i)})^2.$$

II.3.38. Atsitiktiniai dydžiai Y_{n+1} ir $\hat{\mu}(\mathbf{x})$ nepriklausomi ir normalieji. Tada

$$Y_{n+1} - \hat{\mu}(\mathbf{x}) \sim N(0, \sigma^2(1 + b^2(\mathbf{x}))), \quad b^2(\mathbf{x}) = \mathbf{x}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{x}$$

ir

$$\frac{Y_{n+1} - \hat{\mu}(\mathbf{x})}{s\sqrt{1 + b^2(\mathbf{x})}} \sim S(n - m - 1).$$

A. d Y_{n+1} pasiklivimo lygmens $Q = 1 - 2\alpha$ prognozės intervalo rėžiai yra

$$\hat{\mu}(\mathbf{x}) \mp s\sqrt{1 + b^2(\mathbf{x})}t_\alpha(n - m - 1).$$

II.3.39. a) Atlikus polinominę regresiją (pirmo, antro trečio, laipsnio) gauta, kad netenkinamos tiesinės regresijos prielaidos.

b) Imkime eksponentinio tipo priklausomybę $\mathbf{E}(Y|X) = \alpha e^{-\beta X}$. Pažymėję $U = \ln Y$ gausime tiesinį modelį $U_i = \beta_0 - \beta X_i + e_i$, $\beta_0 = \ln \alpha$. Tardami, kad paklaidos tenkina įprastines regresinės analizės sąlygas, gauname parametrų įvertinius $\hat{\beta}_0 = 4,29799$; $\hat{\beta} = -0,01824$. Determinacijos koeficientas $R^2 = 0,3489$, todėl gautas modelis netinkamas prognozavimui.

II.3.40. $\mathbf{E}\hat{\beta}_0 - \beta_0 = 4\beta_2$, $\mathbf{E}\hat{\beta}_1 - \beta_1 = 7\beta_3$.

II.3.41. Parametrų θ_1, θ_2 MK įvertiniai $\hat{\theta}_1 = (Y_1 - Y_3)/2$, $\hat{\theta}_2 = (Y_1 + 2Y_2 + Y_3)/6$; $\mathbf{V}(\hat{\theta}_1) = \sigma^2/2$, $\mathbf{V}(\hat{\theta}_2) = \sigma^2/6$, $\mathbf{Cov}(\hat{\theta}_1, \hat{\theta}_2) = 0$; $SS_E = ((Y_1 - Y_2)^2 + 2Y_3^2)/3 \sim \sigma^2 \chi_1^2$. Tikrinama hipotezė $H : \beta = \theta_1 - 2\theta_2 = 0$; $\hat{\beta} = (Y_1 - 4Y_2 - 5Y_3)/6$, $\mathbf{V}\hat{\beta} = 7\sigma^2/6$; $6\hat{\beta}^2/7 \sim \sigma^2 \chi_1^2$. Hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F = \frac{(Y_1 - 4Y_2 - 5Y_3)^2}{14[(Y_1 - Y_2)^2 + 2Y_3^2]} > F_\alpha(1, 1).$$

II.3.42. Kadangi keturkampio kampų suma lygi 2π , tai išreiškė $\varphi_4 = 2\pi - \varphi_1 - \varphi_2 - \varphi_3$ gauname, kad modelis priklauso nuo 3 nežinomų parametrų $\varphi_1, \varphi_2, \varphi_3$. Stebėjimai turi tokią struktūrą

$$\begin{cases} Y_1 = \varphi_1 + e_1, \\ Y_2 = \varphi_2 + e_2, \\ Y_3 = \varphi_3 + e_3, \\ 2\pi - Y_4 = \varphi_1 + \varphi_2 + \varphi_3 + e_4; \end{cases}$$

$$(\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{4} \begin{pmatrix} 3 & -1 & -1 \\ -1 & 3 & -1 \\ -1 & -1 & 3 \end{pmatrix}, \quad \mathbf{A}^T \mathbf{Y} = \begin{pmatrix} Y_1 - Y_4 + 2\pi \\ Y_2 - Y_4 + 2\pi \\ Y_3 - Y_4 + 2\pi \end{pmatrix}.$$

Gauname parametrų įvertinius $\hat{\varphi}_1 = 3Y_1 - Y_2 - Y_3 - Y_4 + 2\pi$, $\hat{\varphi}_2 = -Y_1 + 3Y_2 - Y_3 - Y_4 + 2\pi$, $\hat{\varphi}_3 = -Y_1 - Y_2 + 3Y_3 - Y_4 + 2\pi$ ir liekamają kvadratų sumą

$$SS_E = \frac{1}{4} \left(\sum_i Y_i - 2\pi \right)^2 \sim \sigma^2 \chi_1^2.$$

Kai hipotezė teisinga yra, du nežinomi parametrai φ_1, φ_2 , kurie susieti lygybe $2\varphi_1 + 2\varphi_2 = 2\pi$. Išreiškė $\varphi_2 = \pi - \varphi_1$ gauname, kad modelis priklauso tik nuo vieno parametru φ_1 . Stebėjimai turi tokią struktūrą

$$Y_1 = \varphi_1 + e_1, \quad \pi - Y_2 = \varphi_1 + e_2, \quad Y_3 = \varphi_1 + e_3, \quad \pi - Y_4 = \varphi_1 + e_4.$$

Parametru φ_1 MK įvertinys $\tilde{\varphi}_1 = (Y_1 + Y_3 - Y_2 - Y_4 + 2\pi)/4$ ir sąlyginė liekamoji kvadratų suma

$$SS_{EH} = SS_E + \frac{1}{2}((Y_1 - Y_3)^2 + (Y_2 - Y_4)^2);$$

$$SS_{EH} - SS_E = \frac{1}{2}((Y_1 - Y_3)^2 + (Y_2 - Y_4)^2) \sim \sigma^2 \chi_2^2.$$

Hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai $F = [(Y_1 - Y_3)^2 + (Y_2 - Y_4)^2]/(\sum_i Y_i - 2\pi)^2 > F_\alpha(2, 1)$.

II.3.43. Pažymėkime $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ ir $\boldsymbol{\beta} = (\beta_0, \beta_1, \beta_2)^T$. Tada

$$\hat{\boldsymbol{\beta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y};$$

čia matrica \mathbf{A}^T turi 3 eilutes ir n stulpelių; pirmoji eilutė yra $(1, 1, \dots, 1)$; antroji $(\cos(2\pi k_1/n), \cos(4\pi k_1/n), \dots, \cos(2n\pi k_1/n))$; trečioji $(\sin(2\pi k_1/n), \sin(4\pi k_1/n), \dots, \sin(2n\pi k_1/n))$.

II.3.44. a) $\hat{\beta}_0 = 84, 55$, $\hat{\beta}_1 = 1, 83$, $\hat{\beta}_2 = 2, 68$; b) Gauname $F_1 = 5, 89$ ir $F_2 = 8, 62$; regresijos koeficientų lygbiės nuliui hipotezės atmetamos; c) 99, 02; 105, 36.

II.3.45. Pažingsninės regresijos metodu (žr. [3], 3.3.11 skyrelį) gauname, kad prognozuojant X_4 reikia naudotis visais kintamaisiais X_1, X_2, X_3 ; regresijos įvertis $\hat{X}_4 = 8, 29 + 0, 60X_1 - 0, 14X_2 + 0, 52X_3$; $r_{X_4(X_1, X_2, X_3)} = 0, 8770$.

II.3.46. Parinkę pirmojo, antrojo, trečiojo ir ketvirtokojo laipsnio polinomus gauname, kad netenkinamos tiesinės regresijos prielaidos.

II.3.47. $\varphi(x) = 2 - 3x^2$.

II.3.4 skyrelis

II.3.48. Žr. [3], 4.3.1 skyrelį.

II.3.49. a) Sąlyginis kvadratinės formos minimums

$$SS_{EH\gamma} = \min_{\boldsymbol{\beta}, \boldsymbol{\gamma}=\mathbf{0}} (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta} - \mathbf{C}\boldsymbol{\gamma})^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta} - \mathbf{C}\boldsymbol{\gamma}) = (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}}_0)^T (\mathbf{Y} - \mathbf{A}\hat{\boldsymbol{\beta}}_0) = R_{yy};$$

$$SS_{\boldsymbol{\gamma}} = SS_{EH\gamma} - SS_E = \hat{\gamma}_1 R_{yx_1} + \dots + \hat{\gamma}_k R_{yx_k}.$$

Hipotezė $H_{\boldsymbol{\gamma}}$ atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_{\boldsymbol{\gamma}} = \frac{SS_{\boldsymbol{\gamma}}(n - m - k)}{kSS_E} > F_\alpha(k, n - m - k).$$

b) Sąlyginis kvadratinės formos minimums

$$SS_{EH_{\gamma_1, \dots, \gamma_l}} = \min_{\boldsymbol{\beta}, \boldsymbol{\gamma}: \gamma_{i_1} = \dots = \gamma_{i_l} = 0} (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta} - \mathbf{C}\boldsymbol{\gamma})^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta} - \mathbf{C}\boldsymbol{\gamma})$$

randamas kaip ir **II.3.48** pratime praleidus modelyje kovariantes X_{i_1}, \dots, X_{i_l} . Tada hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_{\gamma_1, \dots, \gamma_l} = \frac{(SS_{EH_{\gamma_1, \dots, \gamma_l}} - SS_E)(n - m - k)}{lSS_E} > F_{\alpha}(l, n - m - k).$$

II.3.50. Remiantis bendra tiesinių modelių teorija reikia rasti sąlyginį minimumą

$$SS_{EH} = \min_{\beta_{i_1} = \dots = \beta_{i_s}} (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta} - \mathbf{C}\boldsymbol{\gamma})^T (\mathbf{Y} - \mathbf{A}\boldsymbol{\beta} - \mathbf{C}\boldsymbol{\gamma}).$$

Sąlyginį minimumą galima rasti kaip **II.3.48** pratime vietoje parametru $\boldsymbol{\beta}$ imant parametrą $\boldsymbol{\theta} = (\theta_1, \dots, \theta_{m-s+1})$. Šis vektorius susideda iš likusių vektoriaus $\boldsymbol{\beta}$ koordinačių ir parametru θ_{m-s+1} , jrašyto vietoje $\beta_{i_1}, \dots, \beta_{i_s}$.

Tada hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_H = \frac{(SS_{EH} - SS_E)(n - m - k)}{sSS_E} > F_{\alpha}(s, n - m - k).$$

II.3.51. Gauname (žr. **II.3.48** pratimą)

$$\begin{aligned} R_{yy} &= \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})^2, \quad R_{xx} = \sum_{i=1}^I \sum_{j=1}^{J_i} (X_{ij} - \bar{X}_{i.})^2, \\ R_{xy} &= \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})(X_{ij} - \bar{X}_{i.}); \\ \hat{\gamma} &= \frac{R_{xy}}{R_{xx}}, \quad SS_E = R_{yy} - \hat{\gamma}R_{xy} = R_{yy} - \frac{R_{xy}^2}{R_{xx}} \sim \sigma^2 \chi^2_{n-I-1}. \end{aligned}$$

Tikrinant $H_{\gamma} : \gamma = 0$ (žr. **II.3.49** pratimą)

$$SS_{\gamma} = SS_{EH_{\gamma}} - SS_E = \frac{R_{xy}^2}{R_{xx}}.$$

Hipotezė H_{γ} atmetama, kai

$$F_{\gamma} = \frac{SS_{\gamma}(n - I - 1)}{SS_E} = \frac{R_{xy}^2(n - I - 1)}{R_{xx}R_{yy} - R_{xy}^2} > F_{\alpha}(1, n - I - 1).$$

Tikrinant hipotezę $H_A : \alpha_1 = \dots = \alpha_I = 0$ (žr. **II.3.50** pratimą) sąlyginis kvadratinės formos minimumas

$$SS_{EH_A} = \min_{\mu, \gamma} \sum_i \sum_j (Y_{ij} - \mu - \gamma x_{ij})^2.$$

Kartodami **II.3.48** pratimą (vietoje raidžių R imdami T) gausime

$$T_{yy} = \sum_i \sum_j (Y_{ij} - \bar{Y}_{..})^2 = R_{yy} + \sum_i J_i(\bar{Y}_{i.} - \bar{Y}_{..})^2 = R_{yy} + SS_A,$$

$$T_{xx} = \sum_i \sum_j (X_{ij} - \bar{X}_{..})^2, \quad T_{xy} = \sum_i \sum_j (Y_{ij} - \bar{Y}_{..})(X_{ij} - \bar{X}_{..});$$

$$\tilde{\gamma} = \frac{T_{xy}}{T_{xx}}, \quad SS_{EH_A} = T_{yy} - \tilde{\gamma} \frac{T_{xy}}{T_{xx}} = T_{yy} - \frac{T_{xy}^2}{T_{xx}};$$

$$SS_{EH_A} - SS_E = SS_A - \frac{T_{xy}^2}{T_{xx}} + \frac{R_{xy}^2}{R_{xx}}.$$

Hipotezė H_A atmetama reikšmingumo lygmens α kriterijumi, kai

$$F_A = \frac{(SS_{EH_A} - SS_E)(n - I - 1)}{(I - 1)SS_E} =$$

$$= \frac{(SS_A - \frac{T_{xy}^2}{T_{xx}} + \frac{R_{xy}^2}{R_{xx}})(n - I - 1)}{(I - 1)(R_{yy} - \frac{R_{xy}^2}{R_{xx}})} > F_\alpha(I - 1, n - I - 1).$$

Norėdami palyginti pateiksime hipotezės H_A tikrinimo kriterijų dispersinės analizės schema (neatsižvelgiant į kovariantę X): hipotezė atmetama reikšmingumo lygmens α kriterijumi, kai

$$\frac{SS_A(n - I)}{(I - 1)R_{yy}} > F_\alpha(I - 1, n - I).$$

II.3.52. Pažymėkime

$$R_{0r} = \sum_i \sum_j (Y_{ij} - \bar{Y}_{i.})(X_{ij}^{(r)} - \bar{X}_{i.}^{(r)}), \quad r = 1, 2;$$

$$R_{rs} = \sum_i \sum_j (X_{ij}^{(r)} - \bar{X}_{i.}^{(r)})(X_{ij}^{(s)} - \bar{X}_{i.}^{(s)}), \quad r, s = 1, 2.$$

Tada a) $\hat{\gamma}_1 = (R_{01}R_{22} - R_{02}R_{12})/\Delta$, $\hat{\gamma}_2 = (R_{02}R_{11} - R_{01}R_{12})/\Delta$, $\Delta = R_{11}R_{22} - R_{12}^2$;
b) $\mathbf{V}\hat{\gamma}_1 = \sigma^2 I(J-1)R_{22}/\Delta$, $\mathbf{V}\hat{\gamma}_2 = \sigma^2 I(J-1)R_{11}/\Delta$, $\mathbf{Cov}(\hat{\gamma}_1, \hat{\gamma}_2) = -\sigma^2 I(J-1)R_{12}/\Delta$;
 $\hat{\gamma}_1$ ir $\hat{\gamma}_2$ nekoreliuoti, kai $R_{12} = 0$.

II.3.53. a) Randame

$$R_{yy}(i, j) = \sum_k (Y_{ijk} - \bar{Y}_{ij.})^2, \quad R_{xx}(i, j) = \sum_k (X_{ijk} - \bar{X}_{ij.})^2,$$

$$R_{yx}(i, j) = \sum_k (Y_{ijk} - \bar{Y}_{ij.})(X_{ijk} - \bar{X}_{ij.});$$

$$SS_E(i, j) = R_{yy}(i, j) - R_{yx}^2(i, j)/R_{xx}(i, j), \quad SS_E = \sum_i \sum_j SS_E(i, j) \sim \sigma^2 \chi^2_{IJ(K-2)}.$$

Kai hipotezė H teisinga, tai

$$\hat{\gamma} = R_{yx}/R_{xx}, \quad SS_{EH} = R_{yy} - R_{yx}^2/R_{xx},$$

$$R_{yy} = \sum_i \sum_j R_{yy}(i, j), \quad R_{xx} = \sum_i \sum_j R_{xx}(i, j), \quad R_{yx} = \sum_i \sum_j R_{yx}(i, j);$$

hipotezė H atmetama reikšmingumo lygmens α kriterijumi, kai

$$(SS_{EH} - SS_E)(IJ(K-2))/(SS_E(IJ-1)) > F_\alpha(IJ-1, IJ(K-2)).$$

b) Kai H teisinga, tai a. d.

$$\sqrt{R_{xx}}(\hat{\gamma} - \gamma)/\sqrt{SS_{EH}/(IJK - IJ - 1)} \sim S(IJK - IJ - 1).$$

II.3.54. Randame $R_{yy} = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{ij.})^2$, $R_{xx} = \sum_i \sum_j \sum_k (X_{ijk} - \bar{X}_{ij.})^2$, $R_{yx} = \sum_i \sum_j \sum_k (Y_{ijk} - \bar{Y}_{ij.})(X_{ijk} - \bar{X}_{ij.})$; $\hat{\gamma} = R_{yx}/R_{xx}$, $SS_E = R_{yy} - \hat{\gamma}R_{yx} \sim \sigma^2 \chi^2_{IJK - IJ - 1}$.

a) Hipotezė H atmetama reikšmingumo lygmenis α kriterijumi, kai $\hat{\gamma}R_{xx}(IJK - IJ - 1)/SS_E > F_\alpha(1, IJK - IJ - 1)$.

b) Randame $\tilde{R}_{yy} = R_{yy} + JK \sum_i (\bar{Y}_{i..} - \bar{Y}_{...})^2$, $\tilde{R}_{xx} = R_{xx} + JK \sum_i (\bar{X}_{i..} - \bar{X}_{...})^2$, $\tilde{R}_{yx} = R_{yx} + JK \sum_i (\bar{Y}_{i..} - \bar{Y}_{...})(\bar{X}_{i..} - \bar{X}_{...})$, $SS_{EH} = \tilde{R}_{yy} - \hat{\gamma}\tilde{R}_{yx}$; hipotezė H_A atmetama reikšmingumo lygmenis α kriterijumi, kai $(SS_{EH} - SS_E)(IJK - IJ - 1)/((I - 1)SS_E) > F_\alpha(I - 1, IJK - IJ - 1)$.

II.3.55. Remdamiesi kovariacine analize randame $SS_E = \sum_i [R_{yy}^{(i)} - (R_{yx}^{(i)})^2/R_{xx}]$, $R_{yy}^{(i)} = \sum_j (Y_{ij} - \bar{Y}_{i.})^2$, $R_{yx}^{(i)} = \sum_j (Y_{ij} - \bar{Y}_{i.})(X_j - \bar{X}_.)$, $i = 1, 2$, $R_{xx} = \sum_j (X_j - \bar{X}_.)^2$; $SS_{EH} = R_{yy}^{(1)} + R_{yy}^{(2)} - (R_{yx}^{(1)} + R_{yx}^{(2)})^2/(2R_{xx})$. Hipotezė atmetama reikšmingumo lygmenis α kriterijumi, kai $F = (SS_{EH} - SS_E)2(J - 1)/SS_E = [R_{yx}^{(1)} - R_{yx}^{(2)}]^2 2(J - 1)/(2R_{xx}SS_E) > F_\alpha(1, 2(J - 1))$. Tirkindami dviejų regresijos tiesių lygiagretumo hipotezę remiamės statistika $T = (\hat{\gamma}_1 - \hat{\gamma}_2)\sqrt{R_{xx}}/\sqrt{2SS_E/(2(J - 1))}$. Nesunku patikrinti, kad $F = T^2$.

II.3.56. a) Kadangi statistikos reikšmė $F_A = 14,6$, tai hipotezė atmetama kriterijumi su gana aukštu reikšmingumo lygmeniu. b) Imdami antro laipsnio polinomą gauname, kad kovariantė ir jos kvadratas yra reikšmingi, nes statistikų reikšmės atitinkamai yra 48,83 ir 53,75. Imdami trečio laipsnio polinomą gauname, kad kovariantė, jos kvadratas ir trečiasis laipsnis yra reikšmingi, nes statistikų reikšmės atitinkamai yra 35,23, 17,89 ir 8,87. Kadangi statistikos reikšmė yra 28,78, tai hipotezė apie faktoriaus įtakos nebuvinė atmetama kriterijumi su gana aukštu reikšmingumo lygmeniu.

II.3.57. a) Atlikę dispersinę analizę gauname, kad faktorius C ($F_C = 1, 17$; atitinkama P reikšmė yra 0,2947) ir kitų faktorių sąveikos su faktoriumi C ($F_{AC} = 1, 35$, $F_{BC} = 1, 09$, $F_{CD} = 1, 17$; atitinkamos P reikšmės 0,2878; 0,3609; 0,2947) nereikšmingos. Atlikus dispersinę analizę neįtraukiant faktoriaus C ir sąveikų su faktoriumi C gautos tokios statistikų realizacijos: $F_A = 124,60$; $F_B = 728,98$; $F_D = 118,78$; $F_{AB} = 41,75$, todėl hipotezės atmetamos su gana aukštu reikšmingumo lygmeniu. Statistikos $F_{AD} = 0,87$, $F_{BD} = 3,09$; atitinkamos P reikšmės 0,4348, 0,0657. b) Atlikus analizę, kai eliminuota kovariantės B įtaka, gauta: faktorių A ir C , A ir D , C ir D sąveikos nereikšmingos (statistikų reikšmės yra 0,17; 0,11; 0,15; atitinkamos P reikšmės 0,8469; 0,8933; 0,7059). Faktorių A ir D įtakos nebuvinimo hipotezė atmetama aukšto reikšmingumo lygmenis kriterijais. Faktorius C nereikšmingas (statistikos reikšmė 0,15; atitinkama P reikšmė 0,7059).

II.3.58. a) Kadangi $F_A = 43,67$, tai hipotezė atmetama. b) $\hat{\beta}_0 = -127,17$; $\hat{\beta}_1 = 90,827$. Hipotezė $H : \beta_1 = 0$ atmetama. c) Tirkinant hipotezę H_A eliminavus kovariantės X įtaką, hipotezė atmetama kriterijumi, kurio reikšmingumo lygmuo $\alpha > 0,0098$.

II.3.59. a) $F_A = 2,72$, $F_B = 5,50$; atitinkamos P reikšmės 0,1139, 0,0108. b) Eliminavę kintamujų X ir Z įtaką, gauname $F_A = 13,96$, $F_B = 5,96$; atitinkamos P reikšmės 0,0025, 0,0137. Hipotezė, kad kovariantė X nereikšminga (statistikos reikšmė

57,58) atmetama kriterijumi su aukšt u reikšmingumo lygmeniu. Hipotezė, kad kovariantė Z nereikšminga (statistikos reikšmė 8,30) atmetama kriterijumi kai reikšmingumo lygmuo $\alpha > 0,0205$.

II.3.60. a) $F_A = 2,46$; P reikšmė 0,1173. b) Tikrinant hipotezę H_A eliminavus kovariantės X įtaką statistikos reikšmė yra 2,88; hipotezė atmetama kriterijumi, kurio reikšmingumo lygmuo $\alpha > 0,0896$.

II.3.61. a) $F_A = 3,08$, $F_B = 2,88$, $F_C = 1,13$; atitinkamos P reikšmės 0,0373, 0,0773, 0,3001. b) $F_A = 2,58$, $F_B = 5,08$, $F_C = 5,63$; atitinkamos P reikšmės 0,0667, 0,0159, 0,0273. Hipotezė, kad kovariantė X nereikšminga, atmetama kriterijumi su reikšmingumo lygmuo $\alpha > 0,0006$.

II.3.5 skyrelis

II.3.62. $\hat{\beta}_0 = 1/12$; $\hat{\beta}_1 = -1/12$, $\hat{\beta}_2 = -29/12$; $\hat{\sigma}^2 = s^2 = 6,75$. Statistikos, kurios esant teisingoms hipotezėms $H_i : \beta_i = 0$ turi Fišerio skirstinius su 1 ir 9 laisvės laipsniais, įgijo reikšmes 0,012; 0,012, 10,383; atmeti parametru β_0 ir β_1 lygybės 0 hipotezes nėra pagrindo; hipotezė $H_2 : \beta_2 = 0$ atmetama, kai kriterijaus reikšmingumo lygmuo viršija 0,01.

II.3.63. a) $\hat{\beta}_0 = -13/8$, $\hat{\beta}_1 = -19/8$, $\hat{\beta}_2 = 51/8$, $\hat{\beta}_3 = -63/8$, $\hat{\sigma} = s = 2,318$. Statistikos, kurios esant teisingoms hipotezėms $H_i : \beta_i = 0$ turi Fišerio skirstinius su 1 ir 4 laisvės laipsniais, įgijo reikšmes 3,930; 8,395; 60,488; 92,302; atitinkamos P reikšmės yra 0,118; 0,044; 0,0015; 0,0007. b) $\hat{\beta}_{12} = 5/8$, $\hat{\beta}_{13} = -1/8$, $\hat{\beta}_{23} = -11/8$, $\hat{\sigma} = s = 1,768$; atmeti hipotezes nėra pagrindo.

II.3.64. $\hat{\beta}_0 = 1727,63$, $\hat{\beta}_1 = 13$, $\hat{\beta}_2 = 40,875$, $\hat{\beta}_3 = 38,75$, $\hat{\sigma} = s = 167,138$. Hipotezės $H_i : \beta_i = 0$, $i = 1, 2, 3$, neatmetamos. $\hat{\beta}_{12} = -22$, $\hat{\beta}_{13} = 31,875$, $\hat{\beta}_{23} = -63,5$, $\hat{\sigma} = s = 165,564$; atmeti hipotezes $H_{ij} : \beta_{ij} = 0$, $i \neq j = 1, 2, 3$, nėra pagrindo.

II.3.65. a) Parametru įverčiai: $\hat{\beta}_0 = 1848,59$, $\hat{\beta}_1 = -20,7188$, $\hat{\beta}_2 = -13,9063$, $\hat{\beta}_3 = 0,8438$, $\hat{\beta}_4 = 50,3438$; $\hat{\beta}_{12} = 26,2813$, $\hat{\beta}_{13} = 26,5313$, $\hat{\beta}_{14} = -67,4688$, $\hat{\beta}_{23} = -19,4063$, $\hat{\beta}_{24} = 16,9688$, $\hat{\beta}_{34} = -2,1563$, $\hat{\sigma} = 169,803$. b) Hipotezė $H_0 : \beta_0 = 0$ atmetama; hipotezė $H_{14} : \beta_{14} = 0$ atmetama, kai kriterijaus reikšmingumo lygmuo viršija 0,0355; kitos hipotezės neatmetamos. c) Prognozės intervalas su pasiklivimo lygmeniu $Q = 1 - \alpha$ yra $\hat{Y} \pm \hat{\sigma} t_{\alpha/2}(21) \sqrt{(33 + \rho^2)/32}$.

II.3.66. $\hat{\beta}_0 = \sum_i Y_i / 9$, $\hat{\beta}_1 = (-Y_1 + Y_3 - Y_4 + Y_6 - Y_7 + Y_9) / 6$, $\hat{\beta}_2 = (Y_1 + Y_2 + Y_3 - Y_7 - Y_8 - Y_9) / 6$; $\hat{\beta}_{11} = \sum_i Y_i / 3 - (Y_2 + Y_5 + Y_7)$; $\hat{\beta}_{11} = \sum_i Y_i / 3 - (Y_4 + Y_5 + Y_6)$; $\hat{\beta}_{12} = \sum_i Y_i / 9 - (Y_2 + Y_4 - Y_5 + Y_6 + Y_8) / 3$; $\hat{\beta}_{211} = (Y_1 - 2Y_2 + Y_3 - Y_7 + 2Y_8 - Y_9) / 3$; $\hat{\beta}_{122} = (-Y_1 + Y_3 + 2Y_4 - 2Y_6 - Y_7 + Y_8) / 3$; $\mathbf{V}\hat{\beta}_0 = \sigma^2 / 9$; $\mathbf{V}\hat{\beta}_1 = \mathbf{V}\hat{\beta}_2 = \sigma^2 / 6$; $\mathbf{V}\hat{\beta}_{11} = \mathbf{V}\hat{\beta}_{22} = \sigma^2 / 2$; $\mathbf{V}\hat{\beta}_{12} = 9\sigma^2 / 4$; $\mathbf{V}\hat{\beta}_{211} = \mathbf{V}\hat{\beta}_{122} = 3\sigma^2 / 4$.

II.3.67. $a = \sqrt{\sqrt{10} - 2}$.

II.3.68. $a = 2\sqrt{\sqrt{2} - 1}$.

II.3.69. Parametru įverčiai: $\hat{\beta}_0 = 2,0444$, $\hat{\beta}_1 = 0,4667$, $\hat{\beta}_2 = -0,1667$, $\hat{\beta}_{11} = 0,4667$, $\hat{\beta}_{22} = 0,8667$, $\hat{\beta}_{12} = 0,1361$, $\hat{\beta}_{211} = 0,650$, $\hat{\beta}_{122} = 0,625$, $\hat{\sigma}^2 = s^2 = 0,8066$. Hipotezė $H_0 : \beta_0 = 0$ atmetama: P reikšmė $p v = 2 \times 10^{-6}$. Hipotezei $H_{22} : \beta_{22} = 0$ P reikšmė

$p_{\text{v}} = 0,082$; atmesti kitas hipotezes nėra pagrindo.

II.3.70. Abiem atvejais pirmoji replika ((1), ab , ac , bc).

II.3.6 skyrelis

II.3.71. a) $\hat{\beta}_0 = 3,2975$, $\hat{\beta}_1 = 0,0023$, $\hat{\beta}_2 = 0,0188$, $\hat{\beta}_3 = -0,0437$;

$$\hat{\mathbf{V}}(\hat{\boldsymbol{\beta}}) = 10^{-3} \begin{pmatrix} 1,198 & 0 & -0,168 & 0,021 \\ 0 & 0,115 & 0 & 0 \\ -0,168 & 0 & 0,040 & 0 \\ 0,021 & 0 & 0 & 0,245 \end{pmatrix}.$$

b) Tikrinant hipotezes $H_j : \beta_j = 0, j = 1, 2, 3$, statistikos (žr. [3], 5.2.1 skyrelį) įgijo reikšmes 0,05; 8,89; 7,81; atitinkamos P reikšmės yra 0,8299; 0,0029; 0,0052.

c) $\hat{\mu}_{13} = e^{\hat{\beta}_0 - 3\hat{\beta}_1 + 9\hat{\beta}_2} = 31,80$; $\hat{\mu}_{43} = e^{\hat{\beta}_0} = 27,04$;

$$(\underline{\mu}_{13}; \bar{\mu}_{13}) = (28,86; 35,04); \quad (\underline{\mu}_{43}; \bar{\mu}_{43}) = (25,27; 28,94).$$

Taškinis įvertinys $\hat{\mu}_{ij} = e^{\hat{\theta}_{ij}}$, $\hat{\theta}_{ij} = \hat{\boldsymbol{\beta}}^T \mathbf{Z}_{ij}$. Tiesinio darinio $\theta_{ij} = \boldsymbol{\beta}^T \mathbf{Z}_{ij}$ aproksimacinė lygmens $Q = 1 - 2\alpha$ pasikliovimo intervalą gauname aproksimuodami statistikos $(\hat{\theta}_{ij} - \theta_{ij})/\sqrt{\hat{\mathbf{V}}(\hat{\theta}_{ij})}$, $\hat{\mathbf{V}}(\hat{\theta}_{ij}) = \mathbf{Z}_{ij}^T \hat{\mathbf{V}}(\hat{\boldsymbol{\beta}}) \mathbf{Z}_{ij}$, skirstinių standartiniu normaliuoju skirstiniu:

$$(\underline{\theta}_{ij}; \bar{\theta}_{ij}) = (\hat{\theta}_{ij} - z_\alpha \sqrt{\hat{\mathbf{V}}(\hat{\theta}_{ij})}; \hat{\theta}_{ij} + z_\alpha \sqrt{\hat{\mathbf{V}}(\hat{\theta}_{ij})}).$$

Tada $\underline{\mu}_{ij} = e^{\underline{\theta}_{ij}}$, $\bar{\mu}_{ij} = e^{\bar{\theta}_{ij}}$.

II.3.72. a) $\hat{\alpha}_0 = 27,043$, $\hat{\alpha}_1 = 0,0714$, $\hat{\alpha}_2 = 0,5571$, $\hat{\alpha}_3 = -1,279$; $\hat{\sigma}^2 = s^2 = SS_E/(n-4) = 37,891$;

$$\hat{\mathbf{V}}(\hat{\boldsymbol{\beta}}) = \begin{pmatrix} 1,2630 & 0 & -0,1804 & 0 \\ 0 & 0,1353 & 0 & 0 \\ -0,1804 & 0 & 0,0451 & 0 \\ 0 & 0 & 0 & 0,2707 \end{pmatrix}.$$

b) Tikrinant hipotezes $H_j : \alpha_j = 0, j = 1, 2, 3$, statistika įgijo reikšmes 0,19; 2,62; -2,46; atitinkamos P reikšmės yra 0,8466; 0,0108; 0,0166.

c) $\hat{\mu}_{13} = \hat{\alpha}_0 - 3\hat{\alpha}_1 + 9\hat{\alpha}_2 = 31,84$; $\hat{\mu}_{43} = \hat{\alpha}_0 = 27,04$;

$$(\underline{\mu}_{13}; \bar{\mu}_{13}) = (28,45; 35,24); \quad (\underline{\mu}_{43}; \bar{\mu}_{43}) = (24,80; 29,29).$$

II.3.73. a) $\hat{\gamma}_0 = 10,31$, $\hat{\gamma}_1 = 0,0141$, $\hat{\gamma}_2 = 0,0998$, $\hat{\gamma}_3 = -0,2409$; $\hat{\sigma}^2 = s^2 = SS_E/(n-4) = 1,295$;

$$\hat{\mathbf{V}}(\hat{\boldsymbol{\beta}}) = \begin{pmatrix} 0,04317 & 0 & -0,00617 & 0 \\ 0 & 0,00463 & 0 & 0 \\ -0,00617 & 0 & 0,00154 & 0 \\ 0 & 0 & 0 & 0,00925 \end{pmatrix}.$$

b) Tikrinant hipotezes $H_j : \gamma_j = 0, j = 1, 2, 3$, statistika įgijo reikšmes 0,21; 2,54; -2,50; atitinkamos P reikšmės yra 0,8362; 0,0134; 0,0147.

c) $\hat{\mu}_{13} = 31, 14; \hat{\mu}_{43} = 26, 57;$

$$(\underline{\mu}_{13}; \bar{\mu}_{13}) = (27, 77; 34, 75); \quad (\underline{\mu}_{43}; \bar{\mu}_{43}) = (24, 45; 28, 73).$$

II.3.74. a) $\hat{\beta}_0 = 1,897, \hat{\beta}_1 = 0,8193, \hat{\beta}_2 = 0,0773, \hat{\beta}_3 = 0,0788; \mathbf{V}(\hat{\beta}_0) = 1/60,$
 $\mathbf{V}(\hat{\beta}_j) = 1/30, j = 1, 2, 3; \mathbf{Cov}(\hat{\beta}_0, \hat{\beta}_j) = -1/60, j = 1, 2, 3; \mathbf{Cov}(\hat{\beta}_j, \hat{\beta}_l) = 1/60,$
 $j \neq l = 1, 2, 3.$

b) Tikrinant hipotezę $H : \beta_1 = \beta_2 = \beta_3 = 0$, tikėtinumų santykio statistika

$$D_R = -120(8 \ln 2 + \ln(T_1 T_2 T_3 T_4 / T^4)),$$

čia $T_j = \sum_i Y_{ij}, j = 1, 2, 3, 4; T = T_1 + T_2 + T_3 + T_4 = 907, 83 + 432, 27 + 432, 92 + 400, 11 = 2173, 13$; įgijo reikšmę $29,77$; P reikšmė yra $1,54 \times 10^{-6}$. Tikrinant hipotezes $H_j : \beta_j = 0$, statistikos $30\hat{\beta}_j^2$ įgijo reikšmes $20,14, 0,179, 0,186$; atitinkamos P reikšmės $7,20 \times 10^{-6}, 0,6720, 0,6660$. Tikrinant hipotezę $H_{23} : \beta_2 = \beta_3$ parametru $\theta = \beta_2 - \beta_3$ įvertinio dispersija $\mathbf{V}(\hat{\theta}) = \mathbf{V}(\hat{\beta}_2 - \hat{\beta}_3) = 1/30$; statistika $30\hat{\theta}^2 = 6,8 \times 10^{-5}$; P reikšmė $0,9934$.

c) $\hat{\mu}_3 = T_3/20 = 21, 65; (\underline{\mu}_3; \bar{\mu}_3) = (17, 07; 28, 37).$

II.3.75. a) $\hat{\beta}_0 = -12,371, \hat{\beta}_1 = 1,459, \hat{\beta}_2 = 0,590$. Tikrinant hipotezes $H_j : \beta_j = 0, j = 1, 2$ statistikų W_j (žr. [3], 5.3.6 skyrelį) kvadratai įgijo reikšmes $1,125, 4,978$; atitinkamos P reikšmės $0,2889, 0,0257$.

b) $\exp(\hat{\beta}_1) = 4,302; \exp(\hat{\beta}_2) = 1,803$.

c) $\pi(X_2 = 20, X_1 = 0) = 0,3593, \pi(X_2 = 20, X_1 = 1) = 0,7070$.

d) $V_{11}(0,5) = 9, V_{01}(0,5) = V_{10}(0,5) = 4, V_{00}(0,5) = 7$.

II.3.76. a) $\hat{\beta}_0 = 6,549, \hat{\beta}_1 = -0,303, \hat{\beta}_2 = -0,327, \hat{\beta}_3 = 1,741, \hat{\beta}_4 = -0,009$.

b) Tikrinant hipotezes $H_j : \beta_j = 0, j = 1, 2, 3, 4$ statistikų W_j (žr. [3], 5.3.6 skyrelį) kvadratai įgijo reikšmes $4,987, 0,082, 1,372, 0,071$; atitinkamos P reikšmės $0,0255, 0,7742, 0,2415, 0,7899$.

II.3.77. $\hat{\beta}_0 = -1,721, \hat{\beta}_1 = 0,00117, \hat{\beta}_2 = -0,0199$. Tikrinant hipotezes $H_j : \beta_j = 0, j = 1, 2$ statistikų W_j (žr. [3], 5.3.6 skyrelį) kvadratai įgijo reikšmes $3,211, 0,921$; atitinkamos P reikšmės $0,0731, 0,3372$.

II.3.78. a) Kai $Z = 0$, gauname $\hat{\beta}_0 = 3,95, \hat{\beta}_1 = -0,112; \exp(\hat{\beta}_1) = 0,894$; tikrinant hipotezę $H_1 : \beta_1 = 0$ statistikos W_1 (žr. [3], 5.3.6 skyrelį) kvadratas įgijo reikšmę $102,6$; hipotezė atmetama. Kai $Z = 1$, gauname $\hat{\beta}_0 = 3,33, \hat{\beta}_1 = -0,091; \exp(\hat{\beta}_1) = 0,913$; tikrinant hipotezę $H_1 : \beta_1 = 0$ statistikos W_1 kvadratas įgijo reikšmę $58,8$; hipotezė atmetama.

b) $\hat{\beta}_0 = 3,63, \hat{\beta}_1 = -0,103$ (atstumas), $\hat{\beta}_2 = 0,1036$ (lyga). Tikrinant hipotezę $H_1 : \beta_1 = 0$ statistikos W_1 (žr. [3], 5.3.6 skyrelį) kvadratas įgijo reikšmę $161,6$; hipotezė atmetama. Tikrinant hipotezę $H_2 : \beta_2 = 0$ statistikos W_2 kvadratas įgijo reikšmę $0,372$; atitinkama P reikšmė $0,5419$; atmeti hipotezę nėra pagrindo.

III. Neparametrinė statistika

III.1. Chi kvadrato kriterijus

III.1.1. Paprastoji hipotezė

III.1.1. Mendelis stebėjo, kokios žirnių sėklos gaunamos kryžminant augalus, kurių sėklos geltonos ir apvalios, su augalais, kurių sėklos žalios ir raukšlėtos. Rezultatai pateikti lentelėje kartu su teorinėmis tikimybėmis, apskaičiuotomis remiantis Mendelio paveldimumo teorija.

Sėklos	Dažnumai	Tikimybės
Geltonos ir apvalios	315	9/16
Geltonos ir raukšlėtos	101	3/16
Žalios ir apvalios	108	3/16
Žalios ir raukšlėtos	32	1/16
Σ	556	1

Ar stebėjimo duomenys neprieštarauja Mendelio paveldimumo teorijai?

III.1.2. Kryžminant du kukurūzų tipus gauti keturi skirtingi augalų tipai. Pagal paprastąjį Mendelio paveldimumo teoriją šie tipai turėtų pasirodyti su tikimybėmis $9/16$, $3/16$, $3/16$ ir $1/16$. Stebint 1301 augalą gauti tokie dažniai 773, 231, 238 ir 59. Su kokiui reikšmingumu lygmeniu χ^2 kriterijus neprieštarauja Mendelio modeliui?

III.1.3. Skaitmenys 0, 1, 2, ..., 9 tarp pirmųjų 800 skaičiaus π ženklu kartojaisi atitinkamai 74, 92, 83, 79, 80, 73, 77, 75, 76, 91 kartą. Ar galima šiuos duomenis interpretuoti kaip a. v. $\mathbf{U} \sim \mathcal{P}_{10}(800, \boldsymbol{\pi})$, $\boldsymbol{\pi} = (1/10, \dots, 1/10)^T$ realizaciją?

III.1.4. Tirkirama hipotezė apie atsitiktinių skaičių lentelės korektiškumą, t. y. hipotezė, kad lentelėje skaitmenys 0, 1, 2, ..., 9 pasitaiko su vienodomis tikimybėmis $p = 0,1$. Hipotezė tikrinama χ^2 kriterijumi. Koks turi būti imties didumas, kad ta hipotezė būtų atmesta su tikimybe, ne mažesne už 0,95, jei žinoma, kad 5 skaitmenys lentelėje pasirodo su tikimybėmis 0,11, o kiti 5 – su tikimybėmis 0,09 (kriterijaus reikšmingumo lygmuo yra 0,05)?

III.1.5. Nuskaitydami prietaiso skalės parodymus, kai paskutinis skaitmuo įvertinamas iš akies, stebėtojai kartais nesąmoningai suteikia pirmenybę kai kuriems skaičiams. Lentelėje pateikti paskutiniųjų skaitmenų dažniai tam tikram stebėtojui atlikus 200 stebėjimų.

Skaitmuo	0	1	2	3	4	5	6	7	8	9
Dažnis	35	16	15	17	17	19	11	16	30	24

Iš lentelės matome, kad skaitmenys 0 ir 8 pasirodo šiek tiek dažniau, palyginti su kitais. Ar galima daryti išvadą, kad stebėtojas suteikia pirmenybę kai kuriems skaičiams?

III.1.6. Įrodykite, kad tikrinant hipotezę apie polinominio skirstinio $(U_1, \dots, U_k)^T \sim \mathcal{P}_k(n, \boldsymbol{\pi})$ tikimybių vektoriaus $\boldsymbol{\pi} = (\pi_1, \dots, \pi_k)^T$ reikšmę: $H_0 : \boldsymbol{\pi} = \boldsymbol{\pi}_0$; čia $\boldsymbol{\pi}_0 = (\pi_{10}, \dots, \pi_{k0})^T$, $0 < \pi_{j0} < 1$, $\pi_{10} + \dots + \pi_{k0} = 1$ žinomas vektorius, statistika

$$\tilde{X}_n^2 = n \sum_{i=1}^k (1 - \pi_{i0}) [H(U_i/n) - H(\pi_{i0})]^2$$

asimptotiškai ($n \rightarrow \infty$) pasiskirsčiusi pagal χ kvadrato skirstinį su $k - 1$ laisvės laipsnių; čia $H(x) = \arcsin(2x - 1)$.

III.1.7. Raskite Pirsono statistikos

$$X_n^2 = \sum_{i=1}^k \frac{(U_i - n\pi_{i0})^2}{n\pi_{i0}} = \sum_{i=1}^k \frac{U_i^2}{n\pi_{i0} - n}$$

pirmuosius du momentus, kai tikrinamoji hipotezė: a) teisinga; b) neteisinga.

III.1.8. (III.1.7 pratimo tēsinys). Įrodykite, kad jei tikimybės $\pi_{i0} = 1/k$, tai X_n^2 dispersija yra $\mathbf{V}(X_n^2) = 2k^2\{2(n-2)\sum_i \pi_i^3 - (2n-3)(\sum_i \pi_i^2)^2 + \sum_i \pi_i^2\}$, o jeigu ir $\pi_i = \pi_{i0} = 1/k$, tai $\mathbf{V}(X_n^2) = 2(k-1)$.

III.1.9. Kompiuteriu sugeneruota $n = 80$ atsitiktinių skaičių. Gautieji rezultatai:

0,0100 0,0150 0,0155 0,0310 0,0419 0,0456 0,0880 0,1200 0,1229 0,1279 0,1444 0,1456
 0,1621 0,1672 0,1809 0,1855 0,1882 0,1917 0,2277 0,2442 0,2456 0,2476 0,2538 0,2552
 0,2681 0,3041 0,3128 0,3810 0,3832 0,3969 0,4050 0,4182 0,4259 0,4365 0,4378 0,4434
 0,4482 0,4515 0,4628 0,4637 0,4668 0,4773 0,4799 0,5100 0,5309 0,5391 0,6033 0,6283
 0,6468 0,6519 0,6686 0,6689 0,6865 0,6961 0,7058 0,7305 0,7337 0,7339 0,7440 0,7485
 0,7516 0,7607 0,7679 0,7765 0,7846 0,8153 0,8445 0,8654 0,8700 0,8732 0,8847 0,8935
 0,8987 0,9070 0,9284 0,9308 0,9464 0,9658 0,9728 0,9872

Ar šie duomenys nepriestarauja prielaidai, kad tai yra paprastosios imties, gautos stebint a. d. $X \sim U(0, 1)$, realizacija?

III.1.2. Sudėtinės hipotezės

III.1.10. Per 8000 bandymų nesutaikomi, sudarantys pilną įvykių grupę įvykiai A , B ir C pasirodė 2014, 5012 ir 974 kartus. Tarkime, šių įvykių pasirodymo tikimybės yra $\pi_1, \pi_2, \pi_3, \pi_1 + \pi_2 + \pi_3 = 1$. χ^2 kriterijumi patikrinkite hipotezę, kad įvykių pasirodymo tikimybės yra $\pi_1 = 0,5 - 2\alpha$, $\pi_2 = 0,5 + \alpha$, $\pi_3 = \alpha$, $0 < \alpha < 0,25$.

III.1.11. Tarp 2020 šeimų buvo užregistruota 527 šeimos, kuriose abu vaikai berniukai, 476 šeimos, kuriose abu vaikai mergaitės, ir 1017 šeimų, kuriose vaikai skirtingu lyčiu. Ar galima tvirtinti, kad berniukų skaičius šeimose su dvem vaikais yra a) binominis a. d.; b) binominis a. d., kai berniuko ir mergaitės gimimo tikimybės vienodos.

III.1.12. Diskretaus a. d. penkios nepriklausomos realizacijos yra 47, 46, 49, 53 ir 50. Ar galima tvirtinti, kad buvo stebimas Puasono a. d.?

III.1.13. Rezerfordo ir Geigerio bandymuose buvo registruojamas radioaktyvios medžiagos per 2608 ilgio 7,5 sek. periodus išspinduliuotų α dalelių skaičius. Rezultatai pateikti lentelėje (i – išspinduliuotų dalelių skaičius, V_i – periodą, per kuriuos buvo stebima i dalelių, skaičius).

i	0	1	2	3	4	5	6	7	8	9	10	11	12
V_i	57	203	383	525	532	408	273	139	45	27	10	4	2

Ar nepriestarauja gauti duomenys prielaidai, kad per vieną periodą išspinduliuotų dalelių skaičius turi Puasono skirstinį?

III.1.14. Kontroliniu prietaisu buvo išmatuotas atstumas r (mikronais) nuo detalės svorio centro iki jos išorinio cilindro ašies. Matavimo rezultatai pateikti lentelėje (r_i – reikšmės, n_i – dažnai).

r_i	n_i	r_i	n_i
0 – 16	40	80 – 96	45
16 – 32	129	96 – 112	19
32 – 48	140	112 – 128	8
48 – 64	126	128 – 144	3
64 – 80	91	144 – 160	1

Remdamiesi χ^2 kriterijumi, patikrinkite, ar stebėjimo rezultatai nepriestarauja prielaidai, kad stebimi atstumai pasiskirstę pagal Relėjaus dėsnį.

III.1.15. Nustatant 200 elektros lempučių degimo laiką T , gauti rezultatai pateikti lentelėje ($(a_{i-1}, a_i]$ – degimo laiko intervalai, n_i – dažniai).

$a_{i-1} – a_i$	n_i	$a_{i-1} – a_i$	n_i
0 – 300	53	1800 – 2100	9
300 – 600	41	2100 – 2400	7
600 – 900	30	2400 – 2700	5
900 – 1200	22	2700 – 3000	3
1200 – 1500	16	3000 – 3300	2
1500 – 1800	12	3300 – 3600	0

Remdamiesi χ^2 kriterijumi, patikrinkite, ar stebėjimo rezultatai nepriestarauja prielaidai, kad lemputės degimo laikas pasiskirstęs pagal eksponentinį dėsnį.

III.1.16. Lentelėje pateikti prapuolimo kampai 209 pašto balandžių, kai atliekant bandymą buvo bandoma paveikti jų „vidinį laikrodį“ (žr. [14]).

Kryptis	Dažnis	Kryptis	Dažnis
$0^\circ –$	26	$180^\circ –$	14
$30^\circ –$	22	$210^\circ –$	11
$60^\circ –$	26	$240^\circ –$	12
$90^\circ –$	30	$270^\circ –$	5
$120^\circ –$	29	$300^\circ –$	5
$150^\circ –$	18	$330^\circ –$	11

Duomenys sugrupuoti į 30° ilgio intervalus. Lentelėje nurodyti kampai φ_i , atitinkantys i -ojo intervalo pradžią, ir patekusių į i -ajį intervalą dažniai n_i , $i = 1, \dots, 12$. Patikrinkite hipotezę, kad turimi duomenys nepriistarauja prielaidai, jog prapuolimo kampus

turi Mizeso skirstinį $M(\mu, \theta)$.

III.1.17. Lentelėje pateikta smėlio grūdelių orientacija plokštumoje (žr. [14]).

Kampas	Kiekis	Kampas	Kiekis	Kampas	Kiekis
0°–	244	60°–	326	120°–	322
10°–	262	70°–	340	130°–	295
20°–	246	80°–	371	140°–	230
30°–	290	90°–	401	150°–	256
40°–	284	100°–	382	160°–	263
50°–	314	110°–	332	170°–	281

Kampai sugrupuoti į 10° ilgio intervalus (nurodoma grupavimo intervalo pradžia). Gretimuose stulpeliuose nurodomi smėlio grūdelių, kurių orientacija patenka į atitinkamus intervalus, skaičiai.

Padvigubinę kampus perveskite duomenis į intervalą $[0^\circ - 360^\circ]$. Patikrinkite hipotezę, kad stebėtas atsitiktinis kampus turi Mizeso skirstinį $M(\mu, \theta)$.

III.1.18. Didumo $n = 100$ imties realizacija pateikta lentelėje.

338	336	312	322	381	302	296	360	342	334
348	304	323	310	368	341	298	312	322	350
304	302	336	334	304	292	324	331	324	334
314	338	324	292	298	342	338	331	325	324
326	314	312	362	368	321	352	304	302	332
314	304	312	381	290	322	326	316	328	340
324	320	364	304	340	290	318	332	354	324
304	321	356	366	328	332	304	282	330	314
342	322	362	298	316	298	332	342	316	326
308	321	302	304	322	296	322	338	324	323

Modifikuotuoju χ^2 kriterijumi (grupavimo intervalų skaičius $k = 8$) patikrinkite hipotezę, kad buvo stebimas normalusis atsitiktinis dydis.

III.1.19. Lentelėje pateikti duomenys, apibūdinantys tam tikro elemento koncentraciją nesureagavusiame likutyje pasibaigus cheminiam procesui.

10	51	8	47	8	5	56	12	4	5	4	4	7	6	9
30	25	12	3	22	5	15	4	4	29	15	4	2	18	41
3	5	54	110	24	16	2	37	20	2	6	7	16	2	14
68	10	16	11	78	6	17	7	11	21	15	24	6	32	8
11	4	14	45	17	10	15	20	4	65	10	3	5	11	13
35	11	34	3	4	12	7	6	62	13	36	26	6	11	6
13	1	4	36	18	10	37	28	4	12	31	14	3	11	6
4	10	38	6	11	24	9	4	5	8	135	22	6	18	49
17	9	32	27	2	12	8	93	3	9	10	3	14	33	72
14	4	9	10	19	2	5	21	8	25	30	20	12	19	16

Modifikuotuoju χ^2 kriterijumi (grupavimo intervalų skaičius $k = 10$) patikrinkite hipotezę, kad buvo stebimas lognormalusis atsitiktinis dydis.

III.1.20. Modifikuotuoju chi kvadrato kriterijumi patikrinkite hipotezę, kad pateikti $n = 100$ skaičių yra normaliojo a. d. realizacija.

24 41 30 37 25 32 28 35 28 51 36 26 43 25 27 39 21 45 39 25 29 43 66 25 24 56 29 31
 41 41 36 57 36 48 25 36 48 24 48 22 40 7 31 24 32 53 33 46 22 33 25 37 34 32 41 36 19
 32 25 19 19 37 20 21 48 44 35 19 44 34 29 48 38 43 48 35 42 37 35 36 58 45 34 40 37 21
 41 11 41 27 50 24 37 39 33 45 39 43 21 34

Pakoreguokite kriterijų atsižvelgdami į tai, kad duomenys suapvalinti.

III.1.21. Patikrinkite hipotezę, kad tam tikro dalyko pažymiai (penkiabalaėje sistemoje) atestate ir per stojamuosius egzaminus yra nepriklausomi. Duomenys pateikti lentelėje (x_i – pažymys atestate, y_j – pažymys per stojamuosius egzaminus).

$x_i y_j$	5	4	3	2	Σ
4 – 5	110	70	60	10	250
3	0	10	10	30	50
Σ	110	80	70	40	300

III.1.22. Paleidus raketą 87 kartus, buvo gauti tokie duomenys apie atstumą X (m) ir nukrypimą Y (kampo minutės).

$x_i \setminus y_j$	(–250, –50)	(–50, 50)	(50, 250)	Σ
0 – 1200	5	9	7	21
1200 – 1800	7	5	5	21
1800 – 2700	8	21	16	45
Σ	20	35	32	87

Ar šie požymiai nepriklausomi?

III.1.23. Viename sraute iš 300 stojančiųjų pažymius „nepatenkinamai“, „patenkinamai“, „gerai“ ir „labai gerai“ gavo atitinkamai 33, 43, 80 ir 144; kito srauto stojantieji atitinkamai 39, 35, 72 ir 154. Ar galima laikyti, kad abiejų srautų stojantieji pasirengę vienodai?

III.1.24. Tiriant granulometrinę kvarco sudėtį Anykščių ir Afrikos smėlio pavyzdžiuose, buvo gauta duomenų apie jo grūdelių didžiosios ašies ilgi. Remiantis pavyzdžių granulometrine sudėtimi daromos tam tikros išvados apie geologines smėlio susidarymo sąlygas. Pateikiami duomenys sugrupuoti vienodo ilgio intervalais (X_i – i -ojo intervalo vidurys).

X_i	9	13	17	21	25	29	33	37	41	45	49	Σ
Anykščių smėlis	4	12	35	61	52	23	7	4	2	1	0	201
Afrikos smėlis	0	6	10	12	13	12	15	12	11	7	4	102

Remdamiesi χ^2 kriterijumi patikrinkite hipotezę, kad grūdelių didžiosios ašies ilgio skirstinys vienodas Anykščių ir Afrikos smėlio pavyzdžiuose.

III.1.25. Dviejose nepriklausomose didumo 500 imtyse buvo užregistruota laikrodžių, išstatytų jvairių taisyklių vitrinose, rodmenys.

Duomenys sugrupuoti į 12 intervalų (0 reiškia intervalą nuo 0 h iki 1 h; 1 – intervalą nuo 1 h iki 2 h ir t. t.) ir surašyti į lentelę.

Imtis	1	2	3	4	5	6	7	8	9	10	11	12	Σ
1	41	34	54	39	49	45	41	33	37	41	47	39	500
2	36	47	41	47	49	45	32	37	40	41	37	48	500

Remdamiesi χ^2 kriterijumi patikrinkite hipotezę, kad abiejose imtyse laikrodžių rodmenų patekimo į visus intervalus tikimybės yra vienodos.

III.1.26. Ląsteles veikiant rentgeno spinduliais, jose keičiasi kai kurios chromosomas. Lentelėje pateikti kelių nepriklausomų bandymų serijų duomenys (i – chromosomų pasikeitimų skaičius, n_{ik} – ląstelių su i pasikeitimų k -ajame eksperimente skaičius).

i	0	1	2	≥ 3	$\sum n_{ik}$
n_{i1}	280	75	12	1	368
n_{i2}	593	143	20	3	759
n_{i3}	639	141	13	0	793
n_{i4}	359	109	13	1	482

Patikrinkite hipotezę, kad visos 4 imtys gautos stebint atsitiktinius dydžius, kurių skirstiniai yra a) Puasono; b) tie patys Puasono.

III.1.3. Sprendimai, atsakymai, nurodymai

III.1.1 skyrelis

III.1.1. Reikia patikrinti hipotezę apie polinominio skirstinio

$$(U_1, \dots, U_k)^T \sim \mathcal{P}_k(n, \boldsymbol{\pi})$$

tikimybių vektoriaus $\boldsymbol{\pi} = (\pi_1, \dots, \pi_k)^T$ reikšmę: $H_0 : \boldsymbol{\pi} = \boldsymbol{\pi}_0$; čia $\boldsymbol{\pi}_0 = (\pi_{10}, \dots, \pi_{k0})^T$, $0 < \pi_{j0} < 1$, $\pi_{10} + \dots + \pi_{k0} = 1$ žinomas vektorius.

Tikėtinumų santykio statistika

$$\Lambda_n = \frac{\max_{\boldsymbol{\pi}=\boldsymbol{\pi}_0} L(\boldsymbol{\pi})}{\max_{\boldsymbol{\pi}} L(\boldsymbol{\pi})} = \frac{L(\boldsymbol{\pi}_0)}{L(\hat{\boldsymbol{\pi}})} = \prod_{i=1}^k (n\pi_{i0}/U_i)^{U_i}.$$

Kai hipotezė H_0 teisinga ir $n \rightarrow \infty$, tai (žr. [4], 7.1.2 pastaba)

$$R_n = -2 \ln(\Lambda_n) = 2 \sum_{i=1}^k U_i \ln(U_i/(n\pi_{i0})) \xrightarrow{d} V \sim \chi^2(k-1).$$

Pirsono statistika X_n^2 irgi turi tą patį asymptotinį skirstinį (žr. [4], 2.1.1 teorema)

$$X_n^2 = \sum_{i=1}^k \frac{(U_i - n\pi_{i0})^2}{n\pi_{i0}} = \sum_{i=1}^k \frac{U_i^2}{n\pi_{i0}} - n \xrightarrow{d} \chi_{k-1}^2.$$

Remdamiesi šiais sąryšiais gauname tokius asymptotinius kriterijus. Hipotezė H_0 atmetama asymptotiniu reikšmingumo lygmens α tikėtinumo santykio kriterijumi, kai

$$R_n > \chi_{\alpha}^2(k-1).$$

Hipotezė H_0 atmetama asymptotiniu reikšmingumo lygmens α Pirsono χ kvadrato kriterijumi, kai

$$X_n^2 > \chi_{\alpha}^2(k-1).$$

Asimptotinių P reikšmių terminais hipotezė atmetama, kai atitinkamai

$$pv_a = \mathbf{P}\{\chi_{k-1}^2 > r_n\}, \quad \text{arba} \quad pv_a = \mathbf{P}\{\chi_{k-1}^2 > x_n^2\},$$

čia r_n ir x_n^2 yra statistikų R_n ir X_n^2 realizacijos. Pagal turimus duomenis statistikos R_n ir X_n^2 įgijo reikšmes 0,475 ir 0,47; atitinkamos asimptotinės P reikšmės yra 0,9243 ir 0,9254; duomenys neprieštarauja iškeltajai hipotezei.

III.1.2. Statistika X_n^2 įgijo reikšmę 9,2714 ir $pv_a = \mathbf{P}\{\chi_3^2 > 9,2714\} = 0,0259$; hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0259.

III.1.3. Statistika X_n^2 įgijo reikšmę 5,125 ir $pv_a = \mathbf{P}\{\chi_9^2 > 5,125\} = 0,8233$; duomenys neprieštarauja suformuluotai prielaidai.

III.1.4. Jeigu hipotezė H_0 neteisinga, tai Pirsono statistikos X_n^2 iš **III.1.1** pratimo skirstinys aproksimuojamas necentriniu χ^2 skirstiniu su $k - 1$ laisvės laipsnių ir necentriškumo parametru

$$\delta_n = n \sum_{i=1}^k \frac{(\pi_i - \pi_{i0})^2}{\pi_{i0}}$$

(žr. [4], 2.1.5 pastabą).

Pagal pratimo sąlygą $\delta_n = 0,01 n$. Aptyksliam imties didumui rasti gauname nelygybę

$$\mathbf{P}\{\chi_{9;\delta_n}^2 > \chi_{0,05}^2(9)\} \geq 0,95 \Leftrightarrow n \geq 881.$$

III.1.5. a) Tikrinant hipotezę $H : \pi_i = 1/10, i = 1, \dots, 10$ statistika X_n^2 įgijo reikšmę 24,9 ir $pv_a = \mathbf{P}\{\chi_9^2 > 24,9\} = 0,0031$; hipotezė atmetina. b) Atlikdami tolesnę analizę patikrinkime hipotezę, kad skaitmenų 0 arba 8 pasirodymo tikimybė 0,2. Esant teisingai hipotezei $S = U_1 + U_8 \sim B(n, 0, 2)$ ir įgijo reikšmę 65. Taigi $pv = \mathbf{P}\{S \geq 65\} = 0,00002$. Išvada: stebėtojas suteikia pirmenybę skaitmenims 0 ir 8.

III.1.6. Remdamiesi delta metodu įrodykite, kad a. v.

$$\sqrt{n}(\sqrt{1-\pi_{10}}(H(U_1/n) - H(\pi_{10})), \dots, \sqrt{1-\pi_{k0}}(H(U_k/n) - H(\pi_{k0})))^T$$

yra asimptotiškai normalusis $N_k(\mathbf{0}, \boldsymbol{\Sigma})$ su ta pačia kovariacine matrica $\boldsymbol{\Sigma}$, kaip ir [4], 2.1.1 teoremoje.

III.1.7. a) Gauname

$$\mathbf{E}(X_n^2) = \sum_{i=1}^k \frac{\mathbf{E}(U_i^2)}{n\pi_{i0}} - n = \sum_{i=1}^k \frac{n\pi_{i0} + n(n-1)\pi_{i0}^2}{n\pi_{i0}} - n = k - 1;$$

$$\mathbf{V}(X_n^2) = \mathbf{E}(X_n^4) - (\mathbf{E}(X_n^2))^2 = \mathbf{E}\left(\sum_{i=1}^k \frac{U_i^2}{n\pi_{i0}}\right)^2 - (k-1)^2.$$

Randame

$$\mathbf{E}\left(\sum_{i=1}^k \frac{U_i^2}{n\pi_{i0}}\right)^2 = \sum_{i=1}^k \frac{\mathbf{E}U_i^4}{n^2\pi_{i0}^2} + \sum_{i \neq j} \frac{\mathbf{E}(U_i^2 U_j^2)}{n^2\pi_{i0}\pi_{j0}}.$$

Pasinaudoję sąryšiais tarp pradinių $\alpha_k = \mathbf{E}U_i^k$ ir faktorialinių $\nu_k = \mathbf{E}(U_i(U_i - 1) \cdot \dots \cdot (U_i - k + 1))$ momentų

$$\alpha_4 = \nu_4 + 5\nu_3 + 7\nu_2 + \nu_1,$$

$$\alpha_{22} = \nu_{22} + \nu_{21} + \nu_{12} + \nu_{11},$$

randame

$$\begin{aligned} \mathbf{E} \left(\sum_{i=1}^k \frac{U_i^2}{n\pi_{i0}} \right)^2 &= \frac{1}{n^2} \sum_{i=1}^k (n^{[4]}\pi_{i0}^2 + 6n^{[3]}\pi_{i0} + 7n^{[2]}) + \\ &\quad \frac{1}{n^2} \sum_{i \neq j} (n^{[4]}\pi_{i0}\pi_{j0} + 6n^{[3]}(\pi_{i0} + \pi_{j0}) + 7n^{[2]}) + \sum_{i=1}^k \frac{1}{\pi_{i0}}, \end{aligned}$$

čia $n^{[k]} = n(n-1) \cdot \dots \cdot (n-k+1)$.

Susumavę ir sutraukę panašiuosius narius, gausime

$$\mathbf{V}(X_n^2) = 2(k-1) + \frac{1}{n} \sum_{i=1}^k \frac{1}{\pi_{i0}} - \frac{k^2}{n}.$$

b)

$$\begin{aligned} \mathbf{E}(X_n^2) &= \sum_{i=1}^k \frac{\pi_i(1-\pi_i)}{\pi_{i0}} + n \sum_{i=1}^k \frac{\pi_i^2}{\pi_{i0}} - n = \\ &= k - 1 + \frac{n-1}{n} \delta_n + \sum_{i=1}^k (\pi_i/\pi_{i0}) - k, \end{aligned}$$

necentriškumo parametras δ_n apibrėžtas III.1.4 pratime.

Analogiškai p. a) gauname dispersijos $\mathbf{V}(X_n^2)$ išraišką, kai hipotezė nėra teisinga

$$\begin{aligned} \mathbf{V}(X_n^2) &= 2\{(2n-4) \sum_i (pi_i^3/\pi_{i0}^2) - (2n-3)(\sum_i (\pi_i^2/\pi_{i0}))^2 - \\ &\quad 2 \sum_i (\pi_i^2/\pi_{i0}) \sum_i (\pi_i/\pi_{i0}) + 3 \sum_i (\pi_i^2/\pi_{i0}^2)\} + [\sum_i (\pi_i/\pi_{i0}) - (\sum_i (\pi_i/\pi_{i0}))^2]/n. \end{aligned}$$

III.1.8. Pasiremkime III.1.7 pratimu.

III.1.9. Turime paprastąją didumo n imtį $\mathbf{X} = (X_1, \dots, X_n)^T$ ir tikriname suderinamumo hipotezę $H_0 : X_i \sim F_0(x)$; čia $F_0(x)$ yra žinoma pasiskirstymo funkcija. Taikant χ^2 kriterijų abscisių ašis sudalinama į intervalus $-\infty = a_0 < a_1 < \dots < a_k = \infty$. Pažymėję U_i imties elementų, patekusių į i -ajį intervalą, skaičių, nuo pradinės imties \mathbf{X} pereiname prie mažiau informatyvios grupuotosios imties $\mathbf{U} = (U_1, \dots, U_k)^T \sim \mathcal{P}_k(n, \boldsymbol{\pi})$.

Jeigu hipotezė H_0 teisinga, tai $\boldsymbol{\pi} = \boldsymbol{\pi}_0 = (\pi_{10}, \dots, \pi_{k0})^T$, $\pi_{j0} = F_0(a_j) - F_0(a_{j-1})$, $j = 1, \dots, k$. Vietoje hipotezės $H_0 : X_i \sim F_0(x)$ tikriname bendresnę hipotezę $H'_0 : \pi_j = \pi_{j0}$, $j = 1, \dots, k$ (žr. III.1.1 pratimą). Atmetus H'_0 natūralu atesti ir H_0 .

Pagal turimus duomenis sudalinkime intervalą $(0, 1)$ į 5 vienodo ilgio intervalus: $[0; 0, 2]$, $(0, 2; 0, 4]$, $(0, 4; 0, 6]$, $(0, 6; 0, 8]$, $(0, 8; 1]$. Gauname vektoriaus \mathbf{U} realizaciją:

18; 12; 16; 19; 15.

Tikriname hipotezę $H'_0 : \pi_i = 0, 2, i = 1, \dots, 5$. Gauname

$$X_n^2 = \frac{1}{n} \sum_{i=1}^k \frac{U_i^2}{\pi_{i0}} - n = \frac{18^2 + 12^2 + 16^2 + 19^2 + 15^2}{80 \cdot 0,2} - 80 = 1,875.$$

Asimptotinė P reikšmė $pv_a = \mathbf{P}\{\chi_4^2 > 1,875\} = 0,7587$. Atmesti hipotezę H'_0 nėra pagrindo. Tikėtinumų santykio kriterijus duoda tą patį atsakymą, nes statistikos R_n realizacija yra 1,93 ir $pv_a = \mathbf{P}\{\chi_4^2 > 1,93\} = 0,7486$.

III.1.2 skyrelis

III.1.10. Kai hipotezėje H_0 tvirtinama, kad polinomino skirstinio tikimybės π_i yra dimensijos $s < k - 1$ parametru $\boldsymbol{\theta}$ funkcijos $\pi_i = \pi_i(\boldsymbol{\theta}), i = 1, \dots, k$, tai Pirsono statistika

$$X_n^2(\boldsymbol{\theta}) = \sum_{i=1}^k \frac{(U_i - n\pi_i(\boldsymbol{\theta}))^2}{n\pi_i(\boldsymbol{\theta})}$$

priklauso nuo nežinomo parametru $\boldsymbol{\theta}$. Natūralu nežinomą parametrą pakeisti kokiui nors įvertiniu ir išnagrinėti gautosios statistikos savybes.

1. Kai H_0 teisinga, imties \mathbf{U} tikėtinumo funkcija ir jos logaritmas yra

$$L(\boldsymbol{\theta}) = \frac{n!}{U_1! \dots U_k!} \prod_{i=1}^k \pi_i^{U_i}(\boldsymbol{\theta}), \quad \ell(\boldsymbol{\theta}) = \sum_{i=1}^k U_i \ln(\pi_i(\boldsymbol{\theta})) + C.$$

Pažymėkime $\boldsymbol{\theta}_n^*$ DT įvertinį, gautą maksimizuojant $L(\boldsymbol{\theta})$ arba $\ell(\boldsymbol{\theta})$, ir tegu

$$X_n^2(\boldsymbol{\theta}^*) = \sum_{i=1}^k \frac{(U_i - n\pi_i(\boldsymbol{\theta}^*))^2}{n\pi_i(\boldsymbol{\theta}^*)}.$$

2. Parametru $\boldsymbol{\theta}$ įvertinį $\tilde{\boldsymbol{\theta}}$ raskime χ^2 minimumo metodu, t. y. iš sąlygos

$$X_n^2(\tilde{\boldsymbol{\theta}}) = \inf_{\boldsymbol{\theta}} \sum_{i=1}^k \frac{(U_i - n\pi_i(\boldsymbol{\theta}))^2}{n\pi_i(\boldsymbol{\theta})}.$$

3. Kartais parametru $\boldsymbol{\theta}$ įvertinį $\bar{\boldsymbol{\theta}}$ randame modifikuotuoju chi^2 minimumo metodu, t. y. iš sąlygos

$$X_n^2(\bar{\boldsymbol{\theta}}) = \inf_{\boldsymbol{\theta}} \sum_{i=1}^k \frac{(U_i - n\pi_i(\boldsymbol{\theta}))^2}{U_i}.$$

4. Pagaliau, tegu $R_n(\boldsymbol{\theta}^*)$ žymi tikėtinumų santykio statistiką

$$R_n(\boldsymbol{\theta}^*) = -2 \ln \Lambda_n = 2 \sum_{i=1}^k U_i \ln(U_i / (n\pi_i(\boldsymbol{\theta}^*))).$$

Jeigu hipotezė H_0 teisinga, $n \rightarrow \infty$, o funkcijos $\pi_i(\boldsymbol{\theta})$ tenkina gana bendras reguliarumo sąlygas (žr. [4], 2.2.1 teorema), tai visos keturios statistikos $X_n^2(\boldsymbol{\theta}^*)$, $X_n^2(\tilde{\boldsymbol{\theta}})$,

$X_n^2(\bar{\theta})$, $R_n(\theta^*)$ yra asimptotiškai ekvivalenčios ir turi χ^2 skirstinius su $k - 1 - s$ laisvės laipsnių.

Pagal pratimo sąlygą gauname, kad parametru α DT įvertinio realizacija $\alpha^* = 0,1235$. Tada statistikų $X_n^2(\theta^*)$, $R_n(\alpha^*)$ yra $0,3633$, $0,3641$. Įvertinių $\tilde{\alpha}$ ir $\bar{\alpha}$ realizacijos irgi yra $0,1235$ (keturių ženklių po kablelio tikslumu); $X_n^2(\tilde{\alpha}) = 0,3633$, $X_n^2(\bar{\alpha}) = 0,3658$. Visų keturių statistikų atveju asimptotinė P reikšmė ne mažesnė už $0,5453$; atmetti hipotezę nėra pagrindo.

III.1.11. a) Tegu $X_i = 1$, jei i -asis vaikas yra berniukas, ir $X_i = 0$, jei i -asis vaikas yra mergaitė, $i = 1, 2$. Tarkime, kad $\mathbf{P}\{X_1 = 1\} = \mathbf{P}\{X_2 = 1\} = p$ ir a.d. X_1 ir X_2 nepriklausomi. Tada $\mathbf{P}\{X_1 = 1, X_2 = 1\} = p^2$, $\mathbf{P}\{X_1 = 0, X_2 = 0\} = (1-p)^2$, $\mathbf{P}\{X_1 = 1, X_2 = 0\} + \mathbf{P}\{X_1 = 0, X_2 = 1\} = 2p(1-p)$. Tikrinama hipotezė $H : \pi_1 = p^2, \pi_2 = (1-p)^2, \pi_3 = 2p(1-p)$. Šiuo atveju $k = 3, s = 1$. Tikimybės p DT įvertinio realizacija $\hat{p} = 0,5126$. Statistika $X_n^2(\hat{p})$ igijo reikšmę $0,1159$ ir $pv_a = \mathbf{P}\{\chi_1^2 > 0,1159\} = 0,7335$; duomenys neprieštarauja iškeltai hipotezei. b) Jeigu tartume, kad berniuko ir mergaitės gimimo tikimybė vienoda ir lygi $1/2$, tai jokių parametrų vertinti nereikia. Statistika X_n^2 igijo reikšmę $2,6723$ ir $pv_a = \mathbf{P}\{\chi_2^2 > 2,6723\} = 0,2629$; duomenys neprieštarauja ir šiai hipotezei.

III.1.12. Statistika X_n^2 , turinti asimptotinį chi kvadrato skirstinį su 4 laisvės laipsniais, igijo reikšmę $0,6122$ ir $pv_a = \mathbf{P}\{\chi_4^2 > 0,6122\} = 0,9617$; duomenys neprieštarauja iškeltai hipotezei. *Nurodymas.* Įrodykite ir pasiremkite tokiu faktu: esant teisingai hipotezei imties $(X_1, \dots, X_n)^T$ sąlyginis skirstinys, kai suma $S = X_1 + \dots + X_n$ fiksuota, yra polinominis $\mathcal{P}_n(S, \boldsymbol{\pi}_0)$, $\boldsymbol{\pi}_0 = (1/n, \dots, 1/n)^T$.

III.1.13. Parametru λ DT įvertinio realizacija yra $\hat{\lambda} = 3,8666$. Statistika $X_n^2(\hat{\lambda})$ igijo reikšmę $13,0146$ ir $pv_a = \mathbf{P}\{\chi_{10}^2 > 13,0146\} = 0,2229$; duomenys neprieštarauja iškeltai hipotezei. Skaičiuojant statistikos reikšmę du paskutiniai intervalai buvo sujungti.

III.1.14. Parametru σ^2 DT įvertis yra $\hat{\sigma}^2 = 1581,65$. Statistika $X_n^2(\hat{\sigma}^2)$ igijo reikšmę $2,6931$ ir $pv_a = \mathbf{P}\{\chi_7^2 > 2,6931\} = 0,9119$; duomenys neprieštarauja iškeltai hipotezei. Skaičiuojant statistikos reikšmę du paskutiniai intervalai buvo sujungti.

III.1.15. Parametru θ DT įvertis yra $\hat{\theta} = 878,4$. Statistika $X_n^2(\hat{\theta})$ igijo reikšmę $4,0477$ ir $pv_a = \mathbf{P}\{\chi_8^2 > 4,0477\} = 0,8528$; duomenys neprieštarauja iškeltai hipotezei. Skaičiuojant statistikos reikšmę trys paskutiniai intervalai buvo sujungti.

III.1.16. Parametru įverčiai $\hat{\mu} = 96,16^\circ$, $\hat{\theta} = 0,6854$; statistikos $R_n(\hat{\mu}, \hat{\theta})$ ir $X_n^2(\hat{\mu}, \hat{\theta})$ igijo reikšmes $9,960$ ir $10,175$; atitinkamos asimptotinės P reikšmės $pv_a = 0,354$ ir $pv_a = 0,337$. Hipotezė neatmetama.

III.1.17. Parametru įverčiai $\hat{\mu} = 180,8^\circ$, $\hat{\theta} = 0,2047$; statistikos $R_n(\hat{\mu}, \hat{\theta})$ ir $X_n^2(\hat{\mu}, \hat{\theta})$ igijo reikšmes $24,858$ ir $24,641$; atitinkamos asimptotinės P reikšmės $pv_a = 0,0519$ ir $pv_a = 0,0550$. Reikšmingumo lygmens $\alpha = 0,05$ kriterijumi hipotezė neatmetama. Turint omenyje tokį didelį stebėjimų skaičių, matyt, galima daryti išvadą, kad tokio tipo duomenims aprašyti Mizeso modelis yra tinkamas.

III.1.18. Tikriname sudėtinę suderinamumo hipotezę

$$H_0 : F(x) \in \mathcal{F}_0 = \{F(x; \boldsymbol{\theta}), \boldsymbol{\theta} \in \Theta\} \in \mathcal{F},$$

kad paprastosios imties $\mathbf{X} = (X_1, \dots, X_n)^T$ elemento X_j pasiskirstymo funkcija prikla-

so aibei \mathcal{F}_0 , sudarytai iš žinomo pavidalo pasiskirstymo funkcijų $F(x; \boldsymbol{\theta})$ priklausančiu nuo nežinomo parametru $\boldsymbol{\theta} = (\theta_1, \dots, \theta_s)^T$. Taikant χ^2 suderinamumo kriterijų abscisių ašis sudalijama į intervalus $-\infty = a_0 < a_1 < \dots < a_k = \infty$, $k > s + 1$, ir gaunama mažiau informatyvi grupuotoji imtis $\mathbf{U} = (U_1, \dots, U_k)^T \sim \mathcal{P}_k(n, \boldsymbol{\pi})$. Vietoje hipotezės H_0 tikrinama hipotezė

$$H'_0 : \boldsymbol{\pi} = \boldsymbol{\pi}(\boldsymbol{\theta}), \quad \boldsymbol{\pi}(\boldsymbol{\theta}) = (\pi_1(\boldsymbol{\theta}), \dots, \pi_k(\boldsymbol{\theta}))^T, \quad \pi_i(\boldsymbol{\theta}) = F_0(a_i; \boldsymbol{\theta}) - F_0(a_{i-1}; \boldsymbol{\theta}).$$

Tikrinant šią hipotezę Pirsono χ^2 kriterijus (žr. III.1.10 pratimą) turi tam tikrų trūkumų. Pirma, nagrinėjant statistikos asimptotiką [4], 2.2.1 teoremoje buvo laikoma, kad grupavimo intervalų galai nepriklauso nuo imties. Tačiau praktiškai grupavimo intervalai parenkami atsižvelgiant į imties rezultatus. Antra, parametru $\boldsymbol{\theta}$ įvertinj reikia rasti DT ar χ^2 minimumo metodu pagal grupuotus duomenis. Gautieji įvertiniai nėra optimalūs, nes naudoja mažiau informatyvią grupuotą imtį. Naudotis asimptotiškai optimaliaisiai įvertiniai, gautais pagal pradinę negrupuotą imtį, negalima, nes tada statistikos asimptotinis skirstinys priklauso ir nuo skirstinio pavidalo, ir nuo parametru.

Šių trūkumų neturi modifiikuotasis χ^2 kriterijus. Sudarant jo statistiką naudojami parametru $\boldsymbol{\theta}$ DT įvertiniai, gauti pagal pradinę imtį, o grupavimo intervalo galai gali tam tikru būdu priklausyti nuo imties.

Kriterijaus statistika Y_n^2 , kai $n \rightarrow \infty$ ir H'_0 teisinga, asimptotiškai turi χ^2 skirstinį (žr. [4], 2.3 skyrelį)

$$Y_n^2 = X_n^2(\hat{\boldsymbol{\theta}}) + Q_n \xrightarrow{d} \chi_{k-1}^2.$$

Atkreipsime dėmesį, kad laisvės laipsnių skaičius nėra mažinamas įvertintų parametru skaičiumi s . Statistika Y_n^2 yra suma dviejų kvadratininių formų: pirmoji $X_n^2(\hat{\boldsymbol{\theta}})$ yra Pirsono statistika, o kvadratinė forma Q_n parinkta taip, kad Y_n^2 asimptotinis skirstinys būtų χ^2 skirstinys su $k - 1$ laisvės laipsniu.

Modifiukoto χ^2 kriterijaus taikymas tikrinant hipotezę apie stebimo a. d. normalumą detaliai iliustruojamas [4], 2.3.3 skyrelio 2.3.2 ir 2.3.3 pavyzdžiuose.

Pagal turimus duomenis parametru μ ir σ DT įverčiai yra $\hat{\mu} = \bar{X} = 324,57$ ir $\hat{\sigma} = 20,8342$. Parenkame $k = 8$ intervalus. Tada $X_n^2 = 8,0$, $Q_n = 2,8302$, $Y_n^2 = 10,8302$ ir $pv_a = \mathbf{P}\{\chi_7^2 > 10,8302\} = 0,1462$. Hipotezė neatmetama.

III.1.19. Perėję prie logaritmų $Y_i = \ln(X_i)$ gauname DT įverčius $\hat{\mu} = \bar{Y} = 2,4589$ ir $\hat{\sigma} = 0,9529$. Parenkame $k = 10$ intervalus. Tada $X_n^2 = 4,1333$, $Q_n = 1,0668$, $Y_n^2 = 5,2001$ ir $pv_a = \mathbf{P}\{\chi_9^2 > 5,2001\} = 0,8165$. Duomenys nepriestarauja iškeltai hipotezei.

III.1.20. Neatsižvelgiant į duomenų apvalinimą gaunama $X_n^2 = 4,160$, $Q_n = 0,172$, $Y_n^2 = 4,332$ ir $pv_a = \mathbf{P}\{\chi_7^2 > 4,332\} = 0,741$. Duomenys nepriestarauja iškeltai hipotezei. Atlikę korekciją atsižvelgdami į duomenų apvalinimą, gauname $X_n'^2 = 3,731$, $Q_n' = 0,952$, $Y_n'^2 = 4,683$ ir $pv_a' = \mathbf{P}\{\chi_7^2 > 4,683\} = 0,699$. Duomenys nepriestarauja iškeltai hipotezei. Reikia pažymėti, kad P reikšmės pv ir pv' gerokai skiriasi. *Nurodymas.* Kadangi duomenys suapvalinti iki sveikujų skaičių, tai gautuosius intervalų galus a_i reikia pastumti iki artimiausių $m \pm 0,5$ pavidalo réžių (m – sveikasis skaičius) ir apskaičiuoti statistikos reikšmę naudojant naujai gautus a'_i .

III.1.21. Tegu turime dvi sistemos $\{A_1, \dots, A_s\}$ ir $\{B_1, \dots, B_r\}$ nesutaikomų, sudarančių pilnas įvykių grupes atsitiktinių įvykių. Tegu U_{ij} yra įvykio $A_i \cap B_j$ pasirodymų skaičius. Atsitiktinis vektorius

$$\mathbf{U} = (U_{11}, \dots, U_{1r}, U_{21}, \dots, U_{2r}, \dots, U_{s1}, \dots, U_{sr})^T$$

turi polinominį skirstinį

$$\mathbf{U} \sim \mathcal{P}_{s \times r}(n, \boldsymbol{\pi}), \quad \boldsymbol{\pi} = (\pi_{11}, \dots, \pi_{sr})^T, \quad \sum_i \sum_j \pi_{ij} = 1.$$

Dviejų atsitiktinių įvykių sistemų nepriklausomumo hipotezė

$$H'_0 : \pi_{ij} = \mathbf{P}\{A_i \cap B_j\} = \mathbf{P}\{A_i\}\mathbf{P}\{B_j\} = \pi_{i.}\pi_{.j}, \quad i = 1, \dots, s, \quad j = 1, \dots, r.$$

Jei hipotezė H'_0 teisinga, tai turime sudėtinės hipotezės atvejį (žr. III.1.10 pratimą), kai polinominio skirstinio tikimybės π_{ij} yra dimensijos $s + r - 2$ parametru

$$\boldsymbol{\theta} = (\pi_{1.}, \dots, \pi_{s-1.}, \pi_{.1}, \dots, \pi_{.r-1})^T$$

funkcijos. Parametru $\boldsymbol{\theta}$ elementų DT įvertiniai yra

$$\hat{\pi}_{i.} = \frac{1}{n} \sum_{j=1}^r U_{ij} = \frac{U_{i.}}{n}, \quad \hat{\pi}_{.j} = \frac{1}{n} \sum_{i=1}^s U_{ij} = \frac{U_{.j}}{n}.$$

Gauname, kad jei H'_0 teisinga ir $n \rightarrow \infty$, tai

$$X_n^2(\hat{\boldsymbol{\theta}}_n) = \sum_i \sum_j \frac{(U_{ij} - n\hat{\pi}_{i.}\hat{\pi}_{.j})^2}{n\hat{\pi}_{i.}\hat{\pi}_{.j}} = n \left(\sum_i \sum_j \frac{U_{ij}^2}{U_{i.}U_{.j}} - 1 \right) \xrightarrow{d} \chi_{(r-1)(s-1)}^2.$$

Nepriklausomumo hipotezė atmetama asimptotiniu reikšmingumo lygmens α kriterijumi, kai

$$X_n^2(\hat{\boldsymbol{\theta}}_n) > \chi_{\alpha}^2((r-1)(s-1)).$$

Pagal turimus duomenis gauname, kad statistika $X_n^2(\hat{\boldsymbol{\theta}}_n)$ igijo reikšmę 121,286. Hipotezė atmetama.

III.1.22. Statistika $X_n^2(\hat{\boldsymbol{\theta}}_n)$ igijo reikšmę 3,719 ir $pv_a = \mathbf{P}\{\chi_4^2 > 3,719\} = 0,4454$; duomenys neprieštarauja iškeltai hipotezei.

III.1.23. Tegu yra s nepriklausomų objektų grupių; i -osios grupės objektų skaičius n_i , $i = 1, \dots, s$. Tegu $\{B_1, \dots, B_r\}$ yra pilna nesutaikomų atsitiktinių įvykių aibė. Stebint bet kurį objektų žinoma, kuris iš įvykių B_1, \dots, B_r įvyko. Pažymėkime U_{ij} skaičių i -osios grupės objektų, kuriuos stebint įvyko įvykis B_j . Tada atsitiktinis vektorius $\mathbf{U}_i = (U_{i1}, U_{i2}, \dots, U_{ir}) \sim \mathcal{P}_r(n_i, (\pi_{i1}, \dots, \pi_{ir}))$, $i = 1, \dots, s$; čia π_{ij} tikimybė įvykti įvykiui B_j , kai objektas yra iš i -osios grupės.

Homogeniškumo hipotezė

$$H'_0 : \pi_{1j} = \pi_{2j} = \dots = \pi_{sj} = \pi_j, \quad j = 1, \dots, r,$$

reiškia, kad įvykio B_j tikimybė yra ta pati visų grupių objektams.

Turime sudėtinės hipotezės atvejį (žr. III.1.10 pratimą), kai polinominį skirstinį tikimybės π_{ij} yra parametru $\boldsymbol{\theta} = (\pi_1, \dots, \pi_{r-1})^T$ funkcijos. DT įvertiniai yra $\hat{\pi}_j = U_{.j} = \sum_i U_{ij}/n$, $n = n_1 + \dots + n_s$. Jeigu H'_0 teisinga ir $n_i \rightarrow \infty$, $i = 1, \dots, s$, tai

$$X_n^2(\hat{\boldsymbol{\theta}}_n) = \sum_i \sum_j \frac{(U_{ij} - n_i \hat{\pi}_j)^2}{n_i \hat{\pi}_j} = n \left(\sum_i \sum_j \frac{U_{ij}^2}{n_i U_{.j}} - 1 \right) \xrightarrow{d} \chi_{(r-1)(s-1)}^2.$$

Hipotezė atmetama asimptotiniu reikšmingumo lygmens α kriterijumi, kai

$$X_n^2(\hat{\theta}_n) > \chi_{\alpha}^2((r-1)(s-1)).$$

Atkreipsime dėmesį, kad statistika ir kritinė sritis yra tokia pat, kaip ir **III.1.21** pratime, nors sprendžiamas visai kitas uždavinys.

Pagal turimus duomenis statistika $X_n^2(\hat{\theta}_n)$ įgijo reikšmę 2,0771 ir $p_{Va} = \mathbf{P}\{\chi_3^2 > 2,0771\} = 0,5566$; duomenys neprieštarauja išskeltajai hipotezei.

III.1.24. Tegu $(X_{i1}, \dots, X_{in_i})^T$, $i = 1, \dots, s$, yra s paprastųjų nepriklausomų imčių ir $F_i(x)$ yra a. d. X_{ij} pasiskirstymo funkcija. Tada homogeniškumo hipotezė:

$$H_0 : F_1(x) \equiv F_2(x) \equiv \dots \equiv F_s(x).$$

Sudalinę abscisių aši į intervalus $-\infty = a_0 < a_1 < \dots < a_r = \infty$, gauname situaciją, aprašytą **III.1.23** pratime: objektus atitinka imčių elementai, o įvykis B_j reiškia patekimą į j -ąjį intervalą. Vietoje hipotezės H_0 tikriname hipotezę $H'_0 : \pi_{1j} = \dots = \pi_{sj} = \pi_j$, $j = 1, \dots, r$. Atmetus hipotezę H'_0 natūralu atmeti ir hipotezę H_0 .

Pagal turimus duomenis gauname, kad statistika $X_n^2(\hat{\theta})$ įgijo reikšmę 75,035 (trys paskutiniai intervalai sujungti) ir $p_{Va} = \mathbf{P}\{\chi_7^2 > 75,035\} < 10^{-12}$; hipotezė atmetama.

III.1.25. Tarkime, kad **III.1.24** pratimo sąlygomis tikrinama siauresnė homogeniškumo hipotezė

$$H_0 : F_1(x) \equiv F_2(x) \equiv \dots \equiv F_s(x) \equiv F_0(x),$$

kurioje tvirtinama ne tik kad pasiskirstymo funkcijos $F_1(x), \dots, F_s(x)$ yra vienodos, bet ir kad jos sutampa su žinoma pasiskirstymo funkcija $F_0(x)$. Perėję prie grupuotųjų imčių vietoje hipotezės H_0 tikriname paprastąją hipotezę

$$H'_0 : \pi_{1j} = \dots = \pi_{sj} = \pi_j^{(0)}, \quad \pi_j^{(0)} = F_0(a_j) - F_0(a_{j-1}).$$

Kriterijaus statistika

$$X_n^2 = \sum_{i=1}^s \sum_{j=1}^r \frac{(U_{ij} - n_i \pi_j^{(0)})^2}{n_i \pi_j^{(0)}} = \sum_{i=1}^s \left[\sum_{j=1}^r \frac{(U_{ij})^2}{n_i \pi_j^{(0)}} - n_i \right].$$

Jeigu H'_0 teisinga ir $n_i \rightarrow \infty$, tai vidinė suma artėja į χ^2 skirstinį su $r-1$ laisvės laipsnių, o $X_n^2 \xrightarrow{d} \chi_{s(r-1)}^2$. Hipotezė H'_0 atmetama asimptotiniu reikšmingumo lygmens α kriterijumi, kai

$$X_n^2 > \chi_{\alpha}^2(s(r-1)).$$

Pagal turimus duomenis gaume, kad statistika X_n^2 įgijo reikšmę 18,032 ir $p_{Va} = \mathbf{P}\{\chi_{22}^2 > 18,032\} = 0,704$.

III.1.26. a) Kiekvienoje imtyje įvertiname parametrą λ , apskaičiuojame statistikų $X_{n_i}^2(\hat{\lambda}_i)$ reikšmes ir jas sudedame. Gaume statistikos, kuri esant teisingai hipotezei asimptotiškai turi chi kvadrato skirstinį su 4 laisvės laipsniais, realizaciją. Gautoji reikšmė yra 2,5659 ir $p_{Va} = \mathbf{P}\{\chi_4^2 > 2,5659\} = 0,6329$. Hipotezė atmeti nėra pagrindo; b) įvertiname parametrą λ pagal jungtinę imtį ir gaume $\hat{\lambda} = 0,2494$. Apskaičiuojame statistikų $X_{n_i}(\hat{\lambda})$ reikšmes ir jas sudedame; gaume 10,2317. Kadangi $p_{Va} = \mathbf{P}\{\chi_7^2 > 10,2317\} = 0,1758$, tai ir ši hipotezė neatmetama. Skaičiuojant du paskutiniai intervalai buvo sujungti.

III.2. Glodūs Neimano ir Bartono kriterijai

III.2.1. Paprastoji sudeginamumo hipotezė

III.2.1. Remiantis paprastąja imtimi $\mathbf{X} = (X_1, \dots, X_n)^T$ tikrinama paprastojo sudeginamumo hipotezė

$$H_0 : X_i \sim F_0(x);$$

čia $F_0(x)$ žinoma absoliučiai tolydi pasiskirstymo funkcija su tankiu $f_0(x) = F'_0(x)$, kai sudėtinė alternatyva yra $H : X_i \sim F(x) \in \mathcal{F}$; čia \mathcal{F} yra absoliučiai tolydžių skirstinių aibė su tankiais $f(x) = F'(x)$.

a) Atlikus integralinę transformaciją $Y_i = F_0(X_i), i = 1, \dots, n$, hipotezė H_0 pereina į tokią. Remiantis paprastąja imtimi Y_1, \dots, Y_n tikrinama hipotezė $H_0 : Y_i \sim U(0, 1)$. Kaip transformuojama alternatyvų aibė \mathcal{F} ?

b) Tegu tikrinama paprastojo hipotezė $H_0 : Y_i \sim U(0, 1)$, kai alternatyvų aibė yra $H : Y_i \sim g(y) \in \mathcal{G}$; čia \mathcal{G} yra intervale $(0, 1)$ apibrėžtų tankių $g(y), 0 < y < 1$, aibė. Atlikime transformaciją $X_i = F_0^{-1}(Y_i)$. Tada hipotezė H_0 virsta paprastąja hipoteze $H_0 : X_i \sim F_0(x)$. Kaip tokiu atveju transformuojasi alternatyvų aibė \mathcal{G} ?

III.2.2. Pagal paprastąją didumo n imtį $\mathbf{X} = (X_1, \dots, X_n)^T$ tikrinama paprastojo sudeginamumo hipotezė $H_0 : X_i \sim \mathcal{E}(1)$, kai alternatyvų aibė yra $\{\mathcal{E}(\lambda), \lambda \neq 1, \lambda > 0\}$. Raskite alternatyvų aibę \mathcal{G} , kai atlikta a. d. X_1, \dots, X_n transformacija $Y_i = 1 - e^{-X_i}$.

III.2.3. (III.2.1 pratimo tēsinys). Tarkime, kad atlikę transformaciją $Y_i = F_0(X_i)$ gavome alternatyvų aibę $\{Be(\lambda, 1), \lambda \neq 1, \lambda > 0\}$. Kokia yra pradinio uždavinio alternatyvų aibė \mathcal{F} , jei $F_0(x) = 1 - e^{-x}$?

III.2.4. Pagal paprastąją didumo n imtį $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ tikrinama paprastojo sudeginamumo hipotezė $H_0 : Y_i \sim U(0, 1)$, kai Neimano tipo alternatyvių tankių aibė yra $\mathcal{G} = \{g(y|\theta) = \frac{1}{c(\theta)} \exp\{\theta(y-1/2)\}, 0 < y < 1, \theta > 0\}$. Raskite TG kriterijų hipotezei H_0 , kai alternatyva yra $H : Y_i \sim g \in \mathcal{G}$, tikrinti. Naudodami normaliajā aproksimacijā suformuluokite asimptotinį kriterijų.

III.2.5. (III.2.4 pratimo tēsinys). Raskite III.2.4 pratime surasto kriterijaus statistikos asimptotinį skirstinį, kai teisinga alternatyva. Naudodami normaliajā aproksimaciją raskite asimptotinio reikšmingumo lygmens α kriterijaus galios funkciją.

III.2.6. (III.2.5 pratimo tēsinys). Apskaičiuokite asimptotinę reikšmingumo lygmens $\alpha = 0,05$ kriterijaus galią, kai a) $n = 50$; $\theta = 1, 2; 1, 5; 2; 3$; b) $\theta = 0, 5; n = 50; 100; 200$.

III.2.7. Pagal paprastąją didumo n imtį $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ tikrinama paprastojo sudeginamumo hipotezė $H_0 : Y_i \sim U(0, 1)$, kai Neimano tipo alternatyvių tankių aibė yra $\mathcal{G} = \{g(y|\theta) = \frac{1}{c(\theta)} \exp\{\theta(y-1/2)^2\}, 0 < y < 1, \theta > 0\}$. Raskite TG kriterijų hipotezei H_0 , kai alternatyva yra $H : Y_i \sim g \in \mathcal{G}$, tikrinti. Naudodami normaliajā aproksimacijā suformuluokite asimptotinį kriterijų.

III.2.8. (III.2.7 pratimo tēsinys). Raskite III.2.7 pratime surasto kriterijaus statistikos asimptotinį skirstinį, kai teisinga alternatyva. Naudodami normaliajā aproksimaciją raskite asimptotinio reikšmingumo lygmens α kriterijaus galios funkciją.

III.2.9. (III.2.8 pratimo tēsinys). Apskaičiuokite asimptotinę reikšmingumo lygmens $\alpha = 0,05$ kriterijaus galią, kai a) $n = 50$; $\theta = 1, 2; 1, 5; 2; 3$; b) $\theta = 1, 0; n = 50; 100; 200$.

III.2.10. Pagal paprastają didumo n imtį $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ tikrinama paprastojo suderinamumo hipotezė $H_0 : Y_i \sim U(0, 1)$, kai alternatyvių tankių aibė yra $\mathcal{G} = \{g(y|\gamma) = \gamma(1-y)^{\gamma-1}, 0 < y < 1, \gamma > 1\}$. Raskite TG kriterijų hipotezei H_0 , kai alternatyva yra $H : Y_i \sim g \in \mathcal{G}$, tikrinti ir jo galios funkcija.

III.2.11. Pagal paprastają didumo n imtį $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ tikrinama paprastojo suderinamumo hipotezė $H_0 : X_i \sim U(0, 1)$, kai alternatyvių tankių aibė yra $\mathcal{G} = \{g(y|\gamma) = \gamma(1-y)^{\gamma-1}, 0 < y < 1, 0 < \gamma < 1\}$. Raskite TG kriterijų hipotezei H_0 , kai alternatyva yra $H : Y_i \sim g \in \mathcal{G}$, tikrinti ir jo galios funkcija.

III.2.12. Pagal paprastają didumo n imtį $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ tikrinama paprastojo suderinamumo hipotezė $H_0 : X_i \sim U(0, 1)$, kai alternatyvių tankių aibė yra 1) $\mathcal{G} = \{g(y|\gamma) = \gamma y^{\gamma-1}, 0 < y < 1, 0 < \gamma < 1\}$; 2) $\mathcal{G} = \{g(y|\gamma) = \gamma y^{\gamma-1}, 0 < y < 1, 1 < \gamma\}$. Raskite TG kriterijus ir jų galios funkcijas.

III.2.2. Sudėtinės suderinamumo hipotezės

III.2.13. Raskite modifikuotojo Neimano ir Bartono tipo (2 parametrai) asimptotinių kriterijų eksponentiškumo hipotezei $H_0 : X_i \sim \mathcal{E}(1/\lambda), \lambda > 0$ tikrinti.

III.2.14. Raskite modifikuotajį asimptotinį kriterijų, grindžiamą beta skirstiniu, eksponentiškumo hipotezei $H_0 : X_i \sim \mathcal{E}(1/\lambda), \lambda > 0$ tikrinti.

III.2.15. (III.2.13 ir III.2.14 pratimų tēsinys). Remdamiesi III.2.13 ir III.2.14 pratimuose rastais kriterijais patikrinkite hipotezę, kad pateiktieji duomenys gauti stebint eksponentinį a. d.

5,017 0,146 6,474 13,291 5,126 8,934 10,971 7,863 5,492 13,930 12,708 7,329 5,408 6,808
0,923 4,679 2,242 4,120 12,080 2,502 16,182 6,592 2,653 4,252 8,609 10,419 2,173 3,321
4,086 11,667 19,474 11,067 11,503 2,284 0,926 2,065 4,703 3,744 5,286 5,497 4,881 0,529
10,397 30,621 5,193 7,901 10,220 16,806 10,672 4,209 5,699 20,952 12,542 7,316 0,272
4,380 9,699 9,466 7,928 13,086 8,871 13,000 16,132 9,950 8,449 8,301 16,127 22,698 4,335

III.2.16. Modifikuotuoju Neimano ir Bartono tipo ir beta skirstiniu grindžiamais kriterijais patikrinkite hipotezę, kad II.1.18 pratimo duomenys gauti stebint normalujį a. d.

III.2.17. Modifikuotuoju Neimano ir Bartono tipo ir beta skirstiniu grindžiamais kriterijais patikrinkite hipotezę, kad II.1.20 pratimo duomenys gauti stebint normalujį a. d.

III.2.18. Sumodeliuokite didumo $n = 50$ paprastają imtį, gautą stebint normalujį a. d., ir, taikydami [4], 3.5 skyrelio kriterijus, patikrinkite hipotezę, kad buvo sumodeliuotas a) normalusis a. d.; b) logistinis a. d.; c) Koši a. d.

III.2.19. Sumodeliuokite didumo $n = 50$ paprastają imtį, gautą stebint lognormalujį a. d., ir, taikydami [4], 3.5 skyrelio kriterijus, patikrinkite hipotezę, kad buvo sumodeliuotas a) lognormalusis a. d.; b) loglogistinis a. d.

III.2.20. Sumodeliuokite didumo $n = 50$ paprastają imtį, gautą stebint Koši a. d., ir, taikydami [4], 3.5 skyrelio kriterijus, patikrinkite hipotezę, kad buvo sumodeliuotas a) normalusis a. d.; b) logistinis a. d.; c) Koši a. d.

III.2.21. Sumodeliuokite didumo $n = 50$ paprastają imtį, gautą stebint Veibulo a. d., ir, taikydami [4], 3.5 skyrelio kriterijus, patikrinkite hipotezę, kad buvo sumodeliuotas

- a) Veibulo a. d.; b) lognormalusis a. d.; c) maksimalių reikšmių a. d.

III.2.3. Sprendimai, atsakymai, nurodymai

III.2.1 skyrelis

III.2.1. a) Tegu $X_i \sim F(x)$. Tada remdamiesi transformacija $Y_i = F_0(X_i)$ ir atvirkštine transformacija $X_i = F_0^{-1}(Y_i)$ gauname a. d. Y_i pasiskirstymo funkciją

$$G(y) = \mathbf{P}\{Y_i < y\} = \mathbf{P}\{F_0(X_i) < y\} = \mathbf{P}\{X_i < F_0^{-1}(y)\} = F(F_0^{-1}(y))$$

ir tankio funkcija

$$g(y) = G'(y) = f(F_0^{-1}(y))[F_0^{-1}(y)]' = \frac{f(F_0^{-1}(y))}{f_0(F_0^{-1}(y))}, \quad 0 < y < 1.$$

b) Remdamiesi transformacija $x = F_0^{-1}(y)$ ir atvirkštine transformacija $y = F_0(x)$, gauname tankio funkciją

$$f(x) = g(F_0(x))d(F_0(x)) = g(F_0(x))f_0(x), \quad g \in \mathcal{G}.$$

III.2.2. Remdamiesi **III.2.1** pratimu gauname tankio funkciją

$$g(y) = \lambda(1-y)^{\lambda-1}, \quad 0 < y < 1, \quad \lambda \neq 1, \quad \lambda > 0.$$

Taigi $\mathcal{G} = \{\mathcal{B}](\infty, \lambda), \lambda \neq \infty, \lambda > 1\}$.

III.2.3. Remdamiesi **III.2.1** pratimu gauname, kad alternatyvų aibę \mathcal{F} sudaro tankiai $f(x) = g(F_0(x))f_0(x) = \lambda e^{-x}(1-e^{-x})^{\lambda-1}, x > 0, \lambda \neq 1$. Jeigu a. d. Y_i pakeistume a. d $Z_i = 1 - Y_i$, tai alternatyvų aibė būtų kaip **III.2.2** pratime $\{\mathcal{E}(\lambda), \lambda \neq 1, \lambda > 0\}$.

III.2.4. Parinkime konkrečią alternatyvą $g(y|\theta)$ iš alternatyvų aibės \mathcal{G} . Tikrinkime paprastąją hipotezę $H_0 : Y_i \sim U(0, 1)$, kai paprastoji alternatyva yra $\bar{H} : Y_i \sim g(y|\theta), i = 1, \dots, n$. Remiantis Neimano ir Pirsono lema hipotezė atmetama, kai

$$\frac{\prod_{i=1}^n g(Y_i|\theta)}{1} = \frac{1}{[c(\theta)]^n} \exp\{\theta \sum_{i=1}^n (Y_i - 1/2)\} > b \Leftrightarrow T = \sum_{i=1}^n (Y_i - 1/2) > d.$$

Konstanta d randama iš sąlygos, kad esant teisingai hipotezei $\mathbf{P}\{T > d\} = \alpha$; čia α kriterijaus reikšmingumo lygmuo. Kadangi surastas kriterijus nepriklauso nuo pasirinktos alternatyvos, tai jis yra TG su visomis alternatyvomis iš \mathcal{G} .

Randame $\mathbf{E}Y_i = ET = 0, \mathbf{V}Y_i = 1/12, VT = n/12$ ir

$$\frac{2\sqrt{3}}{\sqrt{n}}T = \frac{2\sqrt{3}}{\sqrt{n}} \sum_{i=1}^n (Y_i - \frac{1}{2}) \xrightarrow{d} Z \sim N(0, 1).$$

Asimptotiniu reikšmingumo lygmens α kriterijumi hipotezė H_0 atmetama, kai

$$\frac{2\sqrt{3}}{\sqrt{n}} \sum_{i=1}^n (Y_i - \frac{1}{2}) > z_\alpha.$$

III.2.5. Pažymėkime $\mu(\theta) = \mathbf{E}_\theta(Y_i - 1/2)$ ir $\sigma^2(\theta) = \mathbf{V}_\theta(Y_i - 1/2)$. Jeigu θ tikroji parametru reikšmė, tai

$$T(\theta) = (1/(\sigma(\theta)\sqrt{n})) \sum_{i=1}^n (Y_i - 1/2 - \mu(\theta)) \xrightarrow{d} Z \sim N(0, 1).$$

Asimptotinė reikšmingumo lygmens α kriterijaus galia

$$\begin{aligned} \beta(\theta) &= \mathbf{P}_\theta \left\{ \frac{2\sqrt{3}}{\sqrt{n}} \sum_{i=1}^n (Y_i - \frac{1}{2}) > z_\alpha \right\} = \\ &= \mathbf{P}_\theta \left\{ T(\theta) > \frac{z_\alpha}{2\sqrt{3}\sigma(\theta)} - \frac{\mu(\theta)\sqrt{n}}{\sigma(\theta)} \right\} = \Phi \left(\frac{\sqrt{n}\mu(\theta)}{\sigma(\theta)} - \frac{z_\alpha}{\sqrt{12}\sigma(\theta)} \right). \end{aligned}$$

Reikia dar rasti $\mu(\theta)$ ir $\sigma(\theta)$. Randame normuojančią konstantą $c(\theta) = (e^{\theta/2} - e^{-\theta/2})/\theta$. Tada

$$\mu(\theta) = [\ln c(\theta)]'_\theta = [e^\theta(\theta - 2) + \theta + 2]/(2\theta(e^\theta - 1));$$

$$\sigma^2(\theta) = [\ln c(\theta)]''_{\theta^2} = e^\theta(e^\theta + e^{-\theta} - \theta^2 - 2)/(\theta(e^\theta - 1))^2.$$

III.2.6. a) 0,7807; 0,9164; 0,9919; 1,000; b) 0,6451; 0,8897; 0,9925.

III.2.7. Parinkime konkrečią alternatyvą $g(y|\theta)$ iš alternatyvų aibės \mathcal{G} . Tikrinkime paprastąjį hipotezę $H_0 : Y_i \sim U(0, 1)$, kai paprastoji alternatyva yra $\bar{H} : Y_i \sim g(y|\theta)$, $i = 1, \dots, n$. Remiantis Neimano ir Pirsono lema hipotezė atmetama, kai

$$\frac{\prod_{i=1}^n g(Y_i|\theta)}{1} = \frac{1}{[c(\theta)]^n} \exp \left\{ \theta \sum_{i=1}^n (Y_i - 1/2)^2 \right\} > b \Leftrightarrow T = \sum_{i=1}^n (Y_i - 1/2)^2 > d.$$

Konstanta d randama iš sąlygos, kad esant teisingai hipotezei $\mathbf{P}\{T > d\} = \alpha$; čia α kriterijaus reikšmingumo lygmuo. Kadangi surastas kriterijus nepriklauso nuo pasirinktos alternatyvos, tai jis yra TG su visomis alternatyvomis iš \mathcal{G} .

Kai hipotezė teisinga, tai $\mathbf{E}(Y_i - 1/2)^2 = 1/12$, $\mathbf{V}(Y_i - 1/2)^2 = 1/180$ ir

$$\frac{6\sqrt{5}}{\sqrt{n}} \sum_{i=1}^n [(Y_i - \frac{1}{2})^2 - \frac{1}{12}] \xrightarrow{d} Z \sim N(0, 1).$$

Asimptotiniu reikšmingumo lygmens α kriterijumi hipotezė H_0 atmetama, kai

$$\frac{6\sqrt{5}}{\sqrt{n}} \sum_{i=1}^n [(Y_i - \frac{1}{2})^2 - \frac{1}{12}] > z_\alpha.$$

III.2.8. Pažymėkime $\mu(\theta) = \mathbf{E}_\theta(Y_i - 1/2)^2$ ir $\sigma^2(\theta) = \mathbf{V}_\theta(Y_i - 1/2)^2$. Jeigu θ tikroji parametru reikšmė, tai

$$T(\theta) = \frac{1}{\sqrt{n}\sigma(\theta)} \sum_{i=1}^n [(Y_i - 1/2)^2 - \mu(\theta)] \xrightarrow{d} Z \sim N(0, 1).$$

Asimptotinė kriterijaus galia

$$\beta(\theta) = \Phi\left(\frac{\sqrt{n}(\mu(\theta) - 1/12)}{\sigma(\theta)} - \frac{z_\alpha}{(6\sqrt{5}\sigma(\theta))}\right).$$

Normuojanti konstanta $c(\theta) = \int_0^1 \exp\{\theta(x-1/2)^2\}dx$, $c'(\theta) = \int_0^1 (x-1/2)^2 \exp\{\theta(x-1/2)^2\}dx$, $c''(\theta) = \int_0^1 (x-1/2)^4 \exp\{\theta(x-1/2)^2\}dx$. Tada $\mu(\theta) = c'(\theta)/c(\theta)$, $\sigma^2(\theta) = c''(\theta)/c(\theta) - [c'(\theta)/c(\theta)]^2$. Kai θ žinomas, integralus apskaičiuoti skaitiniai metodais.

III.2.9. a) 0,1668; 0,2122; 0,3016; 0,5148; b) 0,1403; 0,1950; 0,2912.

III.2.10. Parinkime konkretią alternatyvą $g(y|\theta)$ iš alternatyvų aibės \mathcal{G} . Tikrinkime paprastąją hipotezę $H_0 : Y_i \sim U(0, 1)$, kai paprastojoj alternatyva yra $\bar{H} : Y_i \sim g(y|\theta)$, $i = 1, \dots, n$. Remiantis Neimano ir Pirsono lema hipotezė atmetama, kai

$$\frac{\prod_{i=1}^n g(Y_i|\gamma)}{1} = \gamma^n \prod_{i=1}^n (1 - Y_i)^{\gamma-1} = \exp\{(\gamma - 1) \sum_{i=1}^n \ln(1 - Y_i) + n \ln \gamma\} > c \Leftrightarrow \\ T = \sum_{i=1}^n \ln(1 - Y_i) > d.$$

Konstanta d randama iš sąlygos, kad esant teisingai hipotezei $\mathbf{P}\{T > d\} = \alpha$; čia α kriterijaus reikšmingumo lygmuo. Kadangi surastas kriterijus nepriklauso nuo pasirinktos alternatyvos, tai jis yra TG su visomis alternatyvomis iš \mathcal{G} .

Esant teisingai hipotezei $-\ln(1 - Y_i) \sim G(1, 1)$, $-2 \ln(1 - Y_i) \sim \chi^2(2)$, todėl surastajį TG kriterijų galima suformuluoti taip: hipotezė atmetama, kai

$$-2T = -2 \sum_{i=1}^n \ln(1 - Y_i) < \chi^2_{1-\alpha}(2n).$$

Kai teisinga alternatyva $g(y|\gamma)$, tai $-2 \ln(1 - Y_i) \sim G(\gamma, 1)$, $-2\gamma \ln(1 - Y_i) \sim \chi^2(2)$. Kriterijaus galios funkcija

$$\beta(\gamma) = \mathbf{P}_\gamma\left\{-2 \sum_{i=1}^n \ln(1 - Y_i) < \chi^2_{1-\alpha}(2n)\right\} = \mathbf{P}\{\chi^2_{2n} < \gamma \chi^2_{1-\alpha}(2n)\}$$

artėja prie vieneto, kai $\gamma \rightarrow \infty$.

III.2.11. Analogiškai **III.2.10** pratimui reikšmingumo lygmens α TG kriterijus atmeta hipotezę H_0 , kai $T = -2 \sum_{i=1}^n \ln(1 - Y_i) > \chi^2_\alpha(2n)$. Galios funkcija $\beta(\gamma) = \mathbf{P}\{\chi^2_{2n} > \gamma \chi^2_\alpha(2n)\} \rightarrow 1$, kai $\gamma \rightarrow 0$.

III.2.12. Atlikę keitimą $Z_i = 1 - Y_i$ gauname **III.2.10**, **III.2.11** pratimų alternatyvų šeimas.

III.2.2 skyrelis

III.2.13. Hipotezė atmetama asimptotiniu reikšmingumo lygmens α kriterijumi, kai $T = (T_1^2 - 2\rho T_1 T_2 + T_2^2)/(1 - \rho^2) > \chi^2_\alpha(2)$, čia $T_1 = 4\sqrt{3} \sum_{i=1}^n (Y_i - 1/2)/\sqrt{n}$, $T_2 =$

$6\sqrt{5} \sum_{i=1}^n [6(Y_i - 1/2)^2 - 1/2]/\sqrt{31n}$, $Y_i = 1 - \exp(-X_i/\bar{X})$, $\rho = -0,6956$. Nurodymas. Pakartokite [4], 3.4.2 ir 3.4.3 teoremų įrodymus, kai yra eksponentinis skirstinys (vienas mastelio parametras).

III.2.14. Statistikos $\hat{T}_2 = \sum_i (\ln(1 - Y_i) + 1)/\sqrt{n}$ skirstinys išsigimės. Todėl kriterijų sudarome naudodami tik statistiką $\hat{T}_1 = \sum_i \ln Y_i + 1/\sqrt{n\sigma_{11}}$, $\sigma_{11} = \pi^2(12 - \pi^2)/36$. Hipotezė atmetama asimptotiniu reikšmingumo lygmens α kriterijumi, kai $\hat{T}_1^2 > \chi_\alpha^2(1)$.

III.2.15. Statistikos T ir \hat{T}_1^2 igijo reikšmes 11,80085 ir 7,1079; atitinkamos P reikšmės 0,0027 ir 0,0077. Hipotezė atmetina.

III.2.16. Statistikos T ir \tilde{T} igijo reikšmes 0,2714 ir 0,4506; atitinkamos P reikšmės 0,8731 ir 0,7983. Hipotezė neatmetina.

III.2.17. Statistikos T ir \tilde{T} igijo reikšmes 0,2714 ir 0,4506; atitinkamos P reikšmės 0,8731 ir 0,7983. Hipotezė neatmetina.

III.3. Kriterijai, grindžiami empiriniais procesais

III.3.1. Pratimai

III.3.1. Remiantis paprastaja imtimi $\mathbf{X} = (X_1, \dots, Z_n)^T$, gauta stebint a. d. X , kurio pasiskirstymo funkcija priklauso tolydžiųjų skirstinių šeimai \mathcal{F} , tikrinama paprastojo hipotezė

$$H_0 : F(x) \equiv F_0(x);$$

čia $F_0(x)$ žinoma šeimos \mathcal{F} pasiskirstymo funkcija. Tegu $\hat{F}_n(x)$ yra empirinė pasiskirstymo funkcija.

Įrodykite, kad jei H_0 teisinga, tai Kolmogorovo ir Smirnovo statistikos

$$D_n = \sup_{-\infty < x < \infty} |\hat{F}_n(x) - F_0(x)|,$$

Kramerio ir Mizeso statistikos

$$C_n = \int_{-\infty}^{\infty} (\hat{F}_n(x) - F_0(x))^2 d(F_0(x)),$$

Anderseno ir Darlingo statistikos

$$A_n = \int_{-\infty}^{\infty} \frac{(\hat{F}_n(x) - F_0(x))^2}{F_0(x)(1 - F_0(x))} d(F_0(x))$$

skirstiniai nepriklauso nuo $F_0(x)$, o priklauso tik nuo imties didumo n .

III.3.2. (III.3.1 pratimo tēsinys). Tegu $Y_i = F_0(X_i)$, $i = 1, \dots, n$. Įrodykite, kad Kolmogorovo ir Smirnovo statistikos realizacija gali būti surasta tokiu būdu

$$D_n = \max(D_n^+, D_n^-),$$

$$D_n^+ = \max_{1 \leq i \leq n} \left(\frac{i}{n} - Y_{(i)} \right), \quad D_n^- = \max_{1 \leq i \leq n} \left(Y_{(i)} - \frac{i-1}{n} \right).$$

III.3.3. (III.3.1 pratimo tēsinys). Įrodykite, kad Kramerio ir Mizeso statistikos C_n bei Anderseno ir Darlingo statistikos A_n realizacijos gali būti surastos tokiu būdu

$$\begin{aligned} nC_n &= \frac{1}{12n} + \sum_{i=1}^n (Y_{(i)} - \frac{2i-1}{2n})^2, \\ nA_n &= -n - \frac{1}{n} \sum_{i=1}^n (2i-1)[\ln(Y_{(i)}) + \ln(1-Y_{(n-i+1)})]. \end{aligned}$$

III.3.4. Jeigu hipotezė H_0 (žr. III.3.1 pratimą) teisinga ir $n \rightarrow \infty$, tai

$$nC_n \xrightarrow{d} C = \int_0^1 B^2(t)dt, \quad nA_n \xrightarrow{d} A = \int_0^1 \frac{B^2(t)}{t(1-t)}dt,$$

čia $B(t)$ yra intervalo $[0, 1]$ Brauno tiltas (žr. [4], 8.2.3 skyrelij). Raskite a.d. C ir A pirmuosius du momentus.

III.3.5. (III.3.4 pratimo tēsinys). Raskite statistikų nC_n ir nA_n pirmuosius du momentus.

III.3.6. Turime didumo n imtį, gautą stebint tolydujį a.d. su pasiskirstymo funkcija $F(x)$. Nurodykite sritį, i kurią pasiskirstymo funkcija $F(x)$ patenka su tikimybe, ne mažesne už Q .

III.3.7. Tarkime, X yra diskretus a.d., kurio galimos reikšmės $0, 1, 2, \dots$, o jų įgijimo tikimybės $p_k = \mathbf{P}\{X = k\}, k = 0, 1, \dots$. Įrodykite, kad a.d.

$$Z = \sum_{k=0}^{X-1} p_k + p_X Y, \quad \sum_{i=1}^{-1} = 0,$$

yra tolygiai pasiskirstęs intervale $(0, 1)$, kai $Y \sim U(0, 1)$ ir nepriklauso nuo X .

III.3.8. (III.3.7 pratimo tēsinys). Tarkime, X_1, \dots, X_n yra paprastoji imtis diskrečiojo a.d. X , o $\hat{F}_n(x)$ – empirinė pasiskirstymo funkcija. Reikia patikrinti hipotezę $H : \mathbf{E}(\hat{F}_n(x)) = F_0(x), |x| < \infty$; čia $F_0(x)$ – visiškai nusakyta diskrečioji pasiskirstymo funkcija. Remdamiesi III.3.7 pratimu sukonstruokite randomizuotus Kolmogorovo ir Smirnovą, Kramerio ir Mizeso, Anderseno ir Darlingo kriterijų analogus hipotezei H_0 tikrinti.

III.3.9. (III.3.8 pratimo tēsinys). Remdamiesi III.3.8 pratime aptartu kriterijumi atlikite III.1.3 pratimo užduotį.

III.3.10. (III.3.8 pratimo tēsinys). Remdamiesi III.3.8 pratime aptartu kriterijumi atlikite III.1.1 pratimo užduotį.

III.3.11. Remdamiesi Kolmogorovo ir Smirnovą, Kramerio ir Mizeso bei Anderseno ir Darlingo kriterijais patikrinkite hipotezę, kad II.1.18 pratimo imtis gauta stebint a) normalujį a.d., kai jo parametrais imame DT įvertinių $\hat{\mu}$ ir $\hat{\sigma}^2$ realizacijas, b) normalujį a.d.

III.3.12. Remdamiesi Kolmogorovo ir Smirnovą, Kramerio ir Mizeso bei Anderseno ir Darlingo kriterijais patikrinkite hipotezę, kad II.1.19 pratimo imtis gauta stebint a) lognormalujį a.d., kai jo parametrais imame DT įvertinių $\hat{\mu}$ ir $\hat{\sigma}$ realizacijas, b) lognormalujį a.d.

III.3.13. Kontroliuojant staklių stabilumą, kiekvieną valandą paimama 20 gaminiai ir remiantis jų tam tikro parametru matavimo rezultatais apskaičiuojamas nepaslinktasis dispersijos įvertinys s^2 . Lentelėje pateikta 47 įvertinių realizacijos.

0,1225	0,1764	0,1024	0,1681	0,0841	0,0729	0,1444	0,0900
0,0961	0,1369	0,1521	0,1089	0,1296	0,1225	0,1156	0,1681
0,0676	0,0784	0,1024	0,1156	0,1024	0,0676	0,1225	0,1521
0,1369	0,1444	0,1521	0,1024	0,1089	0,1600	0,0961	0,1600
0,1024	0,1369	0,1089	0,1681	0,1296	0,1521	0,1600	0,0576
0,0784	0,1089	0,1056	0,1444	0,1296	0,1024	0,1369	

Remdamiesi Kolmogorovo ir Smirnovo, Kramerio ir Mizeso bei Anderseno ir Darlingo kriterijais, patikrinkite hipotezę, kad prietaisas buvo stabilus (pagal matuojamo parametru reikšmių nukrypimus). Laikykite, kad tokiu atveju matuojamasis parametras pasiskirstęs pagal normalųjį dėsnį su dispersija $\sigma^2 = 0,1090$.

III.3.14. Lentelėje pateikti dviejų eksperimentų su musėmis rezultatai. Pirmame eksperimente tam tikrais nuodais musės veikiamos 30 sekundžių, antrame – 60 sekundžių. Paralyžiuojantį nuodą poveikį apibūdina reakcijos laikas (X_{1i} pirmame ir X_{2i} antrame eksperimente), praėjęs nuo musės salyčio su nuodais iki to momento, kai musė nebegali stovėti.

i	X_{1i}	i	X_{1i}	i	X_{2i}	i	X_{2i}
1	3,1	9	53,1	1	3,3	9	56,7
2	9,4	10	59,4	2	10,0	10	63,3
3	15,6	11	65,6	3	10,7	11	70,0
4	21,9	12	71,9	4	23,3	12	76,7
5	28,1	13	78,1	5	30,0	13	83,3
6	34,4	14	84,4	6	36,7	14	90,0
7	40,6	15	90,6	7	43,3	15	96,7
8	46,9	16	96,9	8	50,0		

Remdamiesi Kolmogorovo ir Smirnovo bei Kramerio ir Mizeso dviejų imčių kriterijais, patikrinkite homogeniškumo hipotezę.

III.3.15. Sudalinkite **II.1.18** pratimo duomenis į dvi imtis (pirmieji 5 ir likusieji 5 stulpeliai). Remdamiesi Kolmogorovo ir Smirnovo bei Kramerio ir Mizeso dviejų imčių kriterijais, patikrinkite homogeniškumo hipotezę.

III.3.16. Sudalinkite **II.1.19** pratimo duomenis į dvi imtis (pirmieji 5 ir likusieji 10 stulpelių). Remdamiesi Kolmogorovo ir Smirnovo bei Kramerio ir Mizeso dviejų imčių kriterijais patikrinkite homogeniškumo hipotezę.

III.3.2. Sprendimai, atsakymai, nurodymai

III.3.1. Tegu $Y_i = (F_0(X_i))$. Tada $\mathbf{Y} = (Y_1, \dots, Y_n)^T$ yra paprastoji imtis a. d. $Y \sim U(0, 1)$. Pažymėję $\hat{G}_n(y)$ imties \mathbf{Y} empirinę pasiskirstymo funkciją, gauname

$$D_n = \sup_{0 \leq y \leq 1} |\hat{G}_n(y) - y|, \quad C_n = \int_0^1 (\hat{G}_n(y) - y)^2 dy,$$

$$A_n = \int_0^1 \frac{(\hat{G}_n(y) - y)^2}{y(1-y)} dy.$$

Taigi statistikų D_n, C_n, A_n skirstiniai nuo F_0 nepriklauso.

III.3.2. Žr. [4], 4.2.1 teorema.

III.3.3. Žr. [4], 4.3.1 teorema.

III.3.4. $EC = 1/6, VC = 1/45; EA = 1, VA = 2\pi^2/3 - 6$. *Nurodymas.* $EC = \int_0^1 \mathbf{E}(B^2(t))dt, \mathbf{E}(C^2) = 2 \int_0^1 \int_0^t \mathbf{E}(B^2(t)B^2(s))dsdt$. Pasinaudokite tuo, kad $B(t) \sim N(0, t(1-t)), 0 \leq t \leq 1; (B(s), B(t))^T \sim N_2(\mathbf{0}, \Sigma)$, $\sigma_{11} = s(1-s), \sigma_{22} = t(1-t), \sigma_{12} = s(1-t), 0 \leq s \leq t \leq 1$.

III.3.5. $\mathbf{E}(nC_n) = 1/6, \mathbf{V}(nC_n) = 1/45 - 1/(60n); \mathbf{E}(nA_n) = 1, \mathbf{V}(nA_n) = 2\pi^2/3 - 6 + (10 - \pi^2)/n$.

Nurodymas. $\mathbf{E}(nC_n) = \int_0^1 n \mathbf{E}((\hat{G}_n(y) - y)^2 dy, \mathbf{E}(nC_n)^2) = 2 \int_0^1 \int_0^y n^2 \mathbf{E}[(\hat{G}_n(x) - x)^2 (\hat{G}_n(y) - y)^2] dx dy$. Atsitiktinis dydis $n\hat{G}_n(y) \sim B(n, y), 0 < y < 1$; atsitiktinis vektorius $(n\hat{G}_n(x), n(\hat{G}_n(y) - \hat{G}_n(x)), n(1 - \hat{G}_n(y)))^T \sim \mathcal{P}_3(n, (x, y - x, 1 - y)), 0 \leq x \leq y \leq 1$. Randame po integralų ženklais parašytų momentų išraiškas ir jas integruojame.

III.3.6. Tegu $\hat{F}_n(x)$ yra empirinė pasiskirstymo funkcija, $D_n = \sup_{-\infty < x < \infty} |\hat{F}_n(x) - F(x)|$ Kolmogorovo ir Smirnov statistika ir $D_\alpha(n)$ statistikos D_n lygmens α kritinė reikšmė. Tada

$$\mathbf{P}\left\{\sup_{-\infty < x < \infty} |\hat{F}_n(x) - F(x)| < D_\alpha(n)\right\} = Q = 1 - \alpha,$$

arba

$$\mathbf{P}\{\hat{F}_n(x) - D_\alpha(n) < F(x) < \hat{F}_n(x) + D_\alpha(n), \forall x \in \mathbf{R}\} = Q.$$

Kadangi $F(x)$ igyja reikšmes iš intervalo $[0, 1]$, tai tikimybė nepakis, jeigu apatinę ribą pakeisime $\max(0, \hat{F}_n(x) - D_\alpha(n))$, o viršutinę ribą į $\min(\hat{F}_n(x) + D_\alpha(n), 1)$.

III.3.7. Pažymėkime $P_k = p_0 + \dots + p_k, k = 0, 1, \dots$. Pagal pilnosios tikimybės formulę

$$G(z) = \mathbf{P}\{Z \leq z\} = \sum_{k=0}^{\infty} \mathbf{P}\{Z \leq z | X = k\} p_k;$$

$$\mathbf{P}\{Z \leq z | X = k\} = \mathbf{P}\{Y \leq (z - P_{k-1})/p_k\};$$

pastaroji tikimybė lygi 0, kai $z < P_{k-1}$, lygi $(z - P_{k-1})/p_k$, kai $P_{k-1} \leq z \leq P_k$, ir lygi 1, kai $z > P_k$. Tankio funkcija

$$g(z) = G'(z) = 1, \text{ kai } 0 \leq z \leq 1.$$

III.3.8. Hipotezę H pakeiskime hipotezę $H' : \mathbf{E}(\hat{G}_n(z)) = G(z), 0 < z < 1$. Čia $\hat{G}_n(z)$ – empirinė pasiskirstymo funkcija imties $Z_i = F_0(X_i) + p_{X_i} Y_k, i = 1, \dots, n, k = 1, \dots, n; Y_1, \dots, Y_n$ – nepriklausanti nuo X_1, \dots, X_n paprastoji a. d. $Y \sim U(0, 1)$ imties, o $G(z)$ – tolygiojo skirstinio $U(0, 1)$ pasiskirstymo funkcija. Taip gauname randomizuotą, pavyzdžiu, Kolmogorovo ir Smirnov kriterijaus analogą diskretiesiems skirstiniams.

III.3.9. Atlikę **III.3.8** pratime nurodytą randomizaciją, gauname statistikų realizacijas $D_n = 0,0196, C_n = 0,0603, A_n = 0,3901$. Atitinkamos P reikšmės $> 0,25$. Hipotezė neatmetama.

III.3.10. Atlikę III.3.8 pratime nurodytą randomizaciją, gauname statistikų realizacijas $D_n = 0,0305, C_n = 0,0814, A_n = 0,5955$. Atitinkamos P reikšmės $> 0,25$. Hipotezė neatmetama.

III.3.11. a) Kolmogorovo ir Smirnovo, Kramerio ir Mizeso bei Anderseno ir Darlingo statistikų realizacijos yra $0,0828, 0,1139, 0,7948$, o atitinkamos P reikšmės $0,5018, 0,5244, 0,4834$. Hipotezė neatmetama. b) Taikydami modifikuotuosius kriterijus gauname tas pačias statistikų realizacijas, o P reikšmės yra $0,0902, 0,0762, 0,0399$. Hipotezės teisingumas kelia abejonių.

III.3.12. a) Kolmogorovo ir Smirnovo, Kramerio ir Mizeso bei Anderseno ir Darlingo statistikų realizacijos yra $0,0573, 0,0464, 0,3411$, o atitinkamos P reikšmės $0,6927, 0,8911, 0,8978$. Hipotezė neatmetama. b) Taikydami modifikuotuosius kriterijus gauname, kad P reikšmė pirmu atveju $> 0,15$, o kitais dviem atvejais $> 0,25$. Atsakymas nepakinta.

III.3.13. Kolmogorovo ir Smirnovo, Kramerio ir Mizeso bei Anderseno ir Darlingo statistikų realizacijos yra $0,2547, 0,8637, 4,3106$, o atitinkamos P reikšmės $0,0041, 0,0049, 0,0065$. Hipotezė at mestina.

III.3.14. Statistika $D_{m,n}$ įgijo reikšmę $0,075$. Kritinė reikšmė $D_{0,05}(15, 16) = 0,475$. Asimptotinė P reikšmė $pv_a = 1 - K(0, 2087) \approx 1$. Hipotezė neatmetama. Kramerio ir Mizeso statistikos reikšmė $0,0032$ ir $pv_a = 1 - a_1(0, 0032) \approx 1$. Hipotezė neatmetama.

III.3.15. Statistika $D_{m,n}$ įgijo reikšmę $0,16$, $pv = 0,471$ ir $pv_a = 1 - K(1, 1) = 0,5441$. Kramerio ir Mizeso statistikos reikšmė $0,2511$ ir $pv_a = 1 - a_1(0, 2511) = 0,187$. Hipotezė neatmetama.

III.3.16. Statistika $D_{m,n}$ įgijo reikšmę $0,13$, $pv = 0,5227$ ir $pv_a = 0,6262$. Kramerio ir Mizeso statistikos reikšmė $0,1668$ ir $pv_a = 1 - a_1(0, 1668) = 0,3425$. Hipotezė neatmetama.

III.4. Ranginiai kriterijai

III.4.1. Nepriklausomumo hipotezių tikrinimas

III.4.1. Tegu $\mathbf{X} = (X_1, \dots, X_n)^T$ yra paprastoji imtis absoliučiai tolydaus a. d. X , o $X_{(1)} \leq \dots \leq X_{(n)}$ yra pozicinės statistikos. Imties elemento X_i rangu R_i vadiname to elemento eilės numerį variacinėje eilutėje $(X_{(1)}, \dots, X_{(n)})$, t. y.

$$R_i = \text{rangas}(X_i) = j, \quad \text{jeigu } X_i = X_{(j)}.$$

Raskite a. d. R_i vidurkį ir dispersiją.

III.4.2. Krakmolo kiekis bulvėse nustatomas dviem būdais. Norint palyginti tuos būdus, buvo paimta 16 bulvių ir kiekvienos iš jų krakmolo kiekis nustatytas abiem būdais. Gauti rezultatai surašyti lentelėje (X_i – pirmu būdu, o Y_i – antruoju).

i	X_i	Y_i	i	X_i	Y_i
1	21,7	21,5	9	14,0	13,9
2	18,7	18,7	10	17,2	17,0
3	18,3	18,3	11	21,7	21,4
4	17,5	17,4	12	18,6	18,6
5	18,5	18,3	13	17,9	18,0
6	15,6	15,4	14	17,7	17,6
7	17,0	16,7	15	18,3	18,5
8	16,6	16,9	16	15,6	15,5

Patikrinkite hipotezę apie a.d. X ir Y nepriklausomumą, remdamiesi Spirmeno ir Kendalo ranginiai koreliacijos koeficientais.

III.4.3. Tiriant specialios sėjamosios efektyvumą, 10 sklypelių buvo sėjama paprasta sėjamaja ir 10 sklypelių – specialia sėjamaja, paskui buvo lyginamas derlingumas. Norint eliminuoti dirvožemio įtaką, 20 vienodo ploto sklypelių buvo taip sugrupuota poromis, kad jie būtų greta vienas kito. Metant monetą, buvo nusprendžiama, kuriame iš dviejų gretimų sklypelių seti specialia sėjamaja. Rezultatai pateikti lentelėje (X_i – derlingumas sėjant specialia sėjamaja, Y_i – paprasta sėjamaja).

i	X_i	Y_i	i	X_i	Y_i
1	8,0	5,6	6	7,7	6,1
2	8,4	7,4	7	7,7	6,6
3	8,0	7,3	8	5,6	6,0
4	6,4	6,4	9	5,6	5,5
5	8,6	7,5	10	6,2	5,5

Patikrinkite hipotezę apie a.d. X ir Y nepriklausomumą, remdamiesi Spirmeno ir Kendalo ranginiai koreliacijos koeficientais.

III.4.4. Patikrinkite atsitiktinumo hipotezę pagal **II.1.18** pratimo duomenis.

III.4.5. Patikrinkite atsitiktinumo hipotezę pagal **II.1.19** pratimo duomenis.

III.4.2. Homogeniškumo hipotezių tikrinimas

III.4.6. Remdamiesi Vilkoksono ir Van der Vardeno kriterijais patikrinkite hipotezę apie nuodū poveikio vienodomą pagal **III.3.15** pratimo duomenis.

III.4.7. Irodykite, kad gama skirstinio $G(1, \eta)$ atveju Vilkoksono kriterijaus ASE, palyginti su Stjudento kriterijumi, kai alternatyvos poslinkio, yra

$$e(W, t) = A(\eta) = \frac{3\eta}{2^{4(\eta-1)}((2\eta-1)B(\eta, \eta))^2}.$$

Patikrinkite, kad $A(\eta) > 1,25$, kai $\eta \leq 3$; $A(\eta) \rightarrow \infty$, kai $\eta \rightarrow 1/2$; $A(\eta) \rightarrow 3/\pi$, kai $\eta \rightarrow \infty$.

III.4.8. Tikrinama hipotezė, kad impulso atpažinimo paklaida nepriklauso nuo jo intensyvumo. Buvo atlikti du nepriklausomi eksperimentai. Impulsas, kurio intensyvumas 10 salyginių vienetų, buvo įvertintas 9, 9, 8, 10, 12, 13, 10, 11 vienetų; impulsas, kurio intensyvumas 20 salyginių vienetų, $-15, 16, 17, 23, 22, 20, 21, 24, 27$. Remdamiesi ranginiai kriterijais, kai alternatyvos yra mastelio, patikrinkite, ar gauti duomenys nepristarauja iškeltais hipotezei.

III.4.9. Suskaidykime **II.1.18** pratimo duomenis į 10 vienodo didumo imčių (duomenys surašyti skirtingose eilutėse). Remdamiesi Kruskalo ir Voliso ir inversijų skaičiumi grindžiamais kriterijais, patikrinkite hipotezę, kad visais atvejais buvo stebimas tas pats atsitiktinis dydis.

III.4.10. Trijose gamyklose buvo testuojami kineskopai. Jų darbo trukmė (mėnesiais iki pirmo gedimo) surašyti pateikiamoje lentelėje. Ar galima tvirtinti, kad visose trijose gamyklose gaminamų kineskopų darbo trukmė yra vienoda?

1 gam.	41	70	26	89	62	54	46	77	34	51
2 gam.	30	69	42	60	44	74	32	47	45	37
3 gam.	23	35	29	38	21	53	31	25	36	50
										61

III.4.11. Lentelėje pateikti avarijų Lietuvos keliuose 1990–1999 metų duomenys.

	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999
X	5135	6067	4049	4319	3902	4144	4579	5319	6445	6356
Y	933	1093	779	893	765	672	667	725	829	748
Z	5491	6638	4251	4555	4146	4508	5223	6198	7669	7696

Apskaičiuokite konkordancijos koeficientą ir patikrinkite hipotezę dėl a. d. X, Y ir Z priklausomybės. Remdamiesi Spirmeno ir Kendalo ranginiaių koreliacijos koeficientais patikrinkite hipotezes dėl a. d. X ir Y priklausomybės; dėl a. d. X ir Z priklausomybės.

III.4.12. Remdamiesi Vilkoksono ženklių kriterijumi priklausomoms imtims, patikrinkite hipotezę dėl a. d. X ir Y skirstinių vienodumo pagal **III.4.2** pratimo duomenis.

III.4.13. Remdamiesi Vilkoksono ženklių kriterijumi priklausomoms imtims, patikrinkite hipotezę dėl a. d. X ir Y skirstinių vienodumo pagal **III.4.3** pratimo duomenis.

III.4.14. Lentelėje pateikti duomenys apie 3 tiekėjų siūlomų 12 skirtinį tipų spausdintuvų kainas.

Tipas	1 tiek.	2 tiek.	3 tiek.	Tipas	1 tiek.	2 tiek.	3 tiek.
1	660	673	658	7	1980	1950	1970
2	790	799	785	8	2300	2295	2310
3	590	580	599	9	2500	2480	2490
4	950	945	960	10	2190	2190	2210
5	1290	1280	1295	11	5590	5500	5550
6	1550	1500	1499	12	6000	6100	6090

Remdamiesi Frydmano kriterijumi patikrinkite hipotezę, kad skirtinį tiekėjų spausdintuvų kainos nesiskiria.

III.4.3. Sprendimai, atsakymai, nurodymai

III.4.1 skyrelis

III.4.1. A. d. R_i įgyja reikšmes $1, 2, \dots, n$ su vienodomis tikimybėmis $1/n$. Randame

$$\mathbf{E}R_i = \sum_{j=1}^n j \mathbf{P}\{R_i = j\} = (1 + \dots + n)/n = \frac{n+1}{2};$$

$$VR_i = \mathbf{E}R_i^2 - (\mathbf{E}R_i)^2 = \frac{(n+1)(2n+1)}{6} - \frac{(n+1)^2}{4} = \frac{n^2 - 1}{12}.$$

III.4.2. Spirmeno ir Kendalo koreliacijos koeficientai (žr. [4], 5.3.1 ir 5.3.2 skyrelius) įgijo reikšmes $r_S = 0,9889$ ir $\tau_b = 0,9422$. Abiejų kriterijų atveju $pv < 0,0001$. Hipotezė atmetama.

III.4.3. Spirmeno ir Kendalo koreliacijos koeficientai įgijo reikšmes $r_S = 0,7822$ ir $\tau_b = 0,6746$. Atitinkamos P reikšmės $pv = 0,0075$ ir $pv = 0,0084$. Hipotezė atmetama.

III.4.4. Spirmeno ir Kendalo koreliacijos koeficientai įgijo reikšmes $r_S = 0,0935$ ir $\tau_b = 0,0621$. Atitinkamos P reikšmės $pv = 0,3547$ ir $pv = 0,3663$. Atmesti hipotezę nėra pagrindo.

III.4.5. Spirmeno ir Kendalo koreliacijos koeficientai įgijo reikšmes $r_S = 0,0643$ ir $\tau_b = 0,0390$. Atitinkamos P reikšmės $pv = 0,4343$ ir $pv = 0,4852$. Atmesti hipotezę nėra pagrindo.

III.4.6. Vilkoksono statistika (žr. [4], 5.5.1 skyrelį) įgijo reikšmę $W = 239$, $Z_{m,n} = -0,0198$; asimptotinė P reikšmė yra $pv_a = 2\Phi(-0,0198) = 0,9842$. Van der Vardeno statistikos (žr. [4], 5.5.4 skyrelį) reikšmė $V = -0,1228$ ir $pv_a = 0,9617$. Atmesti hipotezę nėra pagrindo.

III.4.7. Vilkoksono kriterijaus ASE Stjudento kriterijaus atžvilgiu, kai imties elemento tankio funkcija $f(x)$ yra (žr. [4], 5.5.3 skyrelį)

$$e(W, t) = 12\tau^2 \left[\int_{-\infty}^{\infty} f^2(x) dx \right]^2, \quad \tau^2 = \mathbf{V}X_i.$$

Skirstinio $G(1, \eta)$ atveju gauname

$$e(W, t) = \frac{3\eta}{2^{4(\eta-1)}((2\eta-1)B(\eta, \eta))^2}.$$

III.4.8. Reikia naudoti homogeniškumo kriterijų, kai alternatyva yra mastelio (žr. [4], 5.5.5 skyrelį). Pagal turimus duomenis Zygelio ir Tjukio, Ansario ir Bredlio, Mūdo, Klotso kriterijų statistikų reikšmės: $S_{ZT} = 91,1667$; $S_{AB} = 47,5$; $S_K = 2,2603$; $S_M = 8,9333$ ir atitinkamos P reikšmės $0,0623$; $0,0713$; $0,0320$; $0,0342$. Asimptotinės P reikšmės: $0,0673$; $0,0669$; $0,0371$; $0,0382$. Homogeniškumo hipotezė atmetina.

III.4.9. Kruskalo ir Voliso statistika (žr. [4], 5.8 skyrelį) įgijo reikšmę $F_{KW} = 3,9139$ ir $pv_a = 0,9170$. Atmesti hipotezę nėra pagrindo.

III.4.10. Kruskalo ir Voliso statistika įgijo reikšmę $F_{KW} = 6,5490$ ir $pv_a = 0,0378$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija $0,0378$.

III.4.11. Kendalo konkordancijos koeficiente (žr. [4], 5.10 skyrelį) reikšmė $0,6444$ ir $pv_a = 0,0428$; nepriklausomumo hipotezė atmetama, kai reikšmingumo lygmuo viršija $0,0428$. a) Spirmeno ir Kendalo koreliacijos koeficientai įgijo reikšmes $r_S = 0,2242$ ir $\tau_b = 0,2$; P reikšmės yra $0,5334$ ir $0,4208$. Nepriklausomumo hipotezė neatmetama. b) Spirmeno ir Kendalo koreliacijos koeficientai įgijo reikšmes $r_S = 0,9879$ ir $\tau_b = 0,9556$; P reikšmės abiems atvejais yra $pv < 0,00001$. Nepriklausomumo hipotezė atmetama.

III.4.12. Ranginio ženklų kriterijaus statistikos (žr. [4], 5.6 skyrelj) reikšmė yra $T^+ = 69,5$ ir $pv = 0,0989$. Homogeniškumo hipotezė atmetama, jei reikšmingumo lygmuo viršija 0,0989.

III.4.13. Ranginio ženklų kriterijaus statistikos reikšmė yra $T^+ = 43$ ir $pv = 0,0117$. Homogeniškumo hipotezė atmetama, jei reikšmingumo lygmuo viršija 0,0117.

III.4.14. Frydmano statistika (žr. [4], 5.9 skyrelj) įgijo reikšmę $S_F = 2,5957$; asimptotinė P reikšmė $pv_a = 0,2731$. Duomenys neprieštarauja iškeltai hipotezei.

III.5. Kiti neparametriniai kriterijai

III.5.1. Pratimai

III.5.1. Remdamiesi ženklų kriterijumi patikrinkite hipotezę apie dviejų krakmolo kiekio nustatymo būdų ekvivalentiškumą pagal **III.4.2** pratimo duomenis.

III.5.2. Remdamiesi ženklų kriterijumi patikrinkite hipotezę apie dviejų sėjamųjų vienodą efektyvumą pagal **III.4.3** pratimo duomenis.

III.5.3. Remdamiesi serijų skaičiumi grindžiamu kriterijumi, patikrinkite hipotezę apie nuodų poveikio vienodus pagal **III.3.15** pratimo duomenis.

III.5.4. Naudodami serijų kriterijų patikrinkite atsitiktinumo hipotezę pagal **II.1.18** pratimo duomenis.

III.5.5. Naudodami serijų kriterijų patikrinkite atsitiktinumo hipotezę pagal **II.1.19** pratimo duomenis.

III.5.6. Visuomenės nuomonės apklausoje tų pačių 3000 rinkėjų buvo klausama dėl jų nuomonės apie konkrečią parlamentinę partiją prieš rinkimus ir po jų. Prieš rinkimus neigiamą nuomonę išsakė 300 rinkėjų, o praėjus metams po rinkimų – 350. Be to, 150 rinkėjų nepakeitė savo neigiamos nuomonės, 150 rinkėjų neigama nuomonė pasikeitė į teigiamą, o 200 rinkėjų teigama nuomonė pasikeitė į neigiamą. Ar pakito partijos reitingas?

III.5.7. (**III.5.6** pratimo tēsinys). Tarkime, kad tie patys 3000 rinkėjų buvo apklausti prieš kitus rinkimus. 270 rinkėjų nuomonė buvo neigama. Iš jų 180 rinkėjų buvo tokiai, kurie pirmose dviejose apklausose turėjo teigiamą nuomonę, ir 70 rinkėjų, kurių nuomonė buvo teigama vienoje ir neigama kitaip iš pirmiau buvusių apklausų. Ar pakito partijos reitingas?

III.5.8. Tegu X_1, \dots, X_n yra paprastoji imtis a. d. $X \sim N(\mu, \sigma^2)$ ir $Y_i = X_{i+1} - X_1/(1 + \sqrt{n}) - n\bar{X}/(n + \sqrt{n})$. Irodykite, kad Y_1, \dots, Y_{n-1} yra vienodai pasiskirstę n. a. d. ir $Y_j \sim N(0, \sigma^2)$.

III.5.9. (**III.5.8** pratimo tēsinys). Irodykite, kad Z_1, \dots, Z_{n-2} yra nepriklausomi a. d., turintys Stjudento skirstinius $Z_j \sim S(n - j - 1)$, jei $Z_j = Y_j\sqrt{n - j - 1}/(Y_{j+1}^2 + \dots + Y_{n-1}^2)$.

III.5.10. Patikrinkite normalumo hipotezę naudodami [4], 6.5.1 skyrelio kriterijus pagal **II.1.18** pratimo duomenis.

III.5.11. Patikrinkite lognormalumo hipotezę naudodami [4], 6.5.1 skyrelio kriterijus pagal **II.1.19** pratimo duomenis.

III.5.12. Patikrinkite puasoniškumo hipotezę naudodami tuščių dėžių kriterijų pagal II.1.26 pratimo duomenis.

III.5.2. Sprendimai, atsakymai, nurodymai

III.5.1. Tarp 13 skirtumų $S = 3$ yra neigiami ir $pv = 2\mathbf{P}\{S \leq 3\} = 0,0923$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0923.

III.5.2. Tarp 9 skirtumų $S = 1$ yra neigiamas ir $pv = 2\mathbf{P}\{S \leq 1\} = 0,0391$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0195.

III.5.3. Tikrinant homogeniškumo hipotezę remiantis serijų skaičiumi dažniausiai hipotezė atmetama, kai serijų skaičius mažas. Tačiau per didelis serijų skaičius irgi liudija apie nukrypimą nuo atsitiktinio stebinių išsidėstymo. Šiame pavyzdyste serijų skaičius $V = 29$ aiškiai per daug didelis. Natūralu hipotezę atesti, kai $V \geq 29$; P reikšmė $pv = \mathbf{P}\{V \geq 29\} = 1,2 \cdot 10^{-6}$. Hipotezė atmetama.

III.5.4. Serijų skaičius $V = 54$, $k_1 = 50$, $k_2 = 50$. Gauname $Z_{k_1, k_2}^* = 0,5025$ ir $pv_a = 2(1 - \Phi(0,5025)) = 0,6153$. Atesti hipotezę nėra pagrindo.

III.5.5. Serijų skaičius $V = 90$, $k_1 = 76$, $k_2 = 74$. Gauname $Z_{k_1, k_2}^* = 2,4906$ ir $pv_a = 2(1 - \Phi(2,4906)) = 0,0128$. Hipotezė atmetama, jei kriterijaus reikšmingumo lygmuo viršija 0,0128.

III.5.6. Naudojame Maknemaros kriterijų. Rinkėjų, kurių nuomonė pakito iš teigiamos į neigiamą, skaičius yra 200, o iš neigiamos į teigiamą – 150. Tikrinama hipotezė $H : p = 1/2$ apie binominio skirstinio tikimybę, kai Bernulio eksperimentų skaičius yra $U_{01} + U_{10} = 350$, o sėkmų skaičius yra $U_{10} = 150$. Gauname $pv = 2 \min(\mathbf{P}\{U_{10} \leq 150\}, \mathbf{P}\{U_{10} \geq 150\}) = 0,0087$. Hipotezė at mestina.

III.5.7. Duomenų pakanka, kad būtų galima apskaičiuoti Kochreno statistikos (žr. [4], 6.4 skyrelį) reikšmę. Žymėkime ženklu + teigiamą rinkėjo nuomonę ir ženklu – neigiamą nuomonę. Tada rinkėjų, kurių nuomonė buvo ++ – yra 180; + – – arba – + – yra 70, tai – – – yra 20, o – – + yra 130; rinkėjų + + + skaičius yra $2500 - 180 = 2320$, + – + arba – + + yra 280. Iš čia gauname $x_{01} = 300$, $x_{02} = 350$, $x_{03} = 270$. Be to, yra 20 rinkėjų, kuriems $x_i = 3$, 200 rinkėjų, kuriems $x_i = 2$, 460 rinkėjų, kuriems $x_i = 1$, ir 2320 rinkėjų, kuriems $x_i = 0$. Gauname $3\bar{X}^2 = 920^2/3$. Statistikos Q skaitiklio reikšmė yra $3 \cdot 2(300^2 + 350^2 + 270^2 - 920^2/3)$, o vardiklio reikšmė $3(3 \cdot 20 + 2 \cdot 200 + 460) - (9 \cdot 20 + 4 \cdot 200 + 460)$. Gauname statistikos Q realizaciją $Q = 14,8485$ ir $pv_a = \mathbf{P}\{\chi_2^2 > 14,8485\} = 0,0006$. Hipotezė at mestina.

III.5.8. Reikia patikrinti, kad $\mathbf{V}Y_j = \sigma^2$, $\mathbf{Cov}(Y_i, Y_j) = 0, i \neq j$.

III.5.9. Reikia pasiremti Stjudento skirstinio apibrėžimu ir tuo, kad Y_1, \dots, Y_{n-1} yra n. a. d. ir $Y_i \sim N(0, \sigma^2)$.

III.5.10. Gauname statistikų realizacijas: $\bar{g}_1 = 2,1598$, $\bar{g}_2 = 0,1524$, $\bar{g}_3 = -1,0849$ ir jas atitinkančias asimptotines P reikšmes 0,0308, 0,8788, 0,2779. Remdamiesi empiriniu asimetrijos koeficientu hipotezė atmetame, jei kriterijaus reikšmingumo lygmuo viršija 0,0308. Atlikę Sarkadi transformaciją gauname paprastąja a. d. $Z \sim U(0, 1)$ imtį Z_1, \dots, Z_{n-2} . Taikydami Pirsono chi kvadrato kriterijų hipotezei $H : Z \sim U(0, 1)$ tikrinti ir parinkę $k = 8$ vienodų tikimybių intervalus, gauname $X_n^2 = 5,5102$ ir $pv_a = 0,5980$.

Kolmogorovo ir Smirnovo, Kramerio ir Mizeso, Anderseno ir Darlingo kriterijų statistikos įgijo reikšmes 0,1071, 0,2629, 1,6185. Normalumo hipotezė neatmetama. Šapiro ir Vilkso statistika įgijo reikšmę 0,9716 ir ją atitinkanti P reikšmė yra 0,0293. Šapiro ir Vilkso kriterijus atmeta normalumo hipotezę, jei kriterijaus reikšmingumo lygmuo viršija 0,0293.

III.5.11. Perėję prie logaritmų gauname statistikų realizacijas: $\bar{g}_1 = 0,5901$, $\bar{g}_2 = 0,8785$, $\bar{g}_3 = 0,3765$ ir jas atitinkančias asimptotines P reikšmes 0,5551, 0,3797, // 0,7065. Kriterijai, grindžiami empirinių momentų funkcijomis, lognormalumo hipotezės neatmeta. Atlikę Sarkadi transformaciją gauname paprastąjį a. d. $Z \sim U(0, 1)$ imtį Z_1, \dots, Z_{n-2} . Taikydami Pirsono chi kvadrato kriterijų hipotezei $H : Z \sim U(0, 1)$ tikrinti ir parinkę $k = 10$ vienodų tikimybių intervalų, gauname $X_n^2 = 6,1892$ ir $p_{Va} = 0,7208$. Kolmogorovo ir Smirnovo, Kramerio ir Mizeso ir Anderseno ir Darlingo kriterijų statistikos įgijo reikšmes 0,0548, 0,0752, 0,5594. Atitinkamos P reikšmės viršija 0,25. Lognormalumo hipotezė neatmetama. Šapiro ir Vilkso statistika įgijo reikšmę 0,9920 ir ją atitinkanti P reikšmė yra 0,5644. Šapiro ir Vilkso kriterijus lognormalumo hipotezės taip pat neatmeta.

III.5.12. a) Tuščių dėžių skaičius $Z_0^{(i)}$, $i = 1, 2, 3, 4$, yra 280, 593, 639, 359. Apskaičiavę $\mathbf{E}(Z_0^{(i)})$, $\mathbf{V}(Z_0^{(i)})$ randame $\bar{Z}_0^{(i)}$ realizacijas: 0,399; 0,937; -0,947; -0,826 ir jas atitinkančias asimptotines P reikšmes 0,345; 0,174; 0,828; 0,796. Atmesti hipotezes nėra pagrindo. b) Tuščių dėžių skaičius Z_0 jungtinėje imtyje 1871. Randame $\bar{Z}_0 = -0,107$ ir $p_{Va} = 0,543$. Hipotezė neatmetama.

1 priedas. Pagalbinės lentelės

1.P.1 lentelė. Pateikiama pagrindinių žinių apie dažnai naudojamus diskrečiuosius tikimybinius skirstinius.

1.P.2 lentelė. Pateikiama pagrindinių žinių apie dažnai naudojamus absoliučiai tolydžiuosius skirstinius.

Naudojami trumpiniai: nat. sk. – natūralusis skaičius; sv. nen. sk. – sveikasis neneigiamas skaičius; brūkšnys parodo, kad funkcija neturi paprastos išraiškos.

1.P.3 lentelė. Pateikiama žinių apie tikimybinių skirstinių sąryšius.

1.P.1 lentelė. Diskretieji tikimybiniai skirstiniai

Skirstinys	Parametrai	$\mathbf{P}\{X = k\}$	Vidurkis	Dispersija	Generuojančioji funkcija
Binominis	$0 < p < 1$, n -nat.sk.	$C_n^k p^k (1-p)^{n-k},$ $k = 0, \dots, n$	np	$np(1-p)$	$(1-p+ps)^n$
Geometrinis	$0 < p < 1$	$p(1-p)^{k-1},$ $k = 1, 2, \dots$	$\frac{1}{p}$	$\frac{q}{p^2}$	$\frac{ps}{1-qs}$
Paskalio	$0 < p < 1$, n -nat.sk.	$C_{n+k-1}^k p^n (1-p)^k$ $k = 0, 1, \dots$	$\frac{n(1-p)}{p}$	$\frac{n(1-p)}{p^2}$	$\left(\frac{p}{1-qs}\right)^n$
Neigiamasis binominis	$0 < p < 1$, $n > 0$	$\frac{\Gamma(n+k)}{k! \Gamma(n)} p^n (1-p)^k$ $k = 0, 1, \dots$	$\frac{n(1-p)}{p}$	$\frac{n(1-p)}{p^2}$	$\left(\frac{p}{1-qs}\right)^n$
Apibendrintas binominis	$\gamma, \eta > 0$, n -nat.sk.	$C_n^k \frac{\Gamma(\gamma+\eta)\Gamma(k+\gamma)\Gamma(n-k+\eta)}{\Gamma(\eta)\Gamma(\gamma)\Gamma(n+\gamma+\eta)}$ $k = 0, 1, \dots, n$	$n \frac{\gamma}{\gamma+\eta}$	$n \frac{\gamma\eta(\gamma+\eta+n)}{(\gamma+\eta)^2(\gamma+\eta+1)}$	—
Hipergeometrinis	N, M, n -nat.sk. $M \leq N, n \leq N$	$\frac{C_M^k C_{N-M}^{n-k}}{C_N^n}, k \leq \min(n, M)$ $\max(0, n - N + m) \leq k$	$\frac{nM}{N}$	$np(1-p) \frac{(N-n)}{(N-1)}$ $p = M/N$	—
Neigiamasis hipergeometr.	N, M, n -nat.sk. $M \leq N, n \leq N$	$\frac{C_{n+k-1}^{n-1} C_{N-n-k}^M}{C_N^k}$ $k = 0, 1, \dots, N - M$	$\frac{n(N-M)}{M+1}$	žr. (2.25)	—
Pojos	$b, r, c > 0$	žr. (2.27)	$\frac{nb}{b+r}$	$\frac{nrb(r+nc)}{(b+r)^2(b+r+c)}$	—
Puasono	$\lambda > 0$	$\frac{\lambda^k}{k!} e^{-\lambda},$ $k = 0, 1, 2, \dots$	λ	λ	$e^{-\lambda(1-s)}$
Sudėtingasis Puasono	$t > 0$, $\lambda > 0$	—	$\lambda t \psi'(1)$	$\lambda t(\psi'(1) + \psi''(1))$	$e^{-\lambda t(1-\psi(s))}$
Logaritminis	$0 < p < 1$	$-\frac{1}{\ln p} \frac{q^k}{k}, \quad k = 1, 2, \dots$	$-\frac{q}{p \ln p}$	$-\frac{q}{p^2 \ln p} (1 + \frac{q}{\ln p})$	$\frac{\ln(1-sq)}{\ln p}$
Polinominis	$0 < \pi_i < 1$, n -nat.sk. $\pi_1 + \dots + \pi_k = 1$	$\frac{n!}{m_1! \dots m_k!} \pi_1^{m_1} \dots \pi_k^{m_k}$ $0 \leq m_i \leq n, m_1 + \dots + m_k = n$	$n\pi$	$\sigma_{ii} = n\pi_i(1 - \pi_i),$ $\sigma_{ij} = -n\pi_i\pi_j, i \neq j$	$(\pi_1 s_1 + \dots + \pi_k s_k)^n$
Daugiamatis hipergeometr.	N, M_1, \dots, M_k, n -nat.sk.; $\sum_i M_i = N$	$\frac{C_{M_1}^{m_1} \dots C_{M_k}^{m_k}}{C_N^n}$	$\frac{n}{N} M$	$\sigma_{ii} = np_i(1 - p_i)(N - n)/(N - 1),$ $\sigma_{ij} = np_i p_j (N - n)/(N - 1), i \neq j$	—

1.P.2 lentelė. Tolydieji tikimybiniai skirstinai

Skirstinys	Parametrai	Tankis	Vidurkis	Dispersija	Charakteristinė funkcija
Normalusis	$-\infty < \mu < \infty$, $0 < \sigma < \infty$	$\frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}$ $-\infty < x < \infty$	μ	σ^2	$\exp\{\mu t - \frac{t^2\sigma^2}{2}\}$
Pusiau normalusis	$0 < \sigma < \infty$	$\frac{2}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{x^2}{2\sigma^2}\right\}, \quad x > 0$	$\sigma\sqrt{\frac{2}{\pi}}$	$\sigma^2(1 - \frac{2}{\pi})$	$2e^{-\frac{t^2\sigma^2}{2}} \Phi(it\sigma)$
Relėjaus	$0 < \sigma < \infty$	$\frac{x}{\sigma^2} \exp\left\{-\frac{x^2}{2\sigma^2}\right\}, \quad x > 0$	$\sigma\sqrt{\frac{\pi}{2}}$	$\sigma^2(2 - \frac{\pi}{2})$	—
Maksvelo	$0 < \sigma < \infty$	$\sqrt{\frac{2}{\pi}} \frac{x^2}{\sigma^3} \exp\left\{-\frac{x^2}{2\sigma^2}\right\}, \quad x > 0$	$2\sqrt{\frac{2}{\pi}}$	$\frac{3\pi-8}{\pi}$	—
Lognormalusis	$-\infty < \mu < \infty$ $0 < \sigma < \infty$	$\frac{1}{\sqrt{2\pi}\sigma x} \exp\left\{-\frac{(\ln x - \mu)^2}{2\sigma^2}\right\}$ $x > 0$	$e^{\mu + \frac{\sigma^2}{2}}$	$e^{2\mu + \sigma}(e^{\sigma^2} - 1)$	—
Koši	$-\infty < \mu < \infty$ $0 < \sigma < \infty$	$\frac{1}{\pi} \frac{\sigma}{\sigma^2 + (x-\mu)^2}$ $-\infty < x < \infty$	neegzistuoja	neegzistuoja	$e^{i\mu t - \sigma t }$
Chi kvadrato	n – nat.sk.	$\frac{1}{2^{n/2}\Gamma(n/2)} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, \quad x > 0$	n	$2n$	$\frac{1}{(1-2it)^{n/2}}$
Necentrinis chi kvadrato	n – nat.sk. $\delta > 0$	žr. (3.18)	$n + \delta$	$2(n + 2\delta)$	$\frac{\exp\{it\sqrt{\delta-t^2}/2\}}{(1-2it)^{(n-1)/2}}$
Stjudento	n – nat.sk.	$\frac{\Gamma((n+1)/2)}{\sqrt{n\pi}\Gamma(n/2)} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$ $-\infty < x < \infty$	$0,$ $n > 1$	$\frac{n}{n-2},$ $n > 2$	—
Necentrinis Stjudento	n – nat.sk. $-\infty < \mu < \infty$	žr. (3.23)	$\mu M_n, \quad M_n = \sqrt{\frac{n}{2}} \times \frac{\Gamma((n-1)/2)}{\Gamma(n/2)}, \quad n > 1$	$\frac{n}{n-2} +$ $+ \mu^2 (\frac{n}{n-2} - M_n^2), \quad n > 2$	—
Fišerio	m – nat.sk. n – nat.sk.	$\frac{\Gamma((m+n)/2)}{\Gamma(m/2)\Gamma(n/2)} m^{\frac{m}{2}} n^{\frac{n}{2}} \times$ $\times x^{\frac{m}{2}-1} (n + mx)^{-\frac{m+n}{2}}$	$\frac{nm}{n-2},$ $n > 2$	$\frac{2n^2(n+m-2)}{m(n-2)^2(n-4)},$ $n > 4$	—
Necentrinis Fišerio	m, n – nat.sk. $\delta > 0$	žr. (3.27)	$\frac{n(m+\delta)}{n-2},$ $n > 2$	$2n^2 (\frac{m+2\delta}{(n-2)(n-4)} +$ $+ \frac{2(m+\delta)^2}{(n-2)^2(n-4)}), \quad n > 4$	—
Gama	$\lambda > 0, \quad \eta > 0$	$\frac{\lambda^\eta}{\Gamma(\eta)} x^{\eta-1} e^{-\lambda x}, \quad x > 0$	$\frac{\eta}{\lambda}$	$\frac{\eta}{\lambda^2}$	$\left(\frac{\lambda}{\lambda-it}\right)^\eta$
Eksponentinis	$\lambda > 0$	$\lambda e^{-\lambda x}, \quad x > 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$	$\frac{\lambda}{\lambda-it}$
Paslinktasis eksponentinis	$\lambda > 0,$ $-\infty < \mu < \infty$	$\lambda e^{-\lambda(x-\mu)},$ $\mu < x < \infty$	$\mu + \frac{1}{\lambda}$	$\frac{1}{\lambda^2}$	$e^{i\mu t} \frac{\lambda}{\lambda-it}$

1.P.2 lentelės tėsinys. Tolydieji tikimybiniai skirstiniai

Skirstinys	Parametrai	Tankis	Vidurkis	Dispersija	Charakteristinė funkcija
Laplaso	$-\infty < \mu < \infty$ $0 < \lambda < \infty$	$\frac{\lambda}{2} e^{-\lambda x-\mu },$ $-\infty < x < \infty$	μ	$\frac{2}{\lambda^2}$	$e^{it\mu} \frac{\lambda^2}{\lambda^2 + t^2}$
Logistinis	$\theta > 0,$ $-\infty < \mu < \infty$	$\frac{1}{\theta} \frac{\exp\{-(x-\mu)/\theta\}}{(1+\exp\{-(x-\mu)/\theta\})^2},$ $-\infty < x < \infty$	μ	$\frac{\theta^2 \pi^2}{3}$	$e^{i\mu t} \Gamma(1+it\theta) \times \Gamma(1-it\theta)$
Pareto	$\theta > 0, \alpha > 0$	$\frac{\theta \alpha^\theta}{x^{\theta+1}}, \quad \alpha < x < \infty$	$\frac{\theta \alpha^2}{\theta - 1}, \quad \theta > 1$	$\frac{\theta \alpha^2}{(\theta - 1)^2(\theta - 2)}, \quad \theta > 2$	—
EkspONENTINIŲ SKIRSTINIŲ MIŠINYS	$0 < \theta_1, \theta_2 < \infty,$ $0 < p_1 < 1,$ $p_2 = 1 - p_1$	$\frac{p_1}{\theta_1} \exp\{-\frac{x}{\theta_1}\} +$ $+ \frac{p_2}{\theta_2} \exp\{-\frac{x}{\theta_2}\},$ $0 < x < \infty$	$\theta_1 p_1 + \theta_2 p_2$	$p_1 \theta_1^2 + p_2 \theta_2^2 +$ $+ p_1 p_2 (\theta_1 - \theta_2)^2$	$\frac{p_1}{1-it\theta_1} + \frac{p_2}{1-it\theta_2}$
Loglogistinis	$\theta > 0, \nu > 0$	$\frac{\nu}{\theta} \left(\frac{x}{\theta}\right)^{\nu-1} \times$ $\times (1 + (x/\theta)^\nu)^{-2}$ $0 < x < \infty$	$\theta \Gamma(1 + 1/\nu) \times$ $\times \Gamma(1 - 1/\nu)$	$\theta^2 (\Gamma(1 + 2/\nu) \Gamma(1 - 2/\nu) - \Gamma^2(1 + 1/\nu)) \times$ $\times \Gamma^2(1 - 1/\nu)$	—
Veibulo	$\eta > 0$ $\sigma > 0$	$\frac{\eta}{\sigma} \left(\frac{x}{\sigma}\right)^{\eta-1} \exp\{-\left(\frac{x}{\sigma}\right)^\eta\}$ $0 < x < \infty$	$\sigma \Gamma\left(\frac{1+\eta}{\eta}\right)$	$\sigma^2 \left(\Gamma\left(\frac{2+\eta}{\eta}\right) - \Gamma^2\left(\frac{1+\eta}{\eta}\right)\right)$	—
Apibendrin-tasis Veibulo	$\theta > 0,$ $\sigma > 0,$ $\gamma > 0$	$\frac{\eta}{\sigma \gamma} \frac{x}{\sigma} [1 + (\frac{x}{\sigma})^\eta]^{(1-\gamma/\gamma)} \times$ $\times \exp\{(1 - (1 + \frac{x}{\sigma})^\eta)^{1/\gamma}\},$ $0 < x < \infty$	—	—	—
Minimaliųjų reikšmių	$-\infty < \mu < \infty,$ $0 < \sigma < \infty$	$\frac{1}{\sigma} \exp\{-\frac{x-\mu}{\sigma} - e^{-\frac{x-\mu}{\sigma}}\}$ $-\infty < x < \infty$	$\mu + \gamma \sigma,$ $\gamma = \Gamma'(1)$	$\frac{(\pi \sigma)^2}{6}$	—
Maksimaliųjų reikšmių	$-\infty < \mu < \infty,$ $0 < \sigma < \infty$	$\frac{1}{\sigma} \exp\{\frac{x-\mu}{\sigma} - e^{\frac{x-\mu}{\sigma}}\}$ $-\infty < x < \infty$	$\mu - \gamma \sigma,$ $\gamma = 0.5772156\dots$	$\frac{(\pi \sigma)^2}{6}$	—
Beta	$\gamma > 0,$ $\eta > 0$	$\frac{\Gamma(\gamma+\eta)}{\Gamma(\gamma)\Gamma(\eta)} x^{\gamma-1} (1-x)^{\eta-1},$ $0 < x < 1$	$\frac{\gamma}{\gamma+\eta}$	$\frac{\gamma \eta}{(\gamma+\eta)^2(\gamma+\eta+1)}$	—
Tolygusis	$\infty < \mu_0 < \mu_1 < \infty$	$\frac{1}{\mu_1 - \mu_0}, \quad \mu_0 < x < \mu_1$	$\frac{\mu_1 + \mu_0}{2}$	$\frac{(\mu_1 - \mu_0)^2}{12}$	$\frac{e^{it\mu_1} - e^{it\mu_0}}{it(\mu_1 - \mu_0)}$
k -matis normalusis	$\boldsymbol{\mu} = (\mu_1, \dots, \mu_k)^T,$ $\boldsymbol{\Sigma} = [\sigma_{ij}]_{k \times k}$	$\frac{1}{(\sqrt{2\pi})^k \sqrt{ \boldsymbol{\Sigma} }} \exp\{-\frac{1}{2} \times$ $\times (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\}$	$\boldsymbol{\mu}$	$\boldsymbol{\Sigma}$	$e^{i(\mathbf{t}^T \boldsymbol{\mu}) - \mathbf{t}^T \boldsymbol{\Sigma} \mathbf{t}/2},$ $\mathbf{t} \in \mathbf{R}^k$

1.P.3 lentelė. Tikimybinių skirstinių sąryšiai

Atsitiktinis dydis	Funkcija	Funkcijos skirstinys
$X \sim N(\mu, \sigma^2)$	$Y = \frac{X-\mu}{\sigma}$	$Y \sim N(0, 1)$
$X \sim N(0, 1)$	$Y = X^2$	$Y \sim \chi^2(1); Y \sim F(1, \infty)$
$X_i \sim N(0, 1), i = 1, \dots, n$	$Y = X_1^2 + \dots + X_n^2$	$Y \sim \chi^2(n)$
$Z \sim N(0, 1), X_i \sim N(0, 1), i = 1, \dots, n$	$Y = \frac{Z}{\sqrt{(X_1^2 + \dots + X_n^2)/n}}$	$Y \sim S(n)$
$Z_i \sim N(0, 1), i = 1, \dots, m, X_j \sim N(0, 1), j = 1, \dots, n$	$Y = \frac{(Z_1^2 + \dots + Z_m^2)/m}{(X_1^2 + \dots + X_n^2)/n}$	$Y \sim F(m, n)$
$X_1 \sim G(\lambda, \eta_1), X_2 \sim G(\lambda, \eta_2)$	$Y = \frac{X_1}{X_1 + X_2}$	$Y \sim Be(\eta_1, \eta_2)$
$X \sim G(\lambda, \eta)$	$Y = 2\lambda X$	$Y \sim \chi^2(2\eta)$
$X_1 \sim \chi^2(n_1), X_2 \sim \chi^2(n_2)$	$Y = \frac{X_1}{X_1 + X_2}$	$Y \sim Be(\frac{n_1}{2}, \frac{n_2}{2})$
$X_1 \sim G(\lambda, \eta_1), X_2 \sim G(\lambda, \eta_2)$	$Y = \frac{\eta_2 X_1}{\eta_1 X_2}$	$Y \sim F(2\eta_1, 2\eta_2)$
$X \sim F(m, n)$	$Y = \frac{mX}{n+mX}$	$Y \sim Be(\frac{m}{2}, \frac{n}{2})$
$X \sim S(n)$	$Y = X^2$	$Y \sim F(1, n)$
$X \sim U(0, 1)$	$Y = -\frac{\ln X}{\lambda}$	$Y \sim \mathcal{E}(\lambda)$
$X \sim S(n)$	$Y = \frac{n}{n+X^2}$	$Y \sim Be(\frac{n}{2}, \frac{1}{2})$
$X_i \sim N(\mu_i, \sigma_i^2), i = 1, \dots, n$	$Y = c_1 X_1 + \dots + c_n X_n$	$Y \sim N(\mu, \sigma), \mu = \sum_i c_i \mu_i, \sigma^2 = \sum_i c_i^2 \sigma_i^2$
$X_i \sim \chi^2(n_i), i = 1, \dots, k$	$Y = X_1 + \dots + X_k$	$Y \sim \chi^2(n), n = n_1 + \dots + n_k$
$X_i \sim \mathcal{P}(\lambda_i), i = 1, \dots, n$	$Y = X_1 + \dots + X_n$	$Y \sim \mathcal{P}(\lambda), \lambda = \lambda_1 + \dots + \lambda_n$
$X_i \sim B(n_i, p), i = 1, \dots, k$	$Y = X_1 + \dots + X_k$	$Y \sim B(n, p), n = n_1 + \dots + n_k$
$X_i \sim B^-(n_i, p), i = 1, \dots, k$	$Y = X_1 + \dots + X_k - k + 1$	$Y \sim B^-(n, p), n = n_1 + \dots + n_k - k + 1$
$X_i \sim \mathcal{E}(\lambda), i = 1, \dots, n$	$Y = X_1 + \dots + X_n$	$Y \sim G(\lambda, n),$
$X_i \sim G(\lambda, \eta_i), i = 1, \dots, n$	$Y = X_1 + \dots + X_n$	$Y \sim G(\lambda, \eta), \eta = \eta_1 + \dots + \eta_n$
$X_i \sim K(\mu_i, \sigma_i), i = 1, \dots, n$	$Y = X_1 + \dots + X_n$	$Y \sim K(\mu, \sigma), \mu = \sum_i \mu_i, \sigma = \sum_i \sigma_i$
$X_i \sim K(\mu, \sigma), i = 1, \dots, n$	$Y = \bar{X} = \frac{X_1 + \dots + X_n}{n}$	$Y \sim K(\mu, \sigma),$

Pastaba. Bet kurios funkcijos išraiškoje a. d. laikomi nepriklausomais.

2 priedas. Matematinės statistikos lentelės

2.P.1 lentelė. Nurodytos funkcijos $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp\{-\frac{t^2}{2}\} dt$ reikšmės, kai $x = 0,00$ ($0,01$) $4(0,1)4,9$. Dėl kompaktišumo devynetai, esantys po kablelio, nerašomi, o tik nurodomas jų skaičius. Pavyzdžiu, $\Phi(3,76) = 0,9^415 = 0,999915$. Kadangi skirstinys $N(0, 1)$ simetrinis taško $x = 0$ atžvilgiu, tai $\Phi(-x) = 1 - \Phi(x)$.

2.P.2 lentelė. Pateikiamos standartinio normaliojo skirstinio $N(0, 1)$ P -osios kritinės reikšmės z_P (abscisių ašies taškai, tenkinantys lygtį $\Phi(z_P) = 1 - P$, t.y. $z_P = \Phi^{-1}(1 - P)$), kai $P = 0,0010$ ($0,0001$) $0,003$ ($0,001$) $0,10$ ($0,01$) $0,49$. Jeigu $Q > 0,5$, tai iš pasiskirstymo simetrijos gauname, kad $z_Q = -z_{1-Q}$.

2.P.3 lentelė. Pateikiamos $\chi^2(n)$ skirstinio P -osios kritinės reikšmės $\chi_P^2(n)$, t.y. abscisių ašies taškai, tenkinantys lygtį

$$\int_{\chi_P^2(n)}^{\infty} f(x; n) dx = P;$$

čia $f(x; n)$ – skirstinio $\chi^2(n)$ tikimybinio tankio funkcija. Argumentų reikšmės yra šios: $n = 1(1)20(2)40$ (5) $90(10)100$; $P = 0,0005, 0,0001, 0,01, 0,025, 0,05, 0,10, 0,20, 0,80, 0,90, 0,95, 0,975, 0,99, 0,995, 0,999, 0,9995$.

2.P.4 lentelė. Pateikiamos Stjudento skirstinio $S(n)$ P -osios kritinės reikšmės $t_P = t_P(n)$, t.y. lygties

$$\mathbf{P}\{T_n > x\} = \int_{t_P}^{\infty} f(x|n) dx = P$$

sprendiniai; čia $f(x|n)$ – Stjudento skirstinio su n laisvės laipsnių tikimybinio tankio funkcija. Argumentų reikšmės yra šios: $n = 1(1)20(2)30(4)50(10)100(100)500$; $P = 0,0005, 0,001, 0,0025, 0,005, 0,01, 0,025, 0,05, 0,1, 0,25$. Paskutinėje eilutėje ($n = \infty$) yra standartinio normaliojo skirstinio kritinės reikšmės z_P . Naudojantis 2.P.4 lentele, reikia prisiminti, kad dėl simetrijos $t_P(n) = -t_{1-P}(n)$.

2.P.5 lentelė. Pateikiamos Fišerio skirstinio $F(m, n)$ P -osios kritinės reikšmės, kai $P = 0,05$, t.y. lygties

$$\int_{F_P(m,n)}^{\infty} f(x|m, n) dx = 0,05$$

sprendiniai; čia $f(x|m, n)$ – Fišerio skirstinio su m ir n laisvės laipsnių tikimybinio tankio funkcija. Argumentų reikšmės yra šios: $m = 1(1)10; 12; 15; 20; 24; 30; 40; 60; 120; \infty$; $n = 1(1)30(10)80; 100; 150; 200; 500; \infty$. Kai $n = \infty$, tai $F_P(m, n) = \chi_P^2(m)/m$, žr. 2.P.3 lentelę. Pasinaudojus lygybe $F_P(m, n)F_{1-P}(n, m) = 1$, iš 2.P.2 lentelės galima rasti Fišerio skirstinio kritines reikšmes, kai $P = 0,95$.

2.P.1 lentelė. Standartinio normaliojo skirstinio pasiskirstymo funkcijos reikšmės

x	0	1	2	3	4	5	6	7	8	9
0,0	0,5000	0,5040	0,5080	0,5120	0,5160	0,5199	0,5239	0,5279	0,5319	0,5359
0,1	0,5398	0,5438	0,5478	0,5517	0,5557	0,5596	0,5636	0,5675	0,5714	0,5753
0,2	0,5793	0,5832	0,5871	0,5910	0,5948	0,5987	0,6026	0,6064	0,6103	0,6141
0,3	0,6179	0,6217	0,6255	0,6293	0,6331	0,6368	0,6406	0,6443	0,6480	0,6517
0,4	0,6554	0,6591	0,6628	0,6664	0,6700	0,6736	0,6772	0,6808	0,6844	0,6879
0,5	0,6915	0,6950	0,6985	0,7019	0,7054	0,7088	0,7123	0,7157	0,7190	0,7224
0,6	0,7257	0,7291	0,7324	0,7357	0,7389	0,7422	0,7454	0,7486	0,7517	0,7549
0,7	0,7580	0,7611	0,7642	0,7673	0,7704	0,7734	0,7764	0,7794	0,7823	0,7852
0,8	0,7881	0,7910	0,7939	0,7967	0,7995	0,8023	0,8051	0,8078	0,8106	0,8133
0,9	0,8159	0,8186	0,8212	0,8238	0,8264	0,8289	0,8315	0,8340	0,8365	0,8389
1,0	0,8413	0,8438	0,8461	0,8485	0,8508	0,8531	0,8554	0,8577	0,8599	0,8621
1,1	0,8643	0,8665	0,8686	0,8708	0,8729	0,8749	0,8770	0,8790	0,8810	0,8830
1,2	0,8849	0,8869	0,8888	0,8907	0,8925	0,8944	0,8962	0,8980	0,8997	0,9015
1,3	0,9032	0,9049	0,9066	0,9082	0,9099	0,9115	0,9131	0,9147	0,9162	0,9177
1,4	0,9192	0,9207	0,9222	0,9236	0,9251	0,9265	0,9279	0,9292	0,9306	0,9319
1,5	0,9332	0,9345	0,9357	0,9370	0,9382	0,9394	0,9406	0,9418	0,9429	0,9441
1,6	0,9452	0,9463	0,9474	0,9484	0,9495	0,9505	0,9515	0,9525	0,9535	0,9545
1,7	0,9554	0,9564	0,9573	0,9582	0,9591	0,9599	0,9608	0,9616	0,9625	0,9633
1,8	0,9641	0,9649	0,9656	0,9664	0,9671	0,9678	0,9686	0,9693	0,9699	0,9706
1,9	0,9713	0,9719	0,9726	0,9732	0,9738	0,9744	0,9750	0,9756	0,9761	0,9767
2,0	0,9772	0,9778	0,9783	0,9788	0,9793	0,9798	0,9803	0,9808	0,9812	0,9817
2,1	0,9821	0,9826	0,9830	0,9834	0,9838	0,9842	0,9846	0,9850	0,9854	0,9857
2,2	0,9861	0,9864	0,9868	0,9871	0,9875	0,9878	0,9881	0,9884	0,9887	0,9890
2,3	0,9893	0,9896	0,9898	0,9901	0,9904	0,9906	0,9909	0,9911	0,9913	0,9916
2,4	0,9918	0,9920	0,9922	0,9925	0,9927	0,9929	0,9931	0,9932	0,9934	0,9936
2,5	0,9938	0,9940	0,9941	0,9943	0,9945	0,9946	0,9948	0,9949	0,9951	0,9952
2,6	0,9953	0,9955	0,9956	0,9957	0,9959	0,9960	0,9961	0,9962	0,9963	0,9964
2,7	0,9965	0,9966	0,9967	0,9968	0,9969	0,9970	0,9971	0,9972	0,9973	0,9974
2,8	0,9974	0,9975	0,9976	0,9977	0,9977	0,9978	0,9979	0,9979	0,9980	0,9981
2,9	0,9981	0,9982	0,9982	0,9983	0,9984	0,9984	0,9985	0,9985	0,9986	0,9986
3,0	0,9987	0,9987	0,9987	0,9988	0,9988	0,9989	0,9989	0,9989	0,9990	0,9990
3,1	0,9 ³ 03	0,9 ³ 06	0,9 ³ 10	0,9 ³ 13	0,9 ³ 16	0,9 ³ 18	0,9 ³ 21	0,9 ³ 24	0,9 ³ 26	0,9 ³ 29
3,2	0,9 ³ 31	0,9 ³ 34	0,9 ³ 36	0,9 ³ 38	0,9 ³ 40	0,9 ³ 42	0,9 ³ 44	0,9 ³ 46	0,9 ³ 48	0,9 ³ 50
3,3	0,9 ³ 52	0,9 ³ 53	0,9 ³ 55	0,9 ³ 57	0,9 ³ 58	0,9 ³ 60	0,9 ³ 61	0,9 ³ 62	0,9 ³ 64	0,9 ³ 65
3,4	0,9 ³ 66	0,9 ³ 68	0,9 ³ 69	0,9 ³ 70	0,9 ³ 71	0,9 ³ 72	0,9 ³ 73	0,9 ³ 74	0,9 ³ 75	0,9 ³ 76
3,5	0,9 ³ 77	0,9 ³ 78	0,9 ³ 78	0,9 ³ 79	0,9 ³ 80	0,9 ³ 81	0,9 ³ 81	0,9 ³ 82	0,9 ³ 83	0,9 ³ 83
3,6	0,9 ³ 84	0,9 ³ 85	0,9 ³ 85	0,9 ³ 86	0,9 ³ 86	0,9 ³ 87	0,9 ³ 87	0,9 ³ 88	0,9 ³ 88	0,9 ³ 89
3,7	0,9 ³ 89	0,9 ³ 90	0,9 ⁴ 00	0,9 ⁴ 04	0,9 ⁴ 08	0,9 ⁴ 12	0,9 ⁴ 15	0,9 ⁴ 18	0,9 ⁴ 22	0,9 ⁴ 25
3,8	0,9 ⁴ 28	0,9 ⁴ 31	0,9 ⁴ 33	0,9 ⁴ 36	0,9 ⁴ 38	0,9 ⁴ 41	0,9 ⁴ 43	0,9 ⁴ 46	0,9 ⁴ 48	0,9 ⁴ 50
3,9	0,9 ⁴ 52	0,9 ⁴ 54	0,9 ⁴ 56	0,9 ⁴ 58	0,9 ⁴ 59	0,9 ⁴ 61	0,9 ⁴ 63	0,9 ⁴ 64	0,9 ⁴ 66	0,9 ⁴ 67
4,0	0,9 ⁴ 68	0,9 ⁴ 79	0,9 ⁴ 87	0,9 ⁵ 15	0,9 ⁵ 46	0,9 ⁵ 66	0,9 ⁵ 79	0,9 ⁵ 87	0,9 ⁶ 21	0,9 ⁶ 52

2.P.2 lentelė. Standartinio normaliojo skirstinio P -osios kritinės reikšmės

P	0	1	2	3	4	5	6	7	8	9
0,001	3,0902	3,0618	3,0357	3,0115	2,9889	2,9677	2,9478	2,9291	2,9112	2,8943
0,002	2,8782	2,8627	2,8480	2,8338	2,8202	2,8070	2,7943	2,7822	2,7703	2,7589
0,003	2,7478	2,7370	2,7266	2,7164	2,7065	2,6968	2,6874	2,6783	2,6693	2,6606
0,004	2,6521	2,6437	2,6356	2,6276	2,6197	2,6121	2,6045	2,5972	2,5899	2,5828
0,005	2,5758	2,5690	2,5622	2,5556	2,5491	2,5427	2,5364	2,5302	2,5241	2,5181
0,006	2,5121	2,5063	2,5006	2,4949	2,4893	2,4838	2,4783	2,4730	2,4677	2,4624
0,007	2,4573	2,4522	2,4471	2,4422	2,4372	2,4324	2,4276	2,4228	2,4181	2,4135
0,008	2,4089	2,4044	2,3999	2,3955	2,3911	2,3867	2,3824	2,3781	2,3739	2,3698
0,009	2,3656	2,3615	2,3575	2,3535	2,3495	2,3455	2,3416	2,3378	2,3339	2,3301
0,010	2,3263	2,3226	2,3189	2,3152	2,3116	2,3080	2,3044	2,3009	2,2973	2,2938
0,011	2,2904	2,2869	2,2835	2,2801	2,2768	2,2734	2,2701	2,2668	2,2636	2,2603
0,012	2,2571	2,2539	2,2508	2,2476	2,2445	2,2414	2,2383	2,2353	2,2322	2,2292
0,013	2,2262	2,2232	2,2203	2,2173	2,2144	2,2115	2,2086	2,2058	2,2029	2,2001
0,014	2,1973	2,1945	2,1917	2,1890	2,1862	2,1835	2,1808	2,1781	2,1754	2,1727
0,015	2,1701	2,1675	2,1648	2,1622	2,1596	2,1571	2,1545	2,1520	2,1494	2,1469
0,016	2,1444	2,1419	2,1394	2,1370	2,1345	2,1321	2,1297	2,1272	2,1248	2,1225
0,017	2,1201	2,1177	2,1154	2,1130	2,1107	2,1084	2,1061	2,1038	2,1015	2,0992
0,018	2,0969	2,0947	2,0924	2,0902	2,0880	2,0858	2,0836	2,0814	2,0792	2,0770
0,019	2,0749	2,0727	2,0706	2,0684	2,0663	2,0642	2,0621	2,0600	2,0579	2,0558
0,020	2,0537	2,0517	2,0496	2,0476	2,0456	2,0435	2,0415	2,0395	2,0375	2,0355
0,021	2,0335	2,0315	2,0296	2,0276	2,0257	2,0237	2,0218	2,0198	2,0179	2,0160
0,022	2,0141	2,0122	2,0103	2,0084	2,0065	2,0047	2,0028	2,0009	1,9991	1,9972
0,023	1,9954	1,9936	1,9917	1,9899	1,9881	1,9863	1,9845	1,9827	1,9809	1,9791
0,024	1,9774	1,9756	1,9738	1,9721	1,9703	1,9686	1,9669	1,9651	1,9634	1,9617
0,025	1,9600	1,9583	1,9566	1,9549	1,9532	1,9515	1,9498	1,9481	1,9465	1,9448
0,026	1,9431	1,9415	1,9398	1,9382	1,9366	1,9349	1,9333	1,9317	1,9301	1,9284
0,027	1,9268	1,9252	1,9236	1,9220	1,9205	1,9189	1,9173	1,9157	1,9142	1,9126
0,028	1,9110	1,9095	1,9079	1,9064	1,9048	1,9033	1,9018	1,9003	1,8987	1,8972
0,029	1,8957	1,8942	1,8927	1,8912	1,8897	1,8882	1,8867	1,8852	1,8837	1,8823
0,03	1,8808	1,8663	1,8522	1,8384	1,8250	1,8119	1,7991	1,7866	1,7744	1,7624
0,04	1,7507	1,7392	1,7279	1,7169	1,7060	1,6954	1,6849	1,6747	1,6646	1,6546
0,05	1,6449	1,6352	1,6258	1,6164	1,6072	1,5982	1,5893	1,5805	1,5718	1,5632
0,06	1,5548	1,5464	1,5382	1,5301	1,5220	1,5141	1,5063	1,4985	1,4909	1,4833
0,07	1,4758	1,4684	1,4611	1,4538	1,4466	1,4395	1,4325	1,4255	1,4187	1,4118
0,08	1,4051	1,3984	1,3917	1,3852	1,3787	1,3722	1,3658	1,3595	1,3532	1,3469
0,09	1,3408	1,3346	1,3285	1,3225	1,3165	1,3106	1,3047	1,2988	1,2930	1,2873
0,1	1,2816	1,2265	1,1750	1,1264	1,0803	1,0364	0,9945	0,9542	0,9154	0,8779
0,2	0,8416	0,8064	0,7722	0,7388	0,7063	0,6745	0,6433	0,6128	0,5828	0,5534
0,3	0,5224	0,4959	0,4677	0,4399	0,4125	0,3853	0,3585	0,3319	0,3055	0,2793
0,4	0,2533	0,2275	0,2019	0,1764	0,1510	0,1257	0,1004	0,0753	0,0502	0,0251

2.P.3 lentelė. Chi kvadrato skirstinio P -osios kritinės reikšmės

$n \setminus P$	0,9995	0,999	0,995	0,99	0,975	0,95	0,90	0,80
1	0,0 ⁶ 393	0,0 ³ 157	0,0 ⁴ 393	0,0 ³ 157	0,0 ³ 982	0,00393	0,0158	0,0642
2	0,00100	0,00200	0,0100	0,0201	0,0506	0,103	0,211	0,446
3	0,0153	0,0243	0,0717	0,115	0,216	0,352	0,584	1,005
4	0,0639	0,0908	0,207	0,297	0,484	0,711	1,064	1,649
5	0,158	0,210	0,412	0,554	0,831	1,145	1,610	2,343
6	0,299	0,381	0,676	0,872	1,237	1,635	2,204	3,070
7	0,485	0,598	0,989	1,239	1,690	2,167	2,833	3,822
8	0,710	0,857	1,344	1,646	2,180	2,733	3,490	4,594
9	0,972	1,152	1,535	2,088	2,700	3,325	4,168	5,380
10	1,265	1,479	2,156	2,558	3,247	3,940	4,865	6,179
11	1,587	1,834	2,603	3,053	3,816	4,575	5,578	6,989
12	1,934	2,214	3,074	3,571	4,404	5,226	6,304	7,807
13	2,305	2,617	3,565	4,107	5,009	5,892	7,042	8,634
14	2,697	3,041	4,075	4,660	5,629	6,571	7,790	9,467
15	3,108	3,483	4,601	5,229	6,262	7,261	8,547	10,307
16	3,536	3,942	5,142	5,812	6,908	7,962	9,312	11,152
17	3,980	4,416	5,697	6,408	7,564	8,672	10,085	12,002
18	4,439	4,905	6,265	7,015	8,231	9,390	10,865	12,857
19	4,912	5,406	6,844	7,633	8,907	10,117	11,651	13,716
20	5,398	5,921	7,434	8,260	9,591	10,851	12,443	14,578
22	6,404	6,983	8,643	9,542	10,982	12,338	14,041	16,314
24	7,453	8,085	9,886	10,856	12,401	13,848	15,659	18,062
26	8,538	9,222	11,160	12,198	13,844	15,379	17,292	19,820
28	9,656	10,391	12,461	13,565	15,308	16,928	18,939	21,588
30	10,804	11,588	13,787	14,953	16,791	18,493	20,599	23,364
32	11,979	12,811	15,134	16,362	18,291	20,072	22,271	25,148
34	13,179	14,057	16,501	17,789	19,806	21,664	23,952	26,938
36	14,401	15,324	17,887	19,233	21,336	23,269	25,643	28,735
38	15,644	16,611	19,289	20,691	22,878	24,884	27,343	30,537
40	16,906	17,916	20,707	22,164	24,433	26,509	29,051	32,345
45	20,137	21,251	24,311	25,901	28,366	30,612	33,350	36,884
50	23,461	24,674	27,991	29,707	32,357	34,764	37,689	41,449
55	26,866	28,173	31,735	33,570	36,398	38,958	42,060	46,036
60	30,340	31,738	35,534	37,485	40,482	43,188	46,459	50,641
65	33,877	35,362	39,383	41,444	44,603	47,450	50,883	55,262
70	37,467	39,036	43,275	45,442	48,758	51,739	55,329	59,898
75	41,107	42,757	47,206	49,475	52,942	56,054	59,795	64,547
80	44,791	46,520	51,172	53,540	57,153	60,391	64,278	69,207
85	48,515	50,320	55,170	57,634	61,389	64,749	68,777	73,878
90	52,276	54,155	59,196	61,754	65,647	69,126	73,291	78,558
100	59,896	61,918	67,328	70,065	74,222	77,929	82,358	87,945

2.P.3 lentelės tēsinys. Chi kvadrato skirstinio P -osios kritinės reikšmės

0,20	0,10	0,05	0,025	0,01	0,005	0,001	0,0005	P/n
1,642	2,706	3,841	5,024	6,635	7,879	10,828	12,116	1
3,219	4,605	5,991	7,378	9,210	10,597	13,816	15,202	2
4,642	6,251	7,815	9,348	11,345	12,838	16,266	17,730	3
5,989	7,779	9,488	11,143	13,277	14,860	18,467	19,997	4
7,289	9,236	11,070	12,833	15,086	16,750	20,515	22,105	5
8,558	10,645	12,592	14,449	16,812	18,548	22,458	24,103	6
9,803	12,017	14,067	16,013	18,475	20,278	24,322	26,018	7
11,030	13,362	15,507	17,535	20,090	21,955	26,124	27,868	8
12,242	14,684	16,919	19,023	21,666	23,589	27,877	29,666	9
13,442	15,987	18,307	20,483	23,209	25,188	29,588	31,420	10
14,631	17,275	19,675	21,920	24,725	26,757	31,264	33,137	11
15,812	18,549	21,026	23,337	26,217	28,300	32,909	34,821	12
16,985	19,812	22,362	24,736	27,688	29,819	34,528	36,478	13
18,151	21,064	23,685	26,119	29,141	31,319	36,123	38,109	14
19,311	22,307	24,996	27,488	30,578	32,801	37,697	39,719	15
20,465	23,542	26,296	28,845	32,000	34,267	39,252	41,308	16
21,615	24,769	27,587	30,191	33,409	35,718	40,790	42,879	17
22,760	25,989	28,869	31,526	34,805	37,156	42,312	44,434	18
23,900	27,204	30,144	32,852	36,191	38,582	43,820	45,973	19
25,038	28,412	31,410	34,170	37,566	39,997	45,315	47,498	20
27,301	30,813	33,924	36,781	40,289	42,796	48,268	50,511	22
29,553	33,196	36,415	39,364	42,980	45,559	51,179	53,479	24
31,795	35,563	38,885	41,923	45,642	48,290	54,052	56,407	26
34,027	37,916	41,337	44,461	48,278	50,993	56,892	59,300	28
36,250	40,256	43,773	46,979	50,892	53,672	59,703	62,162	30
38,466	42,585	46,194	49,480	53,486	56,328	62,487	64,995	32
40,676	44,903	48,602	51,966	56,061	58,964	65,247	67,803	34
42,879	47,212	50,998	54,437	58,619	61,581	67,985	70,588	36
45,076	49,513	53,384	56,896	61,162	64,181	70,703	73,351	38
47,269	51,805	55,758	59,342	63,691	66,766	73,402	76,095	40
52,729	57,505	61,656	65,410	69,957	73,166	80,077	82,876	45
58,164	63,167	67,505	71,420	76,154	79,490	86,661	89,561	50
63,577	68,796	73,311	77,380	82,292	85,749	93,168	96,163	55
68,972	74,397	79,082	83,298	88,379	91,952	99,607	102,695	60
74,351	79,973	84,821	89,177	94,422	98,105	105,988	109,164	65
79,715	85,527	90,531	95,023	100,425	104,215	112,317	115,578	70
85,066	91,061	96,217	100,839	106,393	110,286	118,599	121,942	75
90,405	96,578	101,879	106,629	112,329	116,321	124,839	128,261	80
101,054	107,565	113,145	118,136	124,116	128,299	137,208	140,782	90
106,364	113,038	118,752	123,858	129,973	134,247	143,344	146,990	95
111,667	118,498	124,342	129,561	135,807	140,169	149,449	153,167	100

2.P.4 lentelė. Stjudento skirstinio P -osios kritinės reikšmės

$n \setminus P$	0,25	0,10	0,05	0,025	0,01	0,005	0,0025	0,001	0,0005
1	1,0000	3,0777	6,3138	12,7062	31,8205	63,6567	127,321	318,309	636,619
2	0,8165	1,8856	2,9200	4,3027	6,9646	9,9248	14,0890	22,3271	31,5991
3	0,7649	1,6377	2,3534	3,1824	4,5407	5,8409	7,4533	10,2145	12,9240
4	0,7407	1,5332	2,1318	2,7764	3,7469	4,6041	5,5976	7,1732	8,6103
5	0,7267	1,4759	2,0150	2,5706	3,3649	4,0321	4,7733	5,8934	6,8688
6	0,7176	1,4398	1,9432	2,4469	3,1427	3,7074	4,3168	5,2076	5,9588
7	0,7111	1,4149	1,8946	2,3646	2,9980	3,4995	4,0293	4,7853	5,4079
8	0,7064	1,3968	1,8595	2,3060	2,8965	3,3554	3,8325	4,5008	5,0413
9	0,7027	1,3830	1,8331	2,2622	2,8214	3,2498	3,6897	4,2968	4,7809
10	0,6998	1,3722	1,8125	2,2281	2,7638	3,1693	3,5814	4,1437	4,5869
11	0,6974	1,3634	1,7959	2,2010	2,7181	3,1058	3,4966	4,0247	4,4370
12	0,6955	1,3562	1,7823	2,1788	2,6810	3,0545	3,4284	3,9296	4,3178
13	0,6938	1,3502	1,7709	2,1604	2,6503	3,0123	3,3725	3,8520	4,2208
14	0,6924	1,3450	1,7613	2,1448	2,6245	2,9768	3,3257	3,7874	4,1405
15	0,6912	1,3406	1,7531	2,1314	2,6025	2,9467	3,2860	3,7328	4,0728
16	0,6901	1,3368	1,7459	2,1199	2,5835	2,9208	3,2520	3,6862	4,0150
17	0,6892	1,3334	1,7396	2,1098	2,5669	2,8982	3,2224	3,6458	3,9651
18	0,6884	1,3304	1,7341	2,1009	2,5524	2,8784	3,1966	3,6105	3,9216
19	0,6876	1,3277	1,7291	2,0930	2,5395	2,8609	3,1737	3,5794	3,8834
20	0,6870	1,3253	1,7247	2,0860	2,5280	2,8453	3,1534	3,5518	3,8495
22	0,6858	1,3212	1,7171	2,0739	2,5083	2,8188	3,1188	3,5050	3,7921
24	0,6848	1,3178	1,7109	2,0639	2,4922	2,7969	3,0905	3,4668	3,7454
26	0,6840	1,3150	1,7056	2,0555	2,4786	2,7787	3,0669	3,4350	3,7066
28	0,6834	1,3125	1,7011	2,0484	2,4671	2,7633	3,0469	3,4082	3,6739
30	0,6828	1,3104	1,6973	2,0423	2,4573	2,7500	3,0298	3,3852	3,6460
34	0,6818	1,3070	1,6909	2,0322	2,4411	2,7284	3,0020	3,3479	3,6007
38	0,6810	1,3042	1,6860	2,0244	2,4286	2,7116	2,9803	3,3190	3,5657
42	0,6804	1,3020	1,6820	2,0181	2,4185	2,6981	2,9630	3,2960	3,5377
46	0,6799	1,3002	1,6787	2,0129	2,4102	2,6870	2,9488	3,2771	3,5150
50	0,6794	1,2987	1,6759	2,0086	2,4033	2,6778	2,9370	3,2614	3,4960
60	0,6786	1,2958	1,6706	2,0003	2,3901	2,6603	2,9146	3,2317	3,4602
70	0,6780	1,2938	1,6669	1,9944	2,3808	2,6479	2,8987	3,2108	3,4350
80	0,6776	1,2922	1,6641	1,9901	2,3739	2,6387	2,8870	3,1953	3,4163
90	0,6772	1,2910	1,6620	1,9867	2,3685	2,6316	2,8779	3,1833	3,4019
100	0,6770	1,2901	1,6602	1,9840	2,3642	2,6259	2,8707	3,1737	3,3905
200	0,6757	1,2858	1,6525	1,9719	2,3451	2,6006	2,8385	3,1315	3,3398
300	0,6753	1,2844	1,6499	1,9679	2,3388	2,5923	2,8279	3,1176	3,3233
400	0,6751	1,2837	1,6487	1,9659	2,3357	2,5882	2,8227	3,1107	3,3150
500	0,6750	1,2832	1,6479	1,9647	2,3338	2,5857	2,8195	3,1066	3,3101
∞	0,6745	1,2816	1,6449	1,9600	2,3263	2,5758	2,8070	3,0902	3,2905

2.P.5 lentelė. Fišerio skirstinio su m ir n laisvės laipsnių P -osios kritinės reikšmės

$n \setminus m$	1	2	3	4	5	6	7	8	9
1	161,45	199,50	215,71	224,58	230,16	233,99	236,77	238,88	240,54
2	18,513	19,000	19,164	19,247	19,296	19,330	19,353	19,371	19,385
3	10,128	9,5521	9,2766	9,1172	9,0135	8,9406	8,8867	8,8452	8,8123
4	7,7086	6,9443	6,5914	6,3882	6,2561	6,1631	6,0942	6,0410	5,9988
5	6,6079	5,7861	5,4095	5,1922	5,0503	4,9503	4,8759	4,8183	4,7725
6	5,9874	5,1433	4,7571	4,5337	4,3874	4,2839	4,2067	4,1468	4,0990
7	5,5914	4,7374	4,3468	4,1203	3,9715	3,8660	3,7870	3,7257	3,6767
8	5,3177	4,4590	4,0662	3,8379	3,6875	3,5806	3,5005	3,4381	3,3881
9	5,1174	4,2565	3,8625	3,6331	3,4817	3,3738	3,2927	3,2296	3,1789
10	4,9646	4,1028	3,7083	3,4780	3,3258	3,2172	3,1355	3,0717	3,0204
11	4,8443	3,9823	3,5874	3,3567	3,2039	3,0946	3,0123	2,9480	2,8962
12	4,7472	3,8853	3,4903	3,2592	3,1059	2,9961	2,9134	2,8486	2,7964
13	4,6672	3,8056	3,4105	3,1791	3,0254	2,9153	2,8321	2,7669	2,7144
14	4,6001	3,7389	3,3439	3,1122	2,9582	2,8477	2,7642	2,6987	2,6458
15	4,5431	3,6823	3,2874	3,0556	2,9013	2,7905	2,7066	2,6408	2,5876
16	4,4940	3,6337	3,2389	3,0069	2,8524	2,7413	2,6572	2,5911	2,5377
17	4,4513	3,5915	3,1968	2,9647	2,8100	2,6987	2,6143	2,5480	2,4943
18	4,4139	3,5546	3,1599	2,9277	2,7729	2,6613	2,5767	2,5102	2,4563
19	4,3807	3,5219	3,1274	2,8951	2,7401	2,6283	2,5435	2,4768	2,4227
20	4,3512	3,4928	3,0984	2,8661	2,7109	2,5990	2,5140	2,4471	2,3928
21	4,3248	3,4668	3,0725	2,8401	2,6848	2,5727	2,4876	2,4205	2,3660
22	4,3009	3,4434	3,0491	2,8167	2,6613	2,5491	2,4638	2,3965	2,3419
23	4,2793	3,4221	3,0280	2,7955	2,6400	2,5277	2,4422	2,3748	2,3201
24	4,2597	3,4028	3,0088	2,7763	2,6207	2,5082	2,4226	2,3551	2,3002
25	4,2417	3,3852	2,9912	2,7587	2,6030	2,4904	2,4047	2,3371	2,2821
26	4,2252	3,3690	2,9752	2,7426	2,5868	2,4741	2,3883	2,3205	2,2655
27	4,2100	3,3541	2,9604	2,7278	2,5719	2,4591	2,3732	2,3053	2,2501
28	4,1960	3,3404	2,9467	2,7141	2,5581	2,4453	2,3593	2,2913	2,2360
29	4,1830	3,3277	2,9340	2,7014	2,5454	2,4324	2,3463	2,2783	2,2229
30	4,1709	3,3158	2,9223	2,6896	2,5336	2,4205	2,3343	2,2662	2,2107
40	4,0847	3,2317	2,8387	2,6060	2,4495	2,3359	2,2490	2,1802	2,1240
50	4,0343	3,1826	2,7900	2,5572	2,4004	2,2864	2,1992	2,1299	2,0734
60	4,0012	3,1504	2,7581	2,5252	2,3683	2,2541	2,1665	2,0970	2,0401
70	3,9778	3,1277	2,7355	2,5027	2,3456	2,2312	2,1435	2,0737	2,0166
80	3,9604	3,1108	2,7188	2,4859	2,3287	2,2142	2,1263	2,0564	1,9991
100	3,9361	3,0873	2,6955	2,4626	2,3053	2,1906	2,1025	2,0323	1,9748
150	3,9042	3,0564	2,6649	2,4320	2,2745	2,1595	2,0711	2,0006	1,9428
200	3,8884	3,0411	2,6498	2,4168	2,2592	2,1441	2,0556	1,9849	1,9269
500	3,8601	3,0138	2,6227	2,3898	2,2320	2,1167	2,0279	1,9569	1,8986
∞	3,8415	2,9957	2,6049	2,3719	2,2141	2,0986	2,0096	1,9384	1,8799

2.P.5 lentelės tėsinys. Fišerio skirstinio su m ir n laisvės laipsnių P -osios kritinės reikšmės

$n \setminus m$	10	12	15	20	24	30	40	60	120	∞
1	241,88	243,91	245,95	248,01	249,05	250,09	251,14	252,20	253,25	254,31
2	19,396	19,413	19,429	19,446	19,454	19,462	19,471	19,479	19,487	19,496
3	8,7855	8,7446	8,7029	8,6602	8,6385	8,6166	8,5944	8,5720	8,5494	8,5265
4	5,9644	5,9117	5,8578	5,8025	5,7744	5,7459	5,7170	5,6877	5,6581	5,6281
5	4,7351	4,6777	4,6188	4,5581	4,5272	4,4957	4,4638	4,4314	4,3985	4,3650
6	4,0600	3,9999	3,9381	3,8742	3,8415	3,8082	3,7743	3,7398	3,7047	3,6689
7	3,6365	3,5747	3,5108	3,4445	3,4105	3,3758	3,3404	3,3043	3,2674	3,2298
8	3,3472	3,2839	3,2184	3,1503	3,1152	3,0794	3,0428	3,0053	2,9669	2,9276
9	3,1373	3,0729	3,0061	2,9365	2,9005	2,8637	2,8259	2,7872	2,7475	2,7067
10	2,9782	2,9130	2,8450	2,7740	2,7372	2,6996	2,6609	2,6211	2,5801	2,5379
11	2,8536	2,7876	2,7186	2,6464	2,6090	2,5705	2,5309	2,4901	2,4480	2,4045
12	2,7534	2,6866	2,6169	2,5436	2,5055	2,4663	2,4259	2,3842	2,3410	2,2962
13	2,6710	2,6037	2,5331	2,4589	2,4202	2,3803	2,3392	2,2966	2,2524	2,2064
14	2,6022	2,5342	2,4630	2,3879	2,3487	2,3082	2,2664	2,2230	2,1778	2,1307
15	2,5437	2,4753	2,4034	2,3275	2,2878	2,2468	2,2043	2,1601	2,1141	2,0658
16	2,4935	2,4247	2,3522	2,2756	2,2354	2,1938	2,1507	2,1058	2,0589	2,0096
17	2,4499	2,3807	2,3077	2,2304	2,1898	2,1477	2,1040	2,0584	2,0107	1,9604
18	2,4117	2,3421	2,2686	2,1906	2,1497	2,1071	2,0629	2,0166	1,9681	1,9168
19	2,3779	2,3080	2,2341	2,1555	2,1141	2,0712	2,0264	1,9795	1,9302	1,8780
20	2,3479	2,2776	2,2033	2,1242	2,0825	2,0391	1,9938	1,9464	1,8963	1,8432
21	2,3210	2,2504	2,1757	2,0960	2,0540	2,0102	1,9645	1,9165	1,8657	1,8117
22	2,2967	2,2258	2,1508	2,0707	2,0283	1,9842	1,9380	1,8894	1,8380	1,7831
23	2,2747	2,2036	2,1282	2,0476	2,0050	1,9605	1,9139	1,8648	1,8128	1,7570
24	2,2547	2,1834	2,1077	2,0267	1,9838	1,9390	1,8920	1,8424	1,7896	1,7330
25	2,2365	2,1649	2,0889	2,0075	1,9643	1,9192	1,8718	1,8217	1,7684	1,7110
26	2,2197	2,1479	2,0716	1,9898	1,9464	1,9010	1,8533	1,8027	1,7488	1,6906
27	2,2043	2,1323	2,0558	1,9736	1,9299	1,8842	1,8361	1,7851	1,7307	1,6717
28	2,1900	2,1179	2,0411	1,9586	1,9147	1,8687	1,8203	1,7689	1,7138	1,6541
29	2,1768	2,1045	2,0275	1,9446	1,9005	1,8543	1,8055	1,7537	1,6981	1,6377
30	2,1646	2,0921	2,0148	1,9317	1,8874	1,8409	1,7918	1,7396	1,6835	1,6223
40	2,0772	2,0035	1,9245	1,8389	1,7929	1,7444	1,6928	1,6373	1,5766	1,5089
50	2,0261	1,9515	1,8714	1,7841	1,7371	1,6872	1,6337	1,5756	1,5115	1,4383
60	1,9926	1,9174	1,8364	1,7480	1,7001	1,6491	1,5943	1,5343	1,4673	1,3893
70	1,9689	1,8932	1,8117	1,7223	1,6738	1,6220	1,5661	1,5046	1,4351	1,3529
80	1,9512	1,8753	1,7932	1,7032	1,6542	1,6017	1,5449	1,4821	1,4107	1,3247
100	1,9267	1,8503	1,7675	1,6764	1,6267	1,5733	1,5151	1,4504	1,3757	1,2832
150	1,8943	1,8172	1,7335	1,6410	1,5902	1,5354	1,4752	1,4074	1,3275	1,2226
200	1,8783	1,8008	1,7166	1,6233	1,5720	1,5164	1,4551	1,3856	1,3024	1,1885
500	1,8496	1,7716	1,6864	1,5916	1,5392	1,4821	1,4186	1,3455	1,2551	1,1132
∞	1,8307	1,7522	1,6664	1,5705	1,5173	1,4591	1,3940	1,3180	1,2214	1,0000

Literatūra

- [1] Afifi A. A., Azen S. P. *Statistical Analysis. A Computer Oriented Approach.* Vertimas į rusų kalbą. – Maskva: „Mir“, 1982.
- [2] Bagdonavičius V., Kruopis J. J. *Matematinė statistika. Vadovėlis. I dalis. Parametrinė statistika.* Vilnius: VU leidykla, 2015 (www.statistika.mif.vu.lt).
- [3] Bagdonavičius V., Kruopis J. J. *Matematinė statistika. Vadovėlis. II dalis. Tiesiniai modeliai.* Vilnius: VU leidykla, 2015 (www.statistika.mif.vu.lt).
- [4] Bagdonavičius V., Kruopis J. J. *Matematinė statistika. Vadovėlis. III dalis. Neparametrinė statistika.* Vilnius: VU leidykla, 2015 (www.statistika.mif.vu.lt).
- [5] Bagdonavičius V., Kruopis J. J. *Matematinė statistika. Vadovėlis. IV dalis. Daugiamatė statistika.* Vilnius: VU leidykla, 2015 (www.statistika.mif.vu.lt).
- [6] Cox D. R., Hinkley D. V. *Problems and Solutions in Theoretical Statistics.* John Wiley Sans, New York, 1978.
- [7] Bickel P. J., Doksum K. A. *Mathematical statistics: basic ideas and selected topics.* Prentice and Hall, v. I, II, 2000.
- [8] Čekanavičius V., Murauskas G. *Statistika ir jos taikymai.* Vilnius: TEV, I dalis – 2000. II dalis – 2002.
- [9] Čibisov D. M., Pagurova V. I. *Matematinės statistikos uždaviniai.* (rusų kalba). Maskva: Maskvos u-to leidykla, 1990.
- [10] Härdle W. K., Spokoiny V., Panov V., Wang W. *Basics of Modern Mathematical Statistics. Exercises and Solutions.* Springer - Verlag Berlin Heidelberg, 2014.
- [11] Hicks Ch. R., Turner K. V. *Fundamental Concepts in the Design of Experiments.* Oxford University Press, 5th ed., 1999.
- [12] Lehmann E. L, Romano J. P. *Testing Statistical Hypotheses.* Springer, 3rd ed., 2008.
- [13] Levulienė R. *Statistikos taikymai naudojant SAS.* Vilnius: VU leidykla, 2009.
- [14] Mardia K. V. *Statistics of Directional Data.* Academic Press, 1972.
- [15] Rao C. R. *Linear Statistical Inference and Its Applications.* Wiley, 2nd ed., 2002.

- [16] Scheffe H. *The Analysis of Variance*. Wiley, 1999.
- [17] Shao J. *Mathematical Statistics*. Springer, 1999.
- [18] Spokoiny V., Dickhaus T. *Basics of Modern Mathematical Statistics*. Springer - Verlag Berlin Heidelberg, 2015.

Vilijandas Bagdonavičius, Julius Jonas Kruopis, Rūta Levulienė

Matematinės statistikos uždavinynas su sprendimais. – Vilnius: Vilniaus universiteto leidykla, 2019. – 288 p.

ISBN 978-609-07-0247-5

Uždavinynė pateikiami teorinio ir praktinio pobūdžio matematinės statistikos uždaviniai su sprendimais. Jų sudaro trys dalys: parametrinė statistika, tiesiniai modeliai, neparametrinė statistika. Knyga skirta universitetų statistikos ir matematikos studijų kryptių studentams, studijuojantiems matematinės statistikos kursą, taip pat ir kitų mokslinės ar praktinės sričių specialistams, taikantiems matematinės statistikos metodus.

Vilijandas Bagdonavičius, Julius Jonas Kruopis, Rūta Levulienė
Matematinės statistikos uždavinynas su sprendimais

Korektūrą skaitė *Dalia Blažinskaite*
Viršelio dailininkė *Jurga Tévelienė*
Maketuotoja *Rūta Levulienė*

Vilniaus universiteto leidykla
Saulėtekio al. 9, LT-10222 Vilnius
info@leidykla.vu.lt, www.leidykla.vu.lt



Uždavinyne pateikiami teorinio ir praktinio pobūdžio matematinės statistikos uždaviniai su sprendimais. Jų sudaro trys dalys: parametrinė statistika, tiesiniai modeliai, neparametrinė statistika. Knyga skirta universitetų statistikos ir matematikos studijų krypčių studenams, studijuojantiems matematinės statistikos kursą, taip pat ir kitų mokslinės ar praktinės sričių specialistams, taikantiems matematinės statistikos metodus.

