

# Asimptotinė statistika

Vytautas Kazakevičius

December 14, 2007



# Turinys

|          |  |           |
|----------|--|-----------|
| <b>1</b> | <b>Asimptotiniai skirstiniai</b>                           | <b>1</b>  |
| 1.1      | Atsitiktiniai dydžiai ir vektoriai . . . . .               | 1         |
| 1.1.1    | Diskretieji atsitiktiniai dydžiai . . . . .                | 1         |
| 1.1.2    | Diskretieji atsitiktiniai vektoriai . . . . .              | 2         |
| 1.1.3    | Tolydieji atsitiktiniai dydžiai . . . . .                  | 3         |
| 1.1.4    | Tolydieji atsitiktiniai vektoriai . . . . .                | 5         |
| 1.2      | Asimptotiniai skirstiniai . . . . .                        | 9         |
| 1.2.1    | Uždavinio formulavimas . . . . .                           | 9         |
| 1.2.2    | Empiriniai vidurkiai . . . . .                             | 9         |
| 1.2.3    | Normalusis skirstinys . . . . .                            | 10        |
| 1.2.4    | Pagrindiniai asimptotinių skirstinių ieškojimo metodai . . | 10        |
| 1.2.5    | Pavyzdžiai . . . . .                                       | 10        |
| <b>2</b> | <b>Stochastinis konvergavimas</b>                          | <b>17</b> |
| 2.1      | Apibrėžimas ir pavyzdžiai . . . . .                        | 17        |
| 2.1.1    | Apibrėžimas . . . . .                                      | 17        |
| 2.1.2    | Pavyzdžiai . . . . .                                       | 18        |
| 2.1.3    | Kaip įrodyti, kad ribos nėra . . . . .                     | 20        |
| 2.2      | Portmanto lema . . . . .                                   | 21        |
| 2.2.1    | Formulavimas ir įrodymas . . . . .                         | 21        |
| 2.2.2    | Įrodymo paaiškinimai . . . . .                             | 22        |
| 2.2.3    | Komentarai . . . . .                                       | 26        |
| 2.3      | Konvergavimas į išsigimusį dydį . . . . .                  | 27        |
| 2.3.1    | Teoremos . . . . .   | 27        |
| 2.3.2    | Įrodymų paaiškinimai . . . . .                             | 28        |
| 2.3.3    | Komentarai . . . . .                                       | 29        |
| 2.4      | Tolydaus atvaizdžio principas . . . . .                    | 29        |
| 2.4.1    | Teorema . . . . .  | 29        |
| 2.4.2    | Įrodymo paaiškinimai . . . . .                             | 31        |
| 2.4.3    | Komentarai . . . . .                                       | 32        |
| 2.5      | $O$ -simbolika . . . . .                                   | 33        |
| <b>3</b> | <b>Asimptotiniai skirstiniai (tęsinys)</b>                 | <b>35</b> |
| 3.1      | Vektorinis delta metodas . . . . .                         | 35        |
| 3.1.1    | Matricinė notacija . . . . .                               | 35        |
| 3.1.2    | Atsitiktinių matricių vidurkiai . . . . .                  | 36        |
| 3.1.3    | Normalusis skirstinys . . . . .                            | 37        |
| 3.1.4    | Empiriniai vidurkiai . . . . .                             | 37        |
| 3.1.5    | Asimptotikų ieškojimo metodai . . . . .                    | 37        |

|          |  |           |
|----------|--|-----------|
| 3.1.6    | Pavyzdžiai . . . . .   | 38        |
| 3.2      | Ypatingi atvejai . . . . .   | 41        |
| 3.2.1    | Atvejis, kai $g'(a) = 0$ . . . . .   | 41        |
| 3.2.2    | Atvejis, kai $g$ priklauso nuo $n$ . . . . .                                       | 42        |
| 3.3      | Pavyzdžiai . . . . .   | 44        |
| <b>4</b> | <b>Taikymai</b>  | <b>49</b> |
| 4.1      | Pasikliautiniai intervalai . . . . .   | 49        |
| 4.1.1    | Uždavinio formulavimas . . . . .   | 49        |
| 4.1.2    | Standartinė procedūra . . . . .  | 49        |
| 4.1.3    | Modifikuota procedūra . . . . .  | 50        |
| 4.1.4    | Dispersijos stabilizavimo metodas . . . . .  | 52        |
| 4.2      | Hipotezių tikrinimas . . . . .   | 53        |
| 4.2.1    | Bendra teorija . . . . .   | 53        |
| 4.2.2    | Nepriklausomumo tikrinimas, remiantis empiriniu koreliacijos koeficientu . . . . . | 54        |
| 4.3      | Klaidingos modelio specifikacijos efektas . . . . .                                | 57        |
| 4.3.1    | Hipotezės apie dispersiją tikrinimas . . . . .                                     | 57        |
| <b>5</b> | <b><math>M</math>-įvertiniai</b>   | <b>61</b> |
| 5.1      | Maksimalaus tikėtino įvertiniai . . . . .  | 61        |
| 5.2      | $M$ -įvertinių pagrindumas. Klasikinė teorema . . . . .                            | 65        |
| 5.2.1    | $M$ -įvertiniai ir $Z$ -įvertiniai . . . . .                                       | 65        |
| 5.2.2    | Klasikinė teorema . . . . .  | 66        |
| 5.2.3    | Įrodymų paaiškinimai . . . . .   | 67        |
| 5.2.4    | Komentarai . . . . .   | 69        |
| 5.3      | Valdo teorema . . . . .  | 69        |
| 5.3.1    | Valdo teorema . . . . .  | 69        |
| 5.3.2    | Įrodymo paaiškinimai . . . . .   | 70        |
| 5.4      | Kitos teoremos . . . . .   | 72        |
| 5.4.1    | Teoremos . . . . .   | 72        |
| 5.4.2    | Įrodymų paaiškinimai . . . . .   | 73        |

# 1 skyrius

## Asimptotiniai skirstiniai

### 1.1 Atsitiktiniai dydžiai ir vektoriai

#### 1.1.1 Diskretieji atsitiktiniai dydžiai

Diskretaus atsitiktinio dydžio skirstinys paprastai užrašomas lentele

|     |       |         |       |
|-----|-------|---------|-------|
| $X$ | $x_1$ | $\dots$ | $x_r$ |
|     | $p_1$ | $\dots$ | $p_r$ |

Toks užrašas reiškia, kad atsitiktinis dydis įgyja reikšmes  $x_1, \dots, x_r$  ir

$$P\{X = x_j\} = p_j \quad \text{su } j = 1, \dots, r.$$

Visos tikimybės  $p_j$  yra neneigiami skaičiai ir  $\sum_{j=1}^r p_j = 1$ .

Pagrindinės tokio atsitiktinio dydžio charakteristikos skaičiuojamos taip:

$$P\{X \in A\} = \sum_{x_i \in A} p_i, \quad E f(X) = \sum_{i=1}^r f(x_i) p_i, \quad D f(X) = E f^2(X) - [E f(X)]^2.$$

Be to, reikia mokėti rasti bet kokios transformacijos  $Y = \varphi(X)$  skirstinį. Galimos  $Y$  reikšmės yra  $\varphi(x_1), \dots, \varphi(x_r)$  (kai kurie iš tų skaičių gali sutapti) ir su bet kokia galima reikšme  $y$

$$P\{Y = y\} = \sum_{\varphi(x_i)=y} p_i.$$

1.1 PAVYZDYS. Atsitiktinio dydžio  $X$  skirstinys užrašytas lentele

|     |     |     |     |     |
|-----|-----|-----|-----|-----|
| $X$ | 0   | 1   | 2   | 3   |
|     | 0.3 | 0.4 | 0.1 | 0.2 |

Apskaičiuokite:

- $P\{(X - 1)(X - 2) \neq 0\}$ ;
- $E \cos \frac{\pi X}{4}$ ;
- atsitiktinio dydžio  $Y = |X - 1|$  skirstinį.

Sprendimas.

$$P\{(X-1)(X-2) \neq 0\} = 0.3 + 0.2 = 0.5;$$

$$E \cos \frac{\pi X}{4} = 1 \cdot 0.3 + \frac{\sqrt{2}}{2} \cdot 0.4 + 0 - \frac{\sqrt{2}}{2} \cdot 0.2 = 0.3 + 0.1\sqrt{2}.$$

|     |     |     |     |
|-----|-----|-----|-----|
| $Y$ | 0   | 1   | 2   |
|     | 0.4 | 0.4 | 0.2 |

### 1.1.2 Diskretieji atsitiktiniai vektoriai

Jei  $X$  ir  $Y$  yra du diskretūs atsitiktiniai dydžiai, tai jų bendras skirstinys, arba atsitiktinio vektoriaus  $(X, Y)$  skirstinys, aprašomas lentele

|          |          |          |          |
|----------|----------|----------|----------|
| $X \ Y$  | $y_1$    | $\dots$  | $y_s$    |
| $x_1$    | $p_{11}$ | $\dots$  | $p_{1s}$ |
| $\vdots$ | $\vdots$ | $\ddots$ | $\vdots$ |
| $x_r$    | $p_{r1}$ | $\dots$  | $p_{rs}$ |

Toks užrašas reiškia, kad  $X$  įgyja reikšmes  $x_1, \dots, x_r$ ,  $Y$  įgyja reikšmes  $y_1, \dots, y_s$  ir

$$P\{X = x_j, Y = y_k\} = p_{jk} \quad \text{su } j = 1, \dots, r \text{ ir } k = 1, \dots, s.$$

Visos tikimybės  $p_{jk}$  yra neneigiami skaičiai ir  $\sum_{j,k} p_{jk} = 1$ .

Pagrindinės  $(X, Y)$  vektoriaus charakteristikos skaičiuojamos taip:

$$P\{(X, Y) \in A\} = \sum_{(x_j, y_k) \in A} p_{jk}, \quad E f(X, Y) = \sum_{j,k} f(x_j, y_k) p_{jk}.$$

Be to, reikia mokėti rasti bet kokios transformacijos  $Z = \varphi(X, Y)$  skirstinį. Galimos  $Z$  reikšmės yra  $\varphi(x_j, y_k)$  (kai kurie iš tų skaičių gali sutapti) ir su bet kokia galima reikšme  $z$

$$P\{Z = z\} = \sum_{\varphi(x_j, y_k) = z} p_{jk}.$$

Jei  $X$  ir  $Y$  nepriklausomi, užtenka nurodyti tik  $X$  ir  $Y$  skirstinius:

|     |       |         |       |     |       |         |       |
|-----|-------|---------|-------|-----|-------|---------|-------|
| $X$ | $x_1$ | $\dots$ | $x_r$ | $Y$ | $y_1$ | $\dots$ | $y_s$ |
|     | $p_1$ | $\dots$ | $p_r$ |     | $q_1$ | $\dots$ | $q_s$ |

Bendro skirstinio tikimybės tada skaičiuojamos pagal formulę

$$p_{jk} = p_j q_k, \quad j = 1, \dots, r, \quad k = 1, \dots, s.$$

1.2 PAVYZDYS.  $X$  ir  $Y$  yra nepriklausomi atsitiktiniai dydžiai, pasiskirstę taip, kaip parodyta lentelėse:

|     |     |     |     |     |     |     |
|-----|-----|-----|-----|-----|-----|-----|
| $X$ | 0   | 1   | $Y$ | 0   | 1   | 2   |
|     | 0.3 | 0.7 |     | 0.2 | 0.3 | 0.5 |

Apskaičiuokite:

a)  $P\{Y = X\}$ ;

b)  $D(XY)$ ;

c) atsitiktinio dydžio  $Z = XY$  skirstinį.

*Sprendimas.* Bendras  $X$  ir  $Y$  skirstinys aprašomas lentele:

|       |      |      |      |     |
|-------|------|------|------|-----|
| $X Y$ | 0    | 1    | 2    |     |
| 0     | 0.06 | 0.09 | 0.15 | 0.3 |
| 1     | 0.14 | 0.21 | 0.35 | 0.7 |
|       | 0.2  | 0.3  | 0.5  |     |

Tada

$$P\{Y = X\} = 0.06 + 0.21 = 0.27.$$

Be to,

$$D(XY) = E(X^2Y^2) - [E(XY)]^2.$$

Kadangi

$$\begin{aligned} E(XY) &= 0 + 0 + 0 + 0 + 0.21 + 0.7 = 0.91, \\ E(X^2Y^2) &= 0 + 0 + 0 + 0 + 0.21 + 1.4 = 1.61, \end{aligned}$$

gaunu

$$D(XY) = 1.61 - 0.91^2 = 0.7819.$$

$Z$  skirstinys aprašomas lentele

|     |      |      |      |
|-----|------|------|------|
| $Z$ | 0    | 1    | 2    |
|     | 0.44 | 0.21 | 0.35 |

### 1.1.3 Tolydieji atsitiktiniai dydžiai

(Absoliučiai) tolydaus atsitiktinio dydžio  $X$  skirstinys aprašomas, nurodant jo tankį  $p(x)$ , kuris yra neneigiama funkcija, apibrėžta kokioje nors aibėje  $D \subset \mathbb{R}$  ir tokia, kad

$$\int_D p(x) dx = 1.$$

Pavyzdžiui, *tolygiojo*  $(a; b)$  intervale skirstinio tankis

$$p(x) = \frac{1}{b-a}, \quad \text{kai } a < x < b.$$

Pagrindinės atsitiktinio dydžio  $X$  charakteristikos skaičiuojamos taip:

$$P\{X \in A\} = \int_{A \cap D} p(x) dx, \quad E f(X) = \int_D f(x) p(x) dx.$$

Be to, reikia mokėti aprašyti bet kokios transformacijos  $Y = \varphi(X)$  skirstinį. Jei  $\varphi$  yra

$$\varphi(x) = \begin{cases} y_1, & \text{kai } x \in D_1; \\ \vdots \\ y_s, & \text{kai } x \in D_s; \end{cases}$$

pavidalo (čia  $(D_1, \dots, D_s)$  yra  $D$  aibės skaidinys), tai  $Y$  yra diskretus atsitiktinis dydis, įgyjantis reikšmes  $y_1, \dots, y_s$  su tikimybėmis

$$P\{Y = y_k\} = \int_{D_k} p(x)dx, \quad k = 1, \dots, s.$$

Jei  $\varphi$  yra glodi funkcija, tai  $Y$  turi tankį  $q(y)$ , kuris skaičiuojamas taip:

$$q(y) = (G(y))';$$

$$G(y) = P\{Y \leq y\} = P\{\varphi(X) \leq y\} = \int_{\substack{x \in D \\ \varphi(x) \leq y}} p(x)dx.$$

1.3 PAVYZDYS. Atsitiktinis dydis  $X$  turi tankį

$$p(x) = xe^{-x}, \quad \text{kai } x > 0.$$

Apskaičiuokite:

- a)  $P\{1 < X < 2\}$ ;
- b)  $E X^3$ ;
- c) atsitiktinių dydžių

$$Y = \begin{cases} 0, & \text{kai } X < 1; \\ 1, & \text{kai } X \geq 1; \end{cases}$$

ir  $Z = \ln X$  skirstinius.

*Sprendimas.*

$$\begin{aligned} P\{1 < X < 2\} &= \int_1^2 xe^{-x} dx \\ &= - \int_1^2 x de^{-x} \\ &= -xe^{-x} \Big|_1^2 + \int_1^2 e^{-x} dx \\ &= -2e^{-2} + e^{-1} - e^{-x} \Big|_1^2 \\ &= -2e^{-2} + e^{-1} - e^{-2} + e^{-1} \\ &= -3e^{-2} + 2e^{-1} \\ &= \frac{2e - 3}{e^2}. \end{aligned}$$

$$E(X^3) = \int_0^{\infty} x^4 e^{-x} dx = \Gamma(5) = 4! = 24.$$

Kadangi

$$P\{Y = 1\} = P\{X \geq 1\} = \int_1^{\infty} xe^{-x} dx = - \int_1^{\infty} x de^{-x} = -xe^{-x} \Big|_1^{\infty} = e^{-1},$$

$Y$  skirstinys aprašomas lentele:



|     |              |          |
|-----|--------------|----------|
| $Y$ | 0            | 1        |
|     | $1 - e^{-1}$ | $e^{-1}$ |

Kadangi

$$\begin{aligned}
 P\{Z \leq z\} &= P\{\ln X \leq z\} \\
 &= P\{X \leq e^z\} \\
 &= \int_0^{e^z} xe^{-x} dx \\
 &= - \int_0^{e^z} x de^{-x} \\
 &= -xe^{-x} \Big|_0^{e^z} + \int_0^{e^z} e^{-x} dx \\
 &= -e^z e^{-e^z} - e^{-x} \Big|_0^{e^z} \\
 &= 1 - e^{-e^z} - e^z e^{-e^z}
 \end{aligned}$$

ir

$$(1 - e^{-e^z} - e^z e^{-e^z})' = e^{-e^z} e^z - e^z e^{-e^z} + e^{2z} e^{-e^z} = e^{2z} e^{-e^z},$$

atsitiktinis dydis  $Z$  turi tankį

$$q(z) = e^{2z} e^{-e^z}, \quad -\infty < z < \infty.$$

#### 1.1.4 Tolydieji atsitiktiniai vektoriai

Tolydziojo atsitiktinio vektoriaus  $(X, Y)$  skirstinys aprašomas, nurodant tankį  $p(x, y)$ , kuris yra neneigiama funkcija, apibrėžta tam tikroje srityje  $D \subset \mathbb{R}^2$  ir tenkina sąlygą

$$\int_D p(x, y) dx dy = 1.$$

Pagrindinės  $(X, Y)$  vektoriaus charakteristikos skaičiuojamos taip:

$$P\{(X, Y) \in A\} = \int_{D \cap A} p(x, y) dx dy, \quad E f(X, Y) = \int_D f(x, y) p(x, y) dx dy.$$

Be to, reikia mokėti rasti bet kokios transformacijos  $Z = \varphi(X, Y)$  skirstinį. Jei  $\varphi$  yra


$$\varphi(x, y) = \begin{cases} z_1, & \text{kai } (x, y) \in D_1; \\ \vdots \\ z_s, & \text{kai } (x, y) \in D_s; \end{cases}$$

pavidalo (čia  $(D_1, \dots, D_s)$  yra  $D$  aibės skaidinys), tai  $Z$  yra diskretus atsitiktinis dydis, įgyjantis reikšmes  $z_1, \dots, z_s$  su tikimybėmis

$$P\{Z = z_k\} = \int_{D_k} p(x, y) dx dy, \quad k = 1, \dots, s.$$

Jei  $\varphi$  yra glodi funkcija, tai  $Z$  turi tankį  $q(z)$ , kuris skaičiuojamas taip:

$$q(z) = (G(z))';$$



1.1 pav.

$$G(z) = P\{Z \leq z\} = P\{\varphi(X, Y) \leq z\} = \int_{\substack{(x,y) \in D \\ \varphi(x,y) \leq z}} p(x, y) dx dy.$$

Jei  $X$  ir  $Y$  nepriklausomi, užtenka nurodyti tik  $X$  ir  $Y$  tankius  $p(x)$  ir  $q(y)$ . Bendro skirstinio tankis tada yra marginalių tankių sandauga:

$$p(x, y) = p(x)q(y).$$

1.4 PAVYZDYS. Atsitiktiniai dydžiai  $X$  ir  $Y$  nepriklausomi ir tolygiai pasiskirstę  $(0; 2)$  intervale. Apskaičiuokite:

- $P\{Y \geq X \geq 1\}$ ;
- $E|XY - 1|$ ;
- atsitiktinio dydžio  $Z = X + Y$  skirstinį.

*Sprendimas.* Bendras  $X$  ir  $Y$  tankis yra

$$p(x, y) = \frac{1}{4}, \quad \text{kai } 0 < x, y < 2.$$

Todėl (žr. 1.1 pav.)

$$\begin{aligned} P\{Y \geq X \geq 1\} &= \int_{\substack{0 < x < 2 \\ 0 < y < 2 \\ y \geq x \geq 1}} \frac{1}{4} dx dy \\ &= \frac{1}{4} \int_1^2 dx \int_x^2 dy \\ &= \frac{1}{4} \int_1^2 (2 - x) dx \\ &= \frac{1}{4} \left( 2x - \frac{x^2}{2} \right) \Big|_1^2 \\ &= \frac{1}{4} \left( 4 - 2 - 2 + \frac{1}{2} \right) \end{aligned}$$


$$= \frac{1}{8},$$

o

$$\begin{aligned} E|XY - 1| &= \int_{\substack{0 < x < 2 \\ 0 < y < 2}} |xy - 1| \frac{1}{4} dx dy \\ &= \frac{1}{4} \int_{\substack{0 < x < 2 \\ 0 < y < 2 \\ xy > 1}} (xy - 1) dx dy + \frac{1}{4} \int_{\substack{0 < x < 2 \\ 0 < y < 2 \\ xy < 1}} (1 - xy) dx dy \\ &= \frac{1}{4} \int_{1/2}^2 dx \int_{1/x}^2 (xy - 1) dy + \frac{1}{4} \int_0^{1/2} dx \int_0^2 (1 - xy) dy \\ &\quad + \frac{1}{4} \int_{1/2}^2 dx \int_0^{1/x} (1 - xy) dy \\ &= \frac{1}{4} \int_{1/2}^2 \left( x \frac{y^2}{2} - y \right) \Big|_{1/x}^2 dx + \frac{1}{4} \int_0^{1/2} \left( y - x \frac{y^2}{2} \right) \Big|_0^2 dx \\ &\quad + \frac{1}{4} \int_{1/2}^2 \left( y - x \frac{y^2}{2} \right) \Big|_0^{1/x} dx \\ &= \frac{1}{4} \int_{1/2}^2 \left( 2x - 2 - \frac{1}{2x} + \frac{1}{x} \right) dx + \frac{1}{4} \int_0^{1/2} (2 - 2x) dx \\ &\quad + \frac{1}{4} \int_{1/2}^2 \left( \frac{1}{x} - \frac{1}{2x} \right) dx \\ &= \frac{1}{4} \int_{1/2}^2 \left( 2x - 2 + \frac{1}{2x} \right) dx + \frac{1}{4} (2x - x^2) \Big|_0^{1/2} + \frac{1}{4} \int_{1/2}^2 \frac{dx}{2x} \\ &= \frac{1}{4} \int_{1/2}^2 \left( 2x - 2 + \frac{1}{x} \right) dx + \frac{1}{4} \left( 1 - \frac{1}{4} \right) \\ &= \frac{1}{4} (x^2 - 2x + \ln x) \Big|_{1/2}^2 + \frac{3}{16} \\ &= \frac{1}{4} \left( 4 - 4 + \ln 2 - \frac{1}{4} + 1 - \ln \frac{1}{2} \right) + \frac{3}{16} \\ &= \frac{3}{8} + \frac{\ln 2}{2}. \end{aligned}$$

Kadangi  $0 < X, Y < 2$ , galimos sumos  $Z = X + Y$  reikšmės užpildo  $(0; 4)$  intervalą. Jei  $0 < z < 2$ , tai (žr. 1.2 pav.)

$$\begin{aligned} P\{Z \leq z\} &= P\{X + Y \leq z\} \\ &= \int_{\substack{0 < x < 2 \\ 0 < y < 2 \\ x + y \leq z}} \frac{1}{4} dx dy \\ &= \frac{1}{4} \int_0^z dx \int_0^{z-x} dy \\ &= \frac{1}{4} \int_0^z (z - x) dx \end{aligned}$$



1.2 pav.

$$\begin{aligned}
 &= \frac{1}{4} \left( zx - \frac{x^2}{2} \right) \Big|_0^z \\
 &= \frac{z^2}{8}.
 \end{aligned}$$

Jei  $2 < z < 4$ , tai

$$\begin{aligned}
 P\{Z > z\} &= P\{X + Y > z\} \\
 &= \int_{\substack{0 < x < 2 \\ 0 < y < 2 \\ x+y > z}} \frac{1}{4} dx dy \\
 &= \frac{1}{4} \int_{z-2}^2 dx \int_{z-x}^2 dy \\
 &= \frac{1}{4} \int_{z-2}^2 (2 - z + x) dx \\
 &= \frac{1}{4} \left( (2 - z)x + \frac{x^2}{2} \right) \Big|_{z-2}^2 \\
 &= \frac{1}{4} \left( 4 - 2z + 2 + (z - 2)^2 - \frac{(z - 2)^2}{2} \right) \\
 &= 2 - z + \frac{z^2}{8};
 \end{aligned}$$

todėl

$$P\{Z \leq z\} = -1 + z - \frac{z^2}{8}.$$

Išdiferencijavęs gautas lygybes, gaunu, kad  $Z$  turi tankį

$$p(z) = \begin{cases} z/4, & \text{kai } 0 < z < 2; \\ 1 - z/4, & \text{kai } 2 < z < 4. \end{cases}$$

## 1.2 Asimptotiniai skirstiniai

### 1.2.1 Uždavinio formulavimas

Jei atsitiktinių dydžių seka  $T_n$  konverguoja pagal pasiskirstymą į atsitiktinį dydį  $T$ , rašau  $T_n \rightarrow T$ . Tikslų šio termino apibrėžimą duosiu kitame skyriuje. Ten taip pat įrodysiu ir daugumą tokio konvergavimo savybių. Dabar gi reikia išmokti dirbti su šia sąvoka.

Pagrindinis uždavinys, kurį reikia mokėti spręsti — rasti sekos  $T_n$  *asimptotinį skirstinį*. Šie žodžiai reiškia, kad reikia rasti tokias skaičių sekas  $a_n$  ir  $b_n$ , kad

$$b_n(T_n - a_n) \rightarrow T;$$

čia  $T$  — koks nors neišsigimęs atsitiktinis dydis (t.y. dydis, nelygus konstantai su tikimybe 1). Tokiu atveju galima sakyti, kad jei  $n$  didelis, tai  $T_n$  skirstinys maždaug sutampa su  $a_n + b_n^{-1}T$  dydžio skirstiniu (kuris ir vadinamas asimptotiniu  $T_n$  skirstiniu).

Mano duodamuose uždaviniuose dažniausiai bus galima imti  $a_n = a$  ir  $b_n = \sqrt{n}$ ; čia  $a$  — tam tikra konstanta. Bet apskritai gali atsitikti visko. Pavyzdžiui, jei

$$\sqrt{n}(T_n - a) \rightarrow T,$$

o  $U_n = nT_n$ , tai

$$n^{-1/2}(U_n - na) \rightarrow T,$$

t.y. šiuo atveju  $a_n = na$ , o  $b_n = n^{-1/2}$ .

### 1.2.2 Empiriniai vidurkiai

Mano duodamuose uždaviniuose  $T_n$  bus

$$T_n = \varphi_n(X_1, \dots, X_n)$$

pavidalo; čia  $X_1, \dots, X_n$  yra nepriklausomi vienodai pasiskirstę atsitiktiniai dydžiai, o  $\varphi_n$  — kokios nors gražios funkcijos. Jei  $X$  yra atsitiktinis dydis, pasiskirstęs taip pat, kaip kiekvienas  $X_i$ , dažnai sakysiu, kad  $X_1, \dots, X_n$  yra *nepriklausomos  $X$  kopijos*, arba *imtis iš  $X$  skirstinio*. Atsitiktinius dydžius  $T_n$  paprastai vadinsiu *statistikomis*.

Labai svarbios yra

$$\overline{f(X)} = \frac{f(X_1) + \dots + f(X_n)}{n}$$

pavidalo statistikos (empiriniai vidurkiai). Pavyzdžiui,

$$\overline{X} = \frac{X_1 + \dots + X_n}{n}, \quad \overline{X^2} = \frac{X_1^2 + \dots + X_n^2}{n}$$

ir pan.

Reikia žinoti tokias naudingas empirinių vidurkių savybes:

$$\overline{c} = c, \quad \overline{cX} = c\overline{X}, \quad \overline{X+Y} = \overline{X} + \overline{Y}.$$

Bet apskritai

$$\overline{XY} \neq \overline{X}\overline{Y}.$$

Pavyzdžiui, visada  $\overline{X^2} \geq [\overline{X}]^2$  ir lygybė galima tik tada, kai visi  $X_i$  sutampa.

Jei  $f$  yra  $A$  aibės indikatorius  $1_A$ , tai vietoje  $1_A(X)$  aš mėgstu rašyti  $1_{\{X \in A\}}$ . Tokiu atveju

$$\overline{1_{\{X \in A\}}} = \frac{N}{n};$$

čia  $N$  yra  $A$  aibės elementų skaičius  $X_1, \dots, X_n$  imtyje.

### 1.2.3 Normalusis skirstinys

Simboliu  $N(\mu, \sigma^2)$  aš žymiu atsitiktinį dydį, turintį normalųjį skirstinį su vidurkiu  $\mu$  ir dispersija  $\sigma^2$ . Gerai žinoma, kad jei  $X$  pasiskirstęs normaliai, tai  $a + bX$  taip pat pasiskirstęs normaliai, tik su kitais parametrais: vidurkiu  $a + b\mu$  ir dispersija  $b^2\sigma^2$ . Todėl aš dažnai rašau

$$a + bN(\mu, \sigma^2) = N(a + b\mu, b^2\sigma^2).$$

Pavyzdžiui,

$$3N(0, 0.4) = N(0, 3.6).$$

### 1.2.4 Pagrindiniai asimptotinių skirstinių ieškojimo metodai

Ieškodami asimptotinių statistikų skirstinių, naudojames tokiais teiginiais:

- (didžiųjų skaičių dėsnis) jei  $EX = a$ , tai

$$\overline{X} \rightarrow a;$$

- (centrinė ribinė teorema) jei  $EX = a$ ,  $DX = \sigma^2$ , tai

$$\sqrt{n}(\overline{X} - a) \rightarrow N(0, \sigma^2);$$

- (tolydaus atvaizdžio principas) jei  $T_n \rightarrow T$ ,  $U_n^{(1)} \rightarrow u_1, \dots, U_n^{(k)} \rightarrow u_k$ , tai

$$\varphi(T_n, U_n^{(1)}, \dots, U_n^{(k)}) \rightarrow \varphi(T, u_1, \dots, u_k);$$

- (delta metodas) jei  $b_n \rightarrow \infty$  ir  $b_n(T_n - a) \rightarrow T$ , tai

$$b_n(g(T_n) - g(a)) \rightarrow g'(a)T.$$

Tikslūs paskutinių dviejų teiginių formulavimai ir įrodymai bus duoti kitame skyriuje.

### 1.2.5 Pavyzdžiai

1.5 PAVYZDYS. Atsitiktinio dydžio  $X$  skirstinys užrašytas lentelė

|     |     |     |     |     |
|-----|-----|-----|-----|-----|
| $X$ | -1  | 0   | 1   | 2   |
|     | 0.2 | 0.2 | 0.2 | 0.4 |

o  $X_1, \dots, X_n$  yra nepriklausomos  $X$  kopijos. Raskite nurodytų statistikų asimptotinį skirstinį:

- a)  $\frac{N^0}{N^+ - N^-}$ ;  
 b)  $\frac{\sqrt{(N^+)^2 + n^2}}{N^+ + n}$ ;  
 c)  $\frac{n\bar{X} - N^0}{N^+}$ ;

čia  $N^+$ ,  $N^-$  ir  $N^0$  yra, atitinkamai, teigiamų, neigiamų ir lygių nuliui narių skaičius imtyje  $X_1, \dots, X_n$ .

*Sprendimas.* a. Pažymiu

$$T_n = \frac{N^0}{N^+ - N^-} = \frac{N^0/n}{N^+/n - N^-/n} = \frac{\overline{1_{\{X=0\}}}}{\overline{1_{\{X>0\}}} - \overline{1_{\{X<0\}}}}.$$

Pagal didžiųjų skaičių dėsnį

$$\begin{aligned} \overline{1_{\{X=0\}}} &\rightarrow E 1_{\{X=0\}} = 0.2; \\ \overline{1_{\{X>0\}}} &\rightarrow E 1_{\{X>0\}} = 0.2 + 0.4 = 0.6; \\ \overline{1_{\{X<0\}}} &\rightarrow E 1_{\{X<0\}} = 0.2; \end{aligned}$$

todėl pagal tolydaus atvaizdžio principą

$$T_n \rightarrow \frac{0.2}{0.6 - 0.2} = \frac{1}{2}.$$

Turiu:

$$T_n - \frac{1}{2} = \frac{\overline{1_{\{X=0\}}} - \frac{1}{2}\overline{1_{\{X>0\}}} + \frac{1}{2}\overline{1_{\{X<0\}}}}{\overline{1_{\{X>0\}}} - \overline{1_{\{X<0\}}}} = \frac{1_{\{X=0\}} - \frac{1}{2}1_{\{X>0\}} + \frac{1}{2}1_{\{X<0\}}}{1_{\{X>0\}} - 1_{\{X<0\}}}.$$

Kadangi

$$\begin{aligned} E\left[1_{\{X=0\}} - \frac{1}{2}1_{\{X>0\}} + \frac{1}{2}1_{\{X<0\}}\right] &= E 1_{\{X=0\}} - \frac{1}{2}E 1_{\{X>0\}} + \frac{1}{2}E 1_{\{X<0\}} \\ &= 0.2 - \frac{1}{2}0.6 + \frac{1}{2}0.2 \\ &= 0, \\ E\left[1_{\{X=0\}} - \frac{1}{2}1_{\{X>0\}} + \frac{1}{2}1_{\{X<0\}}\right]^2 &= \frac{1}{4}0.2 + 0.2 + \frac{1}{4}(0.2 + 0.4) \\ &= 0.4, \\ D\left[1_{\{X=0\}} - \frac{1}{2}1_{\{X>0\}} + \frac{1}{2}1_{\{X<0\}}\right] &= 0.4, \end{aligned}$$

iš centrinės ribinės teoremos gaunu

$$\sqrt{n}\left[\overline{1_{\{X=0\}}} - \frac{1}{2}\overline{1_{\{X>0\}}} + \frac{1}{2}\overline{1_{\{X<0\}}}\right] \rightarrow N(0, 0.4).$$

Reiškia, vėl pagal tolydaus atvaizdžio principą,

$$\sqrt{n}\left[T_n - \frac{1}{2}\right] \rightarrow \frac{N(0, 0.4)}{0.6 - 0.2} = \frac{1}{0.4}N(0, 0.4) = N\left(0, \frac{1}{0.4}\right) = N\left(0, \frac{5}{2}\right).$$

b. Pažymiu

$$T_n = \frac{\sqrt{(N^+)^2 + n^2}}{N^+ + n} = \frac{\sqrt{(N^+/n)^2 + 1}}{N^+/n + 1} = g(N^+/n) = g(\overline{1_{\{X>0\}}});$$

čia  $g(t) = \sqrt{t^2 + 1}/(t + 1)$ .

Kadangi

$$E 1_{\{X>0\}}^2 = E 1_{\{X>0\}} = 0.6,$$

to dydžio dispersija lygi  $0.6 - 0.36 = 0.24$ ; todėl pagal centrinę ribinę teoremą

$$\sqrt{n}(\overline{1_{\{X>0\}}} - 0.6) \rightarrow N(0, 0.24).$$

Kadangi  $g(0.6) = \sqrt{1.36}/1.6$ ,

$$g'(t) = \frac{\frac{1}{2\sqrt{t^2+1}} \cdot 2t(t+1) - \sqrt{t^2+1}}{(t+1)^2} = \frac{t-1}{(t+1)^2\sqrt{t^2+1}}$$

ir  $g'(0.6) = -0.4/(2.56\sqrt{1.36})$ , pritaikęs delta metodą gaunu

$$\sqrt{n}\left(T_n - \frac{\sqrt{1.36}}{1.6}\right) \rightarrow -\frac{1}{6.4\sqrt{1.36}}N(0, 0.24) = N\left(0, \frac{0.24}{6.4^2 \cdot 1.36}\right) \approx N(0, 0.0043).$$

c. Pažymiu

$$T_n = \frac{n\overline{X} - N^0}{N^+} = \frac{\overline{X} - N^0/n}{N^+/n} = \frac{\overline{X} - \overline{1_{\{X=0\}}}}{\overline{1_{\{X>0\}}}}.$$

Iš didžiųjų skaičių dėsnio

$$\overline{X} \rightarrow E X = -0.2 + 0 + 0.2 + 0.8 = 0.8;$$

$$\overline{1_{\{X=0\}}} \rightarrow E 1_{\{X=0\}} = 0.2;$$

$$\overline{1_{\{X>0\}}} \rightarrow E 1_{\{X>0\}} = 0.6;$$

todėl

$$T_n \rightarrow \frac{0.8 - 0.2}{0.6} = 1.$$

Toliau:

$$T_n - 1 = \frac{\overline{X} - \overline{1_{\{X=0\}}} - \overline{1_{\{X>0\}}}}{\overline{1_{\{X>0\}}}} = \frac{\overline{X - 1_{\{X=0\}} - 1_{\{X>0\}}}}{\overline{1_{\{X>0\}}}}.$$

Kadangi

$$E X - 1_{\{X=0\}} - 1_{\{X>0\}} = E X - E 1_{\{X=0\}} - E 1_{\{X>0\}} = 0.8 - 0.2 - 0.6 = 0,$$

$$E[X - 1_{\{X=0\}} - 1_{\{X>0\}}]^2 = 0.2 + 0.2 + 0 + 0.4 = 0.8,$$

šio dydžio dispersija taip pat yra 0.8. Todėl iš centrinės ribinės teoremos

$$\sqrt{n}\overline{X - 1_{\{X=0\}} - 1_{\{X>0\}}} \rightarrow N(0, 0.8).$$

Tada iš tolydaus atvaizdžio principo

$$\sqrt{n}(T_n - 1) \rightarrow \frac{N(0, 0.8)}{0.6} = N\left(0, \frac{2}{9}\right).$$



1.6 PAVYZDYS. Atsitiktinio dydžio  $X$  tankis

$$p(x) = \begin{cases} 1/2, & \text{kai } -1 < x < 0; \\ x, & \text{kai } 0 < x < 1; \end{cases}$$

o  $X_1, \dots, X_n$  yra nepriklausomos  $X$  kopijos. Raskite nurodytų statistikų asimptotinį skirstinį:

a)  $\frac{N^+}{2n + N^-};$

b)  $\ln(\bar{X} + 2);$

c)  $\frac{\bar{X} - \bar{X}^3}{\bar{X}^2};$

čia  $N^+$  ir  $N^-$  yra, atitinkamai, teigiamų ir neigiamų narių skaičius imtyje  $X_1, \dots, X_n$ .

*Sprendimas.* a. Pažymiu

$$T_n = \frac{N^+}{2n + N^-} = \frac{N^+/n}{2 + N^-/n} = \frac{\overline{1_{\{X>0\}}}}{2 + \overline{1_{\{X<0\}}}} = \frac{\overline{1_{\{X>0\}}}}{3 - \overline{1_{\{X>0\}}}} = g(\overline{1_{\{X>0\}}});$$

čia

$$g(t) = \frac{t}{3-t}.$$

Kadangi

$$E 1_{\{X>0\}}^2 = E 1_{\{X>0\}} = \int_0^1 x \, dx = \frac{x^2}{2} \Big|_0^1 = \frac{1}{2},$$

to dydžio dispersija lygi  $\frac{1}{2} - \frac{1}{4} = \frac{1}{4}$ . Todėl iš centrinės ribinės teoremos

$$\sqrt{n}(\overline{1_{\{X>0\}}} - 0.5) \rightarrow N(0, 0.25).$$

Kadangi

$$g'(t) = \frac{3-t-t \cdot (-1)}{(3-t)^2} = \frac{3}{(3-t)^2},$$

pritaikęs delta metodą gaunu

$$\sqrt{n}(T_n - g(0.5)) \rightarrow g'(0.5)N(0, 0.25);$$

$$\sqrt{n}\left(T_n - \frac{0.5}{2.5}\right) \rightarrow \frac{3}{2.5^2}N(0, 0.25);$$

$$\sqrt{n}\left(T_n - \frac{1}{5}\right) \rightarrow \frac{12}{25}N(0, 0.25) = N\left(0, \frac{1.44}{25}\right) = N(0, 0.0576).$$

b. Pažymiu

$$T_n = \ln(\bar{X} + 2) = g(\bar{X});$$

čia  $g(x) = \ln(x + 2)$ .

Kadangi

$$E X = \int_{-1}^1 xp(x)dx$$

$$\begin{aligned}
&= \int_{-1}^0 x \cdot \frac{1}{2} dx + \int_0^1 x^2 dx \\
&= \frac{1}{2} \frac{x^2}{2} \Big|_{-1}^0 + \frac{x^3}{3} \Big|_0^1 \\
&= -\frac{1}{4} + \frac{1}{3} \\
&= \frac{1}{12}
\end{aligned}$$

ir analogiškai

$$\begin{aligned}
EX^2 &= \frac{1}{2} \int_{-1}^0 x^2 dx + \int_0^1 x^3 dx \\
&= \frac{x^3}{6} \Big|_{-1}^0 + \frac{x^4}{4} \Big|_0^1 \\
&= \frac{1}{6} + \frac{1}{4} \\
&= \frac{5}{12},
\end{aligned}$$

atsitiktinio dydžio  $X$  dispersija yra  $\frac{5}{12} - \frac{1}{144} = \frac{59}{144}$ . Todėl iš centrinės ribinės teoremos

$$\sqrt{n} \left( \bar{X} - \frac{1}{12} \right) \rightarrow N \left( 0, \frac{59}{144} \right).$$

Kadangi

$$g'(x) = \frac{1}{x+2},$$

pritaikęs delta metodą gaunu

$$\sqrt{n} \left( T_n - \ln \frac{25}{12} \right) \rightarrow \frac{12}{25} N \left( 0, \frac{59}{144} \right) = N \left( 0, \frac{59}{625} \right).$$

c. Pažymiu

$$T_n = \frac{\bar{X} - \bar{X}^3}{\bar{X}^2}.$$

Jau žinau, kad  $EX = \frac{1}{12}$  ir  $EX^2 = \frac{5}{12}$ . Be to,

$$\begin{aligned}
EX^3 &= \frac{1}{2} \int_{-1}^0 x^3 dx + \int_0^1 x^4 dx \\
&= \frac{x^4}{8} \Big|_{-1}^0 + \frac{x^5}{5} \Big|_0^1 \\
&= -\frac{1}{8} + \frac{1}{5} \\
&= \frac{3}{40}.
\end{aligned}$$

Todėl iš didžiųjų skaičių dėsnio

$$\bar{X} \rightarrow \frac{1}{12},$$

$$\begin{aligned}\overline{X^2} &\rightarrow \frac{5}{12}, \\ \overline{X^3} &\rightarrow \frac{3}{40}\end{aligned}$$

ir pagal tolydaus atvaizdžio principą

$$T_n \rightarrow \frac{\frac{1}{12} - \frac{3}{40}}{\frac{5}{12}} = \frac{\frac{120}{120} - \frac{90}{120}}{\frac{5}{12}} = \frac{1}{50}.$$

Toliau

$$T_n - \frac{1}{50} = \frac{\overline{X} - \overline{X^3} - \frac{1}{50}\overline{X^2}}{\overline{X^2}} = \frac{\overline{X - X^3 - \frac{1}{50}X^2}}{\overline{X^2}}.$$

Kadangi

$$E\left[X - X^3 - \frac{1}{50}X^2\right] = \frac{1}{12} - \frac{3}{40} - \frac{1}{50} \cdot \frac{5}{12} = 0$$

ir

$$\begin{aligned}& E\left[X - X^3 - \frac{1}{50}X^2\right]^2 \\ &= \frac{1}{2} \int_{-1}^0 \left(x - x^3 - \frac{1}{50}x^2\right)^2 dx + \int_0^1 \left(x - x^3 - \frac{1}{50}x^2\right)^2 x dx \\ &= \frac{1}{2} \int_{-1}^0 \left(x^2 - \frac{1}{25}x^3 - \frac{4999}{2500}x^4 + \frac{1}{25}x^5 + x^6\right) dx \\ &\quad + \int_0^1 \left(x^3 - \frac{1}{25}x^4 - \frac{4999}{2500}x^5 + \frac{1}{25}x^6 + x^7\right) dx \\ &= \frac{1}{6} + \frac{1}{200} - \frac{4999}{25000} - \frac{1}{300} + \frac{1}{14} + \frac{1}{4} - \frac{1}{125} - \frac{4999}{15000} + \frac{1}{175} + \frac{1}{8},\end{aligned}$$

to dydžio dispersija taip pat lygi

$$\sigma^2 = \frac{1}{6} + \frac{1}{200} - \frac{4999}{25000} - \frac{1}{300} + \frac{1}{14} + \frac{1}{4} - \frac{1}{125} - \frac{4999}{15000} + \frac{1}{175} + \frac{1}{8}.$$

Todėl iš centrinės ribinės teoremos

$$\sqrt{n} \overline{X - X^3 - \frac{1}{50}X^2} \rightarrow N(0, \sigma^2),$$

o tada pagal tolydaus atvaizdžio principą

$$\sqrt{n} \left(T_n - \frac{1}{50}\right) \rightarrow \frac{N(0, \sigma^2)}{\frac{5}{12}} = N\left(0, \frac{144\sigma^2}{25}\right).$$



## 2 skyrius

# Stochastinis konvergavimas

### 2.1 Apibrėžimas ir pavyzdžiai

#### 2.1.1 Apibrėžimas

Tegu  $X_n$  ir  $X$  yra atsitiktiniai vektoriai su reikšmėmis  $\mathbb{R}^k$  erdvėje. Sakome, kad  $X_n$  konverguoja pagal pasiskirstymą į  $X$ , ir rašome  $X_n \rightarrow X$ , jei

$$E f(X_n) \rightarrow E f(X)$$

su bet kokia aprėžta tolydžia funkcija  $f: \mathbb{R}^k \rightarrow \mathbb{R}$ .

Aišku, kad jei  $X_n \rightarrow X$ , tai ir bet koks  $(X_n)$  sekos posekis konverguoja į  $X$ .

Jei  $X_n \rightarrow X$  ir  $X_n \rightarrow Y$ , tai  $X$  ir  $Y$  skirstiniai sutampa. Tai įrodoma taip. Jei  $O$  yra atviras  $\mathbb{R}^k$  poaibis, tai egzistuoja tokia tolydžių neneigiamų funkcija seka  $(f_m)$ , kad  $f_m \uparrow 1_O$ . Aišku, kad

$$E f_m(X) = \lim_{n \rightarrow \infty} E f_m(X_n) = E f_m(Y).$$

Todėl

$$P\{X \in O\} = \lim_{m \rightarrow \infty} E f_m(X) = \lim_{m \rightarrow \infty} E f_m(Y) = P\{Y \in O\}.$$

Tegu dabar  $\mathcal{M}$  yra aibė visų Borelio aibių  $A$ , su kuriomis  $P\{X \in A\} = P\{Y \in A\}$ . Iš tikimybių savybių išplaukia, kad

$$\mathbb{R}^k \in \mathcal{M};$$

$$A, B \in \mathcal{M}, A \subset B \Rightarrow B \setminus A \in \mathcal{M};$$

$$A_n \in \mathcal{M}, A_n \uparrow A \Rightarrow A \in \mathcal{M}.$$

Reiškia,  $\mathcal{M}$  yra monotoniška poaibių klasė. Kadangi jai priklauso visos atviros aibės, o atvirų aibių sankirta vėl atvira, iš teoremos apie monotonišką poaibių klasę išplaukia, kad  $\mathcal{M}$  sutampa su visų Borelio aibių sistema.

Jei visi  $X_n$  vektoriai išsigimę, t.y. beveik tikrai įgyja vienintelę reikšmę  $x_n$ , tai jie turi ribą tada ir tik tada, kai vektorių seka  $(x_n)$  konverguoja. Be to, jei  $x_n \rightarrow x$ , tai  $X_n \rightarrow X$ ; čia  $X$  yra išsigimęs atsitiktinis vektorius, beveik tikrai įgyjantis reikšmę  $x$ .

Įrodysiu tai. Tegu  $x_n \rightarrow x$ . Jei  $f$  yra bet kokia tolydžioji funkcija, tai

$$E f(X_n) = f(x_n) \rightarrow f(x) = E f(X).$$

Reiškia,  $X_n \rightarrow X$ .

Dabar įrodysiu, kad jei  $(x_n)$  diverguoja, tai  $(X_n)$  taip pat neturi ribos. Čia galimi keli atvejai. Tegu iš pradžių  $\|x_n\| \rightarrow \infty$ . Tegu  $f_m(x) = g(\|x\|/m)$ ; čia

$$g(t) = \begin{cases} 1, & \text{kai } t \leq 1; \\ 2 - t, & \text{kai } 1 < t \leq 2; \\ 0, & \text{kai } t > 2. \end{cases}$$

Aišku, kad  $f_m$  yra tolydi funkcija,  $0 \leq f_m \leq 1$ ; be to  $f(x) = 1$ , kai  $\|x\| \leq m$ , ir  $f(x) = 0$ , kai  $\|x\| > 2m$ . Jei  $X_n \rightarrow X$ , iš čia išplauktų

$$P\{\|X\| \leq m\} \leq E f_m(X) = \lim_{n \rightarrow \infty} E f_m(X_n) = \lim_{n \rightarrow \infty} f_m(x_n) = 0.$$

Tada  $P\{\|X\| < \infty\} = 0$ , o to negali būti. Reiškia,  $X_n \not\rightarrow X$  su jokia  $X$ .

Bendruoju atveju, jei  $(x_n)$  nekonverguoja, tai arba  $\|x_{n_k}\| \rightarrow \infty$  su koku nors posekiu  $(n_k)$ , arba kokie nors du jos posekiai turi skirtingas ribas. Pirmuoju atveju tam tikras  $(X_{n_k})$  posekis neturi ribos, antruoju — du  $(X_n)$  sekos posekiai turi skirtingas ribas. Abiem atvejais  $(X_n)$  seka ribos neturi.

### 2.1.2 Pavyzdžiai

2.1 PAVYZDYS. Tegu  $X_n$  skirstinys aprašomas lentele

|       |               |     |                 |
|-------|---------------|-----|-----------------|
| $X_n$ | $\frac{1}{n}$ | 1   | $\frac{n}{n+1}$ |
|       | 0.4           | 0.3 | 0.3             |

Tada

$$E f(X_n) = 0.4f\left(\frac{1}{n}\right) + 0.3f(1) + 0.3f\left(\frac{n}{n+1}\right).$$

Aišku, kad  $\frac{1}{n} \rightarrow 0$ ,  $\frac{n}{n+1} \rightarrow 1$ . Jei  $f$  tolydi, tai

$$f\left(\frac{1}{n}\right) \rightarrow f(0), \quad f\left(\frac{n}{n+1}\right) \rightarrow f(1)$$

ir todėl

$$E f(X_n) \rightarrow 0.4f(0) + 0.3f(1) + 0.3f(1) = 0.4f(0) + 0.6f(1).$$

Reiškinys dešinėje pusėje sutampa su  $E f(X)$ , jei  $X$  yra atsitiktinis dydis, kurio skirstinys aprašomas lentele

|     |     |     |
|-----|-----|-----|
| $X$ | 0   | 1   |
|     | 0.4 | 0.6 |

Reiškia,  $X_n \rightarrow X$ .

2.2 PAVYZDYS. Tegu  $X_n$  skirstinys aprašomas lentele

|       |               |               |                   |
|-------|---------------|---------------|-------------------|
| $X_n$ | 1             | 2             | 3                 |
|       | $\frac{1}{n}$ | $\frac{2}{n}$ | $1 - \frac{3}{n}$ |

Tada

$$E f(X_n) = \frac{1}{n}f(1) + \frac{2}{n}f(2) + \left(1 - \frac{3}{n}\right)f(3) \rightarrow f(3) = E f(X);$$

čia  $X$  yra išsigimęs atsitiktinis dydis, įgyjantis reikšmę 3 su tikimybe 1. Tokį dydį aš žymiu tiesiog 3. Taigi  $X_n \rightarrow 3$ .

2.3 PAVYZDYS. Tegu  $X_n$  skirstinys aprašomas lentele

|       |               |                             |               |
|-------|---------------|-----------------------------|---------------|
| $X_n$ | 0             | 1                           | $n$           |
|       | $\frac{1}{2}$ | $\frac{1}{2} - \frac{1}{n}$ | $\frac{1}{n}$ |

Tada

$$E f(X_n) = \frac{1}{2}f(0) + \left(\frac{1}{2} - \frac{1}{n}\right)f(1) + \frac{1}{n}f(n).$$

Jei  $f$  aprėžta, tai  $f(n)/n \rightarrow 0$ ; todėl

$$E f(X_n) \rightarrow \frac{1}{2}f(0) + \frac{1}{2}f(1) = E f(X);$$

čia  $X$  yra atsitiktinis dydis, kurio skirstinys aprašomas lentele

|     |     |     |
|-----|-----|-----|
| $X$ | 0   | 1   |
|     | 0.5 | 0.5 |

Taigi  $X_n \rightarrow X$ .

2.4 PAVYZDYS. Tegu  $X_n$  skirstinys aprašomas lentele

|       |               |               |         |               |
|-------|---------------|---------------|---------|---------------|
| $X_n$ | $\frac{1}{n}$ | $\frac{2}{n}$ | $\dots$ | 1             |
|       | $\frac{1}{n}$ | $\frac{1}{n}$ | $\dots$ | $\frac{1}{n}$ |

Tada

$$E f(X_n) = \frac{1}{n}f(1/n) + \frac{1}{n}f(2/n) + \dots + \frac{1}{n}f(1)$$

Reiškinys dešinėje pusėje yra funkcijos  $f$  integralinė suma  $(0; 1)$  intervale, atitinkanti intervalo skaidinį į  $n$  lygių dalių. Todėl

$$E f(X_n) \rightarrow \int_0^1 f(x)dx = E f(X);$$

čia  $X$  yra atsitiktinis dydis, pasiskirstęs tolygiai  $(0; 1)$  intervale. Reiškia,  $X_n \rightarrow X$ .

2.5 PAVYZDYS. Jei  $X_n$  yra tolydūs atsitiktiniai dydžiai su tankiais  $p_n(x)$ ,  $p(x)$  yra dar vienas tankis ir  $p_n(x) \rightarrow p(x)$  su visais  $x$ , tai  $X_n$  konverguoja į atsitiktinį dydį  $X$ , kurio tankis yra  $p(x)$ . Tai įrodoma taip.

Jei  $f$  yra tolydi aprėžta funkcija, tai

$$\begin{aligned} |E f(X_n) - E f(X)| &= \left| \int f(x)p_n(x)dx - \int f(x)p(x)dx \right| \\ &\leq c \int |p_n(x) - p(x)|dx \end{aligned}$$

$$= c \int_{p_n \geq p} (p_n(x) - p(x)) dx + c \int_{p > p_n} (p(x) - p_n(x)) dx.$$

Kadangi  $p_n$  yra tankis,

$$\int_{p_n \geq p} p_n(x) dx = 1 - \int_{p_n < p} p_n(x) dx.$$

Analogiškai gaunu

$$\int_{p_n \geq p} p(x) dx = 1 - \int_{p_n < p} p(x) dx.$$

Reiškia,

$$|E f(X_n) - E f(X)| \leq 2c \int_{p > p_n} (p(x) - p_n(x)) dx \leq 2c \int_{p > p_n} p(x) dx \rightarrow 0,$$

nes  $1_{\{p > p_n\}}(x) \rightarrow 0$  su visais  $x$ .

### 2.1.3 Kaip įrodyti, kad ribos nėra

Yra du pagrindiniai atvejai, kada  $X_n$  seka neturi ribos pagal pasiskirstymą:

- kai du sekos posekiai turi skirtingas ribas;
- kai dalis skirstinio masės dingsta begalybėje.

Pirmąjį atvejį iliustruoja toks pavyzdys.

2.6 PAVYZDYS. Tegu  $X_n$  skirstinys aprašomas lentele

$$\begin{array}{c|cc} X_n & 1 & 2 \\ \hline & \frac{1}{2} + \frac{(-1)^n n}{2n+1} & \frac{1}{2} - \frac{(-1)^n n}{2n+1} \end{array}$$

Jei  $n = 2k$ , tai lentelė supaprastėja:

$$\begin{array}{c|cc} X_{2k} & 1 & 2 \\ \hline & \frac{1}{2} + \frac{2k}{4k+1} & \frac{1}{2} - \frac{2k}{4k+1} \end{array}$$

Šiuo atveju

$$E f(X_{2k}) = \left(\frac{1}{2} + \frac{2k}{4k+1}\right) f(1) + \left(\frac{1}{2} - \frac{2k}{4k+1}\right) f(2) \rightarrow f(1);$$

todėl  $X_{2k} \xrightarrow[k \rightarrow \infty]{} 1$ .

Jei  $n = 2k + 1$ ,  $X_n$  skirstinys aprašomas tokia lentele:

$$\begin{array}{c|cc} X_{2k+1} & 1 & 2 \\ \hline & \frac{1}{2} - \frac{2k}{4k+1} & \frac{1}{2} + \frac{2k}{4k+1} \end{array}$$

Šiuo atveju

$$E f(X_{2k+1}) = \left(\frac{1}{2} - \frac{2k}{4k+1}\right) f(1) + \left(\frac{1}{2} + \frac{2k}{4k+1}\right) f(2) \rightarrow f(2);$$

todėl  $X_{2k+1} \xrightarrow[k \rightarrow \infty]{} 2$ .

Taigi  $X_n$  seka ribos neturi.



Antrą atvejį iliustruoja kitas pavyzdys.

2.7 PAVYZDYS. Tegu  $X_n$  skirstinys aprašomas lentele

|       |     |     |
|-------|-----|-----|
| $X_n$ | 1   | $n$ |
|       | 0.4 | 0.6 |

Tada

$$E f(X_n) = 0.4f(1) + 0.6f(n).$$

Galima sugalvoti tokią aprėžtą tolydžią funkciją  $f$ , kad seka  $f(n)$  neturėtų ribos (pavyzdžiui, jei  $f(x) = \cos \pi x$ , tai  $f(n) = \cos \pi n = (-1)^n$ ). Tada  $E f(X_n)$  neturi ribos ir, reiškia,  $X_n \not\rightarrow X$  su jokia  $X$ . Tačiau paprastai šis faktas įrodomas, pasirinkus vienu teiginiu, kurį ruošiuosi įrodyti vėliau šiame skyriuje.

Teiginys, kurį ruošiuosi įrodyti vėliau, skamba taip: jei  $X_n \rightarrow X$ , tai  $X_n = O_P(1)$ , t.y.

$$\sup_n P\{|X_n| \geq k\} \xrightarrow{k \rightarrow \infty} 0.$$

Iš čia išplaukia, kad su bet koku posekiu  $n_k$

$$P\{|X_{n_k}| \geq k\} \xrightarrow{k \rightarrow \infty} 0.$$

Nagrinėjame pavyzdyje paimu  $n_k = k$ . Tada

$$P\{|X_k| \geq k\} = 0.6 \not\rightarrow 0;$$

todėl  $X_n \not\rightarrow X$  su jokia  $X$ .

## 2.2 Portmanto lema

### 2.2.1 Formulavimas ir įrodymas

**2.1 teorema.** *Tokie penki teiginiai yra ekvivalentūs:*

- 1)  $X_n \rightarrow X$ ;
- 2)  $E f(X_n) \rightarrow E f(X)$  su bet kokia aprėžta Lipšico funkcija  $f$ ;
- 3)  $\underline{\lim} P\{X_n \in O\} \geq P\{X \in O\}$  su bet kokia atvira aibe  $O$ ;
- 4)  $\overline{\lim} P\{X_n \in C\} \leq P\{X \in C\}$  su bet kokia uždara aibe  $C$ ;
- 5)  $P\{X_n \in A\} \rightarrow P\{X \in A\}$  su bet kokia Borelio aibe  $A$ , tenkinančia sąlygą  $P\{X \in \partial A\} = 0$ .

*Įrodymas.* (1  $\Rightarrow$  2) Akivaizdu, nes kiekviena Lipšico funkcija tolydi.

(2  $\Rightarrow$  3) Raskime tokią aprėžtą Lipšico funkcijų seką  $(f_m)$ , kad  $f_m \uparrow 1_O$  (tinka, pavyzdžiui,  $f_m(x) = [md(x, O^c)] \wedge 1$ ). Tada su visais  $m$

$$\underline{\lim} P\{X_n \in O\} \geq \lim_{n \rightarrow \infty} E f_m(X_n) = E f_m(X); \quad (2.1)$$

todėl

$$\underline{\lim} P\{X_n \in O\} \geq \lim_{m \rightarrow \infty} E f_m(X) = P\{X \in O\}. \quad (2.2)$$

(3  $\Rightarrow$  4) Tegu  $C$  uždara ir  $O = C^c$ . Tada  $O$  atvira ir todėl

$$\overline{\lim} P\{X_n \in C\} = 1 - \underline{\lim} P\{X_n \in O\} \leq 1 - P\{X \in O\} = P\{X \in C\}. \quad (2.3)$$

Analogiškai įrodoma  $4 \Rightarrow 3$  implikacija.

( $4 \Rightarrow 5$ ) Tegū  $A$  yra Borelio poaibis,  $C = \bar{A}$  ir  $O = \text{Int } A$ . Tada

$$\begin{aligned} P\{X \in O\} &\leq \underline{\lim} P\{X_n \in O\} \leq \underline{\lim} P\{X_n \in A\} \\ &\leq \overline{\lim} P\{X_n \in A\} \leq \overline{\lim} P\{X_n \in C\} \leq P\{X \in C\}. \end{aligned} \quad (2.4)$$

Iš  $P\{X \in \partial A\} = 0$  išplaukia, kad  $P\{X \in O\} = P\{X \in C\} = P\{X \in A\}$ .  
Reiškia,  $P\{X_n \in A\} \rightarrow P\{X \in A\}$ .

( $5 \Rightarrow 1$ ) Tegū  $f$  yra bet kokia aprėžta tolydi funkcija. Tarkime  $f(x) \in (-c; c)$  su visais  $x$ .

Randu tokią  $(-c; c)$  intervalo skaidinių seką  $(c_{n0}, \dots, c_{ns_n})$ , kad

$$c_{nj} - c_{n,j-1} \leq \frac{1}{n} \quad \text{ir} \quad P\{f(X) = c_{nj}\} = 0$$

su visais  $j$  ir  $n$ . Pažymiu

$$A_{nj} = \{x \mid c_{n,j-1} \leq f(x) < c_{nj}\}, \quad g_n = \sum_{j=1}^{s_n} c_{n,j-1} 1_{A_{nj}} \quad \text{ir} \quad h_n = \sum_{j=1}^{s_n} c_{nj} 1_{A_{nj}}.$$

Aišku, kad  $g_n, h_n$  yra Borelio funkcijos  $|g_n| \leq c, |h_n| \leq c, g_n \leq f \leq h_n, g_n \rightarrow f$  ir  $h_n \rightarrow f$ .

Dėl  $f$  tolydumo aibės  $O_{nj} = \{x \mid c_{n,j-1} < f(x) < c_{nj}\}$  yra atviros, o aibės  $C_{nj} = \{x \mid c_{n,j-1} \leq f(x) \leq c_{nj}\}$  — uždaros. Reiškia,

$$\partial A_{nj} \subset C_{nj} \setminus O_{nj} = \{x \mid f(x) = c_{n,j-1}\} \cup \{x \mid f(x) = c_{nj}\} \quad (2.5)$$

ir todėl  $P(X \in \partial A_{nj}) = 0$ . Su kiekvienu  $m$

$$E f(X_n) \geq E g_m(X_n) \rightarrow E g_m(X); \quad (2.6)$$

todėl

$$\underline{\lim} E f(X_n) \geq \lim_{m \rightarrow \infty} E g_m(X) = E f(X). \quad (2.7)$$

Analogiškai gaunu, kad su visais  $m$

$$E f(X_n) \leq E h_m(X_n) \rightarrow E h_m(X);$$

todėl

$$\overline{\lim} E f(X_n) \geq \lim_{m \rightarrow \infty} E h_m(X) = E f(X).$$

Reiškia,  $E f(X_n) \rightarrow E f(X)$ .  $\square$

## 2.2.2 Įrodymo paaiškinimai

### 1. Kas yra Lipšico funkcija?

Funkcija  $f: \mathbb{R}^k \rightarrow \mathbb{R}$  vadinama Lipšico, jei egzistuoja tokia konstanta  $q$ , kad su visais  $x, y \in \mathbb{R}^k$

$$|f(x) - f(y)| \leq q \|x - y\|.$$

### 2. Kodėl kiekviena Lipšico funkcija tolydi?

Jei  $x_n \rightarrow x$ , tai

$$|f(x_n) - f(x)| \leq q \|x_n - x\| \rightarrow 0,$$

t.y.  $f(x_n) \rightarrow f(x)$ .

**3.** Kodėl  $f_m$  funkcija aprėžta?

Nes  $0 \leq f_m(x) \leq 1$  su visais  $x$ .

**4.** Kodėl  $f_m$  yra Lipšico funkcija?

Nes

$$|f_m(x) - f_m(y)| \leq |md(x, O^c) - md(y, O^c)| \leq md(x, y) = m \|x - y\|.$$

Antras sąryšis išplaukia iš nelygybės

$$|d(x, A) - d(y, A)| \leq d(x, y),$$

teisingos bet kokioje metrinėje erdvėje.

Pirmas sąryšis išplaukia iš nelygybės

$$|a \wedge 1 - b \wedge 1| \leq |a - b|,$$

teisingos su visais  $a, b \geq 0$ . Nelygybė įrodoma, perrenkant visus galimus variantus:

jei  $a, b \leq 1$ , ji virsta  $|a - b| \leq |a - b|$  nelygybe;

jei  $a \leq 1 < b$ , ji virsta  $1 - a \leq b - a$  nelygybe, kuri teisinga, nes  $b > 1$ ;

jei  $a, b > 1$ , ji virsta  $0 \leq |a - b|$  nelygybe.

**5.** Kodėl  $f_m \uparrow 1_O$ ?

Šis klausimas išsiskaido į du: kodėl  $(f_m)$  yra nemažėjanti seka ir kodėl  $f_m \rightarrow 1_O$ ?

Atsakymas į pirmą klausimą: jei  $m < n$ , tai  $md(X, O^c) \leq nd(x, O^c)$  (nes  $d(x, O^c) \geq 0$ ) ir todėl  $md(X, O^c) \wedge 1 \leq nd(x, O^c) \wedge 1$  (tai galima įrodyti, perrenkant variantus).

Atsakymas į antrą klausimą: jei  $x \in O^c$ , tai

$$f_m(x) = (m \cdot 0) \wedge 1 = 0 \rightarrow 0 = 1_O(x);$$

jei  $x \in O$ , tai  $d(x, O^c) > 0$  (nes  $O^c$  uždara); todėl  $md(x, O^c) \rightarrow \infty$  ir

$$f_m(x) \rightarrow 1 = 1_O(x).$$

**6.** Kodėl teisingi sąryšiai (2.1) grandinėje?

Su visais  $n$

$$P\{X_n \in O\} = E 1_O(X_n) \geq E f_m(X_n)$$

(nes  $1_O \geq f_m$ ); todėl

$$\liminf_{n \rightarrow \infty} P\{X_n \in O\} \geq \liminf_{n \rightarrow \infty} E f_m(X_n).$$

Tačiau  $f_m$  yra Lipšico funkcija; todėl iš 2 prielaidos gauname  $E f_m(X_n) \rightarrow E f_m(X)$ , t.y.

$$\liminf_{n \rightarrow \infty} E f_m(X_n) = \lim_{n \rightarrow \infty} E f_m(X_n) = E f_m(X).$$

7. Kodėl teisingi sąryšiai (2.2) grandinėje?

Iš (2.1) išplaukia, kad su visais  $m$

$$\underline{\lim}_{n \rightarrow \infty} P\{X_n \in O\} \geq E f_m(X).$$

Iš čia

$$\underline{\lim}_{n \rightarrow \infty} P\{X_n \in O\} \geq \overline{\lim}_{m \rightarrow \infty} E f_m(X).$$

Tačiau iš  $0 \leq f_m \uparrow 1_O$  ir Lebego teoremos apie monotonišką konvergavimą išplaukia

$$E f_m(X) \uparrow E 1_O(X) = P\{X \in O\}.$$

Reiškia,

$$\overline{\lim}_{m \rightarrow \infty} E f_m(X) = \lim_{m \rightarrow \infty} E f_m(X) = P\{X \in O\}.$$

8. Kodėl teisingi sąryšiai (2.3) grandinėje?

Pirma lygybė gaunama pasirinkus tuo, kad

$$P\{X_n \in C\} = P\{X_n \notin O\} = 1 - P\{X_n \in O\},$$

ir tuo, kad

$$\overline{\lim}(1 - a_n) = 1 - \underline{\lim} a_n$$

su bet kokia seka  $(a_n)$ .

Antras sąryšis išplaukia iš 3 teoremos prielaidos, o paskutinė lygybė — vėl iš to, kad  $C = O^c$ .

9. Kodėl teisingi sąryšiai (2.4) grandinėje?

Pirma nelygybė teisinga, nes iš 4 prielaidos išplaukia 3 prielaida, o  $O$  aibė atvira. Antra nelygybė teisinga, nes  $O \subset A$ . Trečia nelygybė teisinga, nes apatinė sekos riba visada neviršija viršutinės. Ketvirta nelygybė teisinga, nes  $A \subset C$ . Paskutinė nelygybė išplaukia iš 4 prielaidos.

10. Kaip iš  $P\{X \in \partial A\} = 0$  išplaukia  $P\{X \in O\} = P\{X \in C\} = P\{X \in A\}$ ?

Kadangi  $O \subset A \subset C$  ir  $\partial A = C \setminus O$ ,

$$0 = P\{X \in \partial A\} = P\{X \in C\} - P\{X \in O\},$$

t.y.  $P\{X \in O\} = P\{X \in C\}$ . Kita vertus, iš  $O \subset A \subset C$  gauname

$$P\{X \in O\} \leq P\{X \in A\} \leq P\{X \in C\}.$$

Kraštiniai šios nelygybių grandinės nariai vienodi; todėl visos nelygybės virsta lygybėmis.

11. Kodėl daroma išvada, kad  $P\{X_n \rightarrow A\} \rightarrow P\{X \in A\}$ ?

Kraštiniai (2.4) grandinės nariai lygūs  $P\{X \in A\}$ . Reiškia, tam skaičiui lygūs ir visi kiti nariai; pavyzdžiui,

$$\underline{\lim}_{n \rightarrow \infty} P\{X_n \in A\} = \overline{\lim}_{n \rightarrow \infty} P\{X_n \in A\} = P\{X \in A\}.$$

Jei skaičių sekos apatinė ir viršutinė riba sutampa, tai ta sutampanti reikšmė ir yra sekos riba.

12. Kodėl egzistuoja tokia skaidinių seka  $(c_{nj})$ ?

Yra tik ne daugiau kaip skaiti aibė skaičių  $a$ , su kuriais  $P\{f(X) = a\} > 0$  (nes su kiekvienu  $k$  yra ne daugiau kaip  $k$  skirtingų  $a$ , su kuriais  $P\{f(X) = a\} \geq 1/k$ ). Todėl šalia kiekvieno  $a$  kiek norima arti yra toks  $a'$ , kad  $P\{f(X) = a'\} = 0$ .

Skaidinys  $(c_{nj})$  gali būti rastas taip: padaliname  $(-c; c)$  intervalą bet kaip į  $< \frac{1}{3n}$  ilgio gabalus ir šalia kiekvieno dalijimo taško  $c'_{nj}$  randame tokį  $c_{nj}$ , kad  $|c_{nj} - c'_{nj}| < \frac{1}{3n}$  ir  $P\{f(X) = c_{nj}\} = 0$ .

**13.** Kodėl  $|g_n| \leq c$ ?

Funkcija  $g_n$  įgyja tik reikšmes  $c_{n,j-1}$ ,  $j = 1, \dots, s_n$ . Taigi  $g_n(x) \geq c_{n0} = -c$  ir  $g_n(x) \leq c_{ns_n} = c$  su visais  $x$ .

**14.** Kodėl  $g_n \leq f \leq h_n$ ?

Koks bebūtų  $x$ , atsiras toks  $j$ , kad  $c_{n,j-1} \leq f(x) < c_{nj}$ . Tuomet  $g_n(x) = c_{n,j-1} \leq f(x)$ , o  $h_n(x) = c_{nj} \geq f(x)$ .

**15.** Kodėl  $g_n \rightarrow f$ ?

Jei  $c_{n,j-1} \leq f(x) < c_{nj}$ , tai

$$|g_n(x) - f(x)| = f(x) - c_{n,j-1} \leq c_{nj} - c_{n,j-1} \leq \frac{1}{n}.$$

**16.** Paaiškinkite smulkiau, kodėl  $O_{nj}$  atvira.

$O_{nj}$  yra atviros aibės  $(c_{n,j-1}; c_{nj})$  pirmavaizdis tolydžiosios funkcijos  $f$  atžvilgiu; todėl atvira.

**17.** Kodėl teisingi sąryšiai (2.5) grandinėje?

Kadangi  $C_{nj}$  uždara ir  $\supset A_{nj}$ , ji didesnė už  $\overline{A_{nj}}$ . Aibė  $O_{nj}$  atvira ir  $\subset A_{nj}$ ; todėl ji mažesnė už  $\text{Int } A_{nj}$ . Reiškia,

$$C_{nj} \setminus O_{nj} \supset \overline{A_{nj}} \setminus \text{Int } A_{nj} = \partial A_{nj}.$$

Antras sąryšis įrodomas taip. Tegu  $x \in C_{nj} \setminus O_{nj}$ . Tada  $x \in C_{nj}$ , t.y.

$$c_{n,j-1} \leq f(x) \leq c_{nj}.$$

Be to,  $x \notin O_{nj}$ , t.y. arba  $c_{n,j-1} < f(x)$ , arba  $f(x) < c_{nj}$  sąryšis neteisingas. Pirmu atveju gaunu  $f(x) = c_{n,j-1}$ , antruoju —  $f(x) = c_{nj}$ .

**18.** Kodėl  $P\{X \in \partial A\} = 0$ ?

Iš (2.5)

$$P\{X \in \partial A\} \leq P\{f(X) = c_{n,j-1}\} + P\{f(X) = c_{nj}\},$$

o pagal  $c_{nj}$  parinkimą  $P\{f(X) = c_{n,j-1}\} = P\{f(X) = c_{nj}\} = 0$ .

**19.** Kodėl teisingi sąryšiai (2.6) grandinėje?

Pirma nelygybė teisinga dėl to, kad  $g_n \leq f$ . Antras sąryšis — dėl to, kad

$$E g_m(X_n) = \sum_{j=1}^{s_m} c_{m,j-1} P\{X_n \in A_{mj}\}$$

ir pagal 5 prielaidą  $P\{X_n \in A_{mj}\} \rightarrow P\{X \in A_{mj}\}$  (nes  $P\{X \in \partial A_{mj}\} = 0$ ).

**20.** Kodėl teisingi sąryšiai (2.7) grandinėje?

Pirmas sąryšis išplaukia iš (2.6), o antras — iš Lebego teoremos apie aprėžtą konvergavimą (nes  $g_m \rightarrow f$  ir  $|g_m| \leq c$ ).

### 2.2.3 Komentarai

**21.** Jei  $X_n \rightarrow X$ , tai su bet kokia atvira  $O$

$$\underline{\lim}_{n \rightarrow \infty} P\{X_n \in O\} \geq P\{X \in O\}.$$

Nelygybės pakeisti lygybe apskritai negalima. Tegu, pavyzdžiui,  $X_n = 1/n$ ; tada  $X = 0$ . Aibė  $O = (0; \infty)$  atvira, bet su visais  $n$

$$P\{X_n \in O\} = 1, \quad \text{o} \quad P\{X \in O\} = 0.$$

Taip pat negalima  $\underline{\lim}$  pakeisti į lim, nes seka  $P\{X_n \in O\}$  gali neturėti ribos. Pavyzdžiui, jei  $X_n = (-1)^n/n$ ,  $X = 0$  ir  $O = (0; \infty)$ , tai

$$P\{X_n \in O\} = \begin{cases} 0, & \text{kai } n \text{ nelyginis;} \\ 1, & \text{kai } n \text{ lyginis;} \end{cases}$$

ir ribos neturi.

**22.** Jei  $X_n \rightarrow X$ , tai su bet kokia uždara  $C$

$$\overline{\lim}_{n \rightarrow \infty} P\{X_n \in C\} \leq P\{X \in C\}.$$

Nelygybės pakeisti lygybe apskritai negalima. Tegu, pavyzdžiui,  $X_n = -1/n$ ; tada  $X = 0$ . Aibė  $C = [0; \infty)$  uždara, bet su visais  $n$

$$P\{X_n \in C\} = 0, \quad \text{o} \quad P\{X \in C\} = 1.$$

Taip pat negalima  $\overline{\lim}$  pakeisti į lim, nes seka  $P\{X_n \in C\}$  gali neturėti ribos. Pavyzdžiui, jei  $X_n = (-1)^n/n$ ,  $X = 0$  ir  $C = [0; \infty)$ , tai

$$P\{X_n \in C\} = \begin{cases} 0, & \text{kai } n \text{ nelyginis;} \\ 1, & \text{kai } n \text{ lyginis;} \end{cases}$$

ir ribos neturi.

**23.** Jei  $X_n \rightarrow X$ , tai

$$P\{X_n \in A\} \rightarrow P\{X \in A\}$$

su bet kokia aibe  $A$ , tenkinančia sąlygą  $P\{X \in \partial A\} = 0$ . Pastarosios sąlygos praleisti apskritai negalima. Tegu, pavyzdžiui,  $X_n = 1/n$ ,  $X = 0$  ir  $A = (0; 1)$ . Tada su visais  $n$

$$P\{X_n \in A\} = 1, \quad \text{bet} \quad P\{X \in A\} = 0.$$

Priežastis, dėl kurios  $P\{X_n \in A\}$  nekonverguoja į  $P\{X \in A\}$ , paprasta: šiuo atveju  $\partial A = \{0, 1\}$  ir

$$P\{X \in \partial A\} = 0.$$

**24.** Jei  $(X_n)$  yra atsitiktinių dydžių seka ir  $X_n \rightarrow X$ , tai Portmanto lemos 5 teiginyje paėmęs  $A = (-\infty; x]$  gaunu

$$P\{X_n \leq x\} \xrightarrow{n \rightarrow \infty} P\{X \leq x\},$$

jei tik  $P\{X = x\} = 0$ .

Funkcija  $F(x) = P\{X \leq x\}$  vadinama atsitiktinio dydžio  $X$  pasiskirstymo funkcija, o sąlyga  $P\{X = x\} = 0$  reiškia, kad  $x$  yra tos funkcijos tolydumo taškas. Taigi jei  $X_n \rightarrow X$ ,  $F_n$  yra  $X_n$  dydžio, o  $F$  —  $X$  dydžio pasiskirstymo funkcija, tai  $F_n(x) \rightarrow F(x)$  kiekviename  $F$  funkcijos tolydumo taške  $x$ .

Teisingas ir atvirkščias teiginys: jei  $F_n(x) \rightarrow F(x)$  su kiekvienu  $x$ , kuriame  $F$  tolydi, tai  $X_n \rightarrow X$ . Jis įrodomas panašiai kaip  $5 \Rightarrow 1$  implikacija Portmanto lemoje. Aš tą faktą praleidau, nes toliau tikiuosi apseiti be pasiskirstymo funkcijų.

## 2.3 Konvergavimas į išsigimusį dydį

### 2.3.1 Teoremos

**2.2 teorema.** *Tokie du teiginiai ekvivalentūs:*

- 1)  $X_n \rightarrow a$ ;
- 2)  $P\{\|X_n - a\| \geq \varepsilon\} \rightarrow 0$  su visais  $\varepsilon$ .

*Įrodymas.* ( $1 \Rightarrow 2$ ) Tegu  $f$  yra tolydi neneigiama funkcija su tokiomis savybėmis:  $f(a) = 0$ ,  $f(x) = 1$ , kai  $\|x - a\| \geq \varepsilon$ . Pavyzdžiui, galiu paimti

$$f(x) = [\varepsilon^{-1}\|x - a\|] \wedge 1.$$

Tada

$$P\{\|X_n - a\| \geq \varepsilon\} \leq E f(X_n) \rightarrow f(a) = 0. \quad (2.8)$$

( $2 \Rightarrow 1$ ) Tegu  $f$  yra bet kokia tolydi aprėžta funkcija. Randu tokį  $c$ , kad  $|f(x)| \leq c$  su visais  $x$ , ir, fiksavęs  $\varepsilon$ , tokį  $\delta$ , kad  $|f(x) - f(a)| < \varepsilon$ , kai  $\|x - a\| < \delta$ . Tada

$$\begin{aligned} & |E f(X_n) - f(a)| \\ & \leq E |f(X_n) - f(a)| \\ & = E |f(X_n) - f(a)| 1_{\{\|X_n - a\| < \delta\}} + E |f(X_n) - f(a)| 1_{\{\|X_n - a\| \geq \delta\}} \\ & \leq \varepsilon + 2c P\{\|X_n - a\| \geq \delta\} \\ & = \varepsilon + o(1). \end{aligned} \quad (2.9)$$

Reiškia,

$$\overline{\lim} |E f(X_n) - f(a)| \leq \varepsilon. \quad (2.10)$$

Gauta nelygybė teisinga su visais  $\varepsilon$ ; todėl  $E f(X_n) \rightarrow f(a)$ .  $\square$

Iš įrodytos teoremos išplaukia ir tokie paprasti teiginiai:

- 1)  $X_n \rightarrow a \iff \|X_n - a\| \rightarrow 0$ ;
- 2) jei  $\|X_n - a\| \leq Y_n \rightarrow 0$ , tai  $X_n \rightarrow a$ .

Įrodysiu dar du teiginius.

**2.3 teorema.** 1. Jei  $X_n \rightarrow X$  ir  $\|X_n - Y_n\| \rightarrow 0$ , tai  $Y_n \rightarrow X$ .

2. Jei  $X_n \rightarrow X$ ,  $Y_n \rightarrow a$ , tai  $(X_n, Y_n) \rightarrow (X, a)$ .

*Įrodymas.* 1. Tegu  $f$  yra aprėžta Lipšico funkcija:  $|f(x)| \leq c$  su visais  $x$  ir  $|f(x) - f(y)| \leq q\|x - y\|$  su visais  $x, y$ . Kadangi

$$E f(Y_n) - E f(X) = E f(Y_n) - E f(X_n) + E f(X_n) - E f(X), \quad (2.11)$$

pakanka parodyti, kad  $E f(Y_n) - E f(X_n) \rightarrow 0$ . Tai išplaukia iš sąryšių

$$|E f(Y_n) - E f(X_n)| \leq E |f(Y_n) - f(X_n)| \leq q \|Y_n - X_n\| \rightarrow 0. \quad (2.12)$$

2. Kadangi

$$\|(X_n, Y_n) - (X_n, a)\| = \|Y_n - a\| \rightarrow 0, \quad (2.13)$$

pakanka įrodyti, kad  $(X_n, a) \rightarrow (X, a)$ . Tai išplaukia iš tokio samprotavimo. Jei  $f(x, y)$  yra aprėžta tolydi dviejų kintamųjų funkcija, tai  $f(x, a)$  yra aprėžta tolydi vieno kintamojo funkcija ir, reiškia,  $E f(X_n, a) \rightarrow E f(X, a)$ .  $\square$

### 2.3.2 Įrodymų paaiškinimai

Iš pradžių aiškinu 2.2 teoremos įrodymą.

**25.** Kodėl teisingi sąryšiai (2.8) grandinėje?

Pirma nelygybė teisinga dėl to, kad  $1_{\{\|x-a\| \geq \varepsilon\}} \leq f(x)$ , antras sąryšis — dėl to, kad  $f$  tolydi ir aprėžta, o  $X_n \rightarrow a$ . Paskutinė lygybė teisinga dėl  $f$  funkcijos parinkimo.

**26.** Kodėl egzistuoja toks  $\delta$ ?

Nes  $f$  tolydi  $a$  taške.

**27.** Kodėl teisingi sąryšiai (2.9) grandinėje?

Pirmas sąryšis išplaukia iš vidurkio savybių:

$$f(a) = E f(a) \quad \text{ir} \quad |E X - E Y| \leq E |X - Y|.$$

Antras — dėl to, kad

$$1_{\{\|X_n - a\| < \delta\}} + 1_{\{\|X_n - a\| \geq \delta\}} = 1$$

ir  $E(X + Y) = E X + E Y$ .

Trečia nelygybė gauta taip: pirmame integrale įvertinau

$$|f(X_n) - f(a)| \leq \varepsilon$$

(taip galima daryti, nes  $|f(x) - f(a)| < \varepsilon$ , kai  $\|x - a\| < \delta$ , o pirmame integrale  $\|X_n - a\| < \delta$ ); antrame integrale —

$$|f(X_n) - f(a)| \leq |f(X_n)| + |f(a)| \leq 2c$$

(tai teisėta, nes  $|f(x)| \leq c$  su visais  $x$ ).

Paskutinis sąryšis išplaukia iš teoremos 2 prielaidos.

**28.** Kodėl teisingas (2.10) sąryšis?

Suskaičiavau viršutinės ribas (2.9) nelygybėje.

Dabar aiškinu 2.3 teoremos įrodymą.

**29.** Kodėl pakanka įrodyti, kad  $E f(Y_n) - E f(X_n) \rightarrow 0$ ?



Jei tai įrodysiu, iš (2.11) išplauks, kad su bet kokia aprėžta Lipšico funkcija

$$E f(Y_n) \rightarrow E f(X)$$

(nes iš  $X_n \rightarrow X$  išplaukia  $E f(X_n) \rightarrow f(X)$ ). Tada  $Y_n \rightarrow X$  gausiu, pasirėmęs Portmanto lema.

**30.** Kodėl teisingi sąryšiai (2.12) grandinėje?

Pirmas sąryšis: ikėliau modulį į vduokį; antras sąryšis: nes  $|f(x) - f(y)| \leq q\|x - y\|$  su visais  $x$  ir  $y$ ; trečias sąryšis: nes duota  $\|X_n - Y_n\| \rightarrow 0$ .

**31.** Kodėl teisingi sąryšiai (2.13) grandinėje?

Pirmas sąryšis: jei  $x = (x_1, \dots, x_k)$ ,  $y = (y_1, \dots, y_l)$  ir  $a = (a_1, \dots, a_l)$ , tai

$$\begin{aligned} & \| (x, y) - (x, a) \| \\ &= \sqrt{(x_1 - x_1)^2 + \dots + (x_k - x_k)^2 + (y_1 - a_1)^2 + \dots + (y_l - a_l)^2} \\ &= \sqrt{(y_1 - a_1)^2 + \dots + (y_l - a_l)^2} \\ &= \|y - a\|. \end{aligned}$$

Antras sąryšis išplaukia iš teoremos sąlygos  $Y_n \rightarrow a$ .

**32.** Kodėl pakanka įrodyti, kad  $(X_n, a) \rightarrow (X, a)$ ?

Tą įrodžius, bus galima pasiremti 1 teoremos teiginiu su  $(X_n, a)$  vietoje  $X_n$ ,  $(X, a)$  vietoje  $X$  ir  $(X_n, Y_n)$  vietoje  $Y_n$ .

### 2.3.3 Komentariai

**33.** Jei  $X$  neišsigimęs, tai sąryšis  $X_n \rightarrow X$  apskritai nėra ekvivalentus sąryšiui

$$\forall \varepsilon \ P\{\|X_n - X\| \geq \varepsilon\} \rightarrow 0, \quad (2.14)$$

jau vien dėl to, kad pirmojo sąryšio apibrėžime figūruoja tik atskirų dydžių skirstiniai, o antrasis išreiškiamas per  $(X_n, X)$  vektoriaus bendrą skirstinį.

Pavyzdžiui, jei visi  $X_n$  yra nepriklausomi ir vienodai pasiskirstę, tai  $X_n \rightarrow X_1$ , nes  $E f(X_n) = E f(X_1)$  su visais  $n$ . Kita vertus,

$$P\{\|X_n - X_1\| \geq \varepsilon\} = P\{\|X_2 - X_1\| \geq \varepsilon\}$$

su visais  $n \geq 2$  ir jei ta tikimybė lygi 0 su visais  $\varepsilon$ , tai  $X_2 = X_1$ , o tai neįmanoma, jei  $X_1$  ir  $X_2$  nepriklausomi ir neišsigimę.

**34.** Jei teisinga (2.14) formulė, sakoma, kad  $X_n$  konverguoja prie  $X$  pagal tikimybę, ir rašoma  $X_n \xrightarrow{P} X$ . Taigi  $X_n \rightarrow a \iff X_n \xrightarrow{P} a$ , bet apskritai  $X_n \rightarrow X$  ir  $X_n \xrightarrow{P} X$  sąryšiai nėra ekvivalentūs. Aš ruošiuosi išsiversti be konvergavimo pagal tikimybę sąvokos.

## 2.4 Tolydaus atvaizdžio principas

### 2.4.1 Teorema

**2.4 teorema.** Tegu  $X_n \rightarrow X$ , o  $\varphi_n$  ir  $\varphi$  yra funkcijos iš  $\mathbb{R}^k$  į  $\mathbb{R}^l$ . Jei egzistuoja tokia Borelio aibė  $A \subset \mathbb{R}^k$ , kad

$$P\{X \in A\} = 1,$$

$$x_n \rightarrow x \in A \Rightarrow \varphi_n(x_n) \rightarrow \varphi(x),$$

tai  $\varphi_n(X_n) \rightarrow \varphi(X)$ .

*Irodymas.* Iš pradžių pastebiu, kad jei  $x \in A$ , tai

$$\forall \varepsilon \exists \delta \exists k \forall n \geq k \forall y \in U(x, \delta) \|\varphi_n(y) - \varphi(x)\| < \varepsilon. \quad (2.15)$$

Tikrai, priešingu atveju atsirastų toks  $\varepsilon$ , kad

$$\forall \delta \forall k \exists n \geq k \exists y \in U(x, \delta) \|\varphi_n(y) - \varphi(x)\| \geq \varepsilon.$$

Imdamas  $\delta = 1/k$ , rasčiau tokius  $n_k \geq k$  ir  $y_k \in U(x, 1/k)$ , kad

$$\|\varphi_{n_k}(y_k) - \varphi(x)\| \geq \varepsilon$$

su visais  $k$ . Tegu  $x_n = y_k$ , kai  $n = n_k$ , ir  $x_n = x$  su likusiais  $n$ . Tada  $x_n \rightarrow x$ , bet  $\varphi_{n_k}(x_{n_k}) \not\rightarrow \varphi(x)$ , o tai prieštarauja  $A$  aibės apibrėžimui.

Tegu dabar  $O$  yra bet koks atviras  $\mathbb{R}^l$  poaibis. Jei  $x \in A$  ir  $\varphi(x) \in O$ , tai iš (2.15) išplaukia, jog egzistuoja toks  $\delta$  ir toks  $k$ , kad su visais  $y \in U(x, \delta)$

$$\begin{aligned} \forall n \geq k \varphi_n(y) &\in O; \\ \forall n \geq k y &\in \varphi_n^{-1}(O); \\ y &\in \bigcap_{n \geq k} \varphi_n^{-1}(O). \end{aligned}$$

Reiškia, egzistuoja toks  $k$ , kad  $x$  yra vidinis aibės  $\bigcap_{n \geq k} \varphi_n^{-1}(O)$  taškas, t.y

$$x \in \bigcup_{k \geq 1} \text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O). \quad (2.16)$$

Iš įrodyto teiginio išplaukia, kad

$$P\{\varphi(X) \in O\} \leq P\left\{X \in \bigcup_{k \geq 1} \text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)\right\}. \quad (2.17)$$

Kai  $k$  didėja, aibės  $\text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)$  didėja; todėl fiksavęs  $\varepsilon$  galiu rasti tokį  $k$ , kad

$$P\{\varphi(X) \in O\} \leq P\left\{X \in \text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)\right\} + \varepsilon. \quad (2.18)$$

Iš  $X_n \rightarrow X$  dabar išplaukia

$$\begin{aligned} P\{\varphi(X) \in O\} &\leq \varliminf_{n \rightarrow \infty} P\left\{X_n \in \text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)\right\} + \varepsilon \\ &\leq \varliminf_{n \rightarrow \infty} P\left\{X_n \in \bigcap_{n \geq k} \varphi_n^{-1}(O)\right\} + \varepsilon \\ &\leq \varliminf_{n \rightarrow \infty} P\{X_n \in \varphi_n^{-1}(O)\} + \varepsilon \\ &= \varliminf_{n \rightarrow \infty} P\{\varphi_n(X_n) \in O\} + \varepsilon \end{aligned} \quad (2.19)$$

Kadangi  $\varepsilon$  pasirinkau laisvai, iš čia gaunu

$$\varliminf_{n \rightarrow \infty} P\{\varphi_n(X_n) \in O\} \geq P\{\varphi(X) \in O\}.$$

Nelygybė teisinga su bet kokia atvira  $O$ ; todėl  $\varphi_n(X_n) \rightarrow \varphi(X)$ .  $\square$

### 2.4.2 Įrodymo paaiškinimai

**35.** Kodėl  $x_n \rightarrow x$  ir  $\varphi_{n_k}(x_{n_k}) \not\rightarrow \varphi(x)$  ir kur čia prieštara?

$x_n \rightarrow x$ , nes  $x_n \in U(x, 1/n)$ , t.y.  $\|x_n - x\| < 1/n$  su visais  $n$ .

$\varphi_{n_k}(x_{n_k}) \not\rightarrow \varphi(x)$ , nes  $|\varphi_{n_k}(x_{n_k}) - \varphi(x)| \geq \varepsilon$  su visais  $k$ .

Iš pastarojo sąryšio išplaukia  $\varphi_n(x_n) \not\rightarrow \varphi(x)$ . Reiškia,  $x$  negali priklausyti  $A$  aibei, nes jei priklausytų, iš  $x_n \rightarrow x$  išplauktų  $\varphi_n(x_n) \rightarrow \varphi(x)$ . Gavau prieštarą, nes  $x$  paėmiau iš  $A$ .

**36.** Kaip iš (2.15) išplaukia, jog egzistuoja tokie  $\delta$  ir  $k$ , kad  $\forall n \geq k \varphi_n(y) \in O$  su visais  $y \in U(x, \delta)$ ?

Kadangi  $O$  atvira, o  $\varphi(x) \in O$ , egzistuoja toks  $\varepsilon$ , kad  $U(\varphi(x), \varepsilon) \subset O$ . Pasirėmęs (2.15), randu tokius  $\delta$  ir  $k$ , kad  $\varphi_n(y) \in U(\varphi(x), \varepsilon)$  su visais  $n \geq k$  ir  $y \in U(x, \delta)$ . Tada su visais  $y \in U(x, \delta)$

$$\forall n \geq k \varphi_n(y) \in U(\varphi(x), \varepsilon) \subset O.$$

**37.** Kodėl teisingas (2.16) sąryšis?

Jei  $y \in \bigcap_{n \geq k} \varphi_n^{-1}(O)$  su visais  $y \in U(x, \delta)$ , tai

$$U(x, \delta) \subset \bigcap_{n \geq k} \varphi_n^{-1}(O).$$

Reiškia,  $x$  yra vidinis  $\bigcap_{n \geq k} \varphi_n^{-1}(O)$  taškas, t.y. priklauso tos aibės vidui. Reiškia, egzistuoja toks  $k$ , kad

$$x \in \text{Int}\left(\bigcap_{n \geq k} \varphi_n^{-1}(O)\right).$$

Reiškia,  $x$  priklauso visų tokių aibių junginiui.

**38.** Kodėl teisingas (2.17) sąryšis?

Įrodžiau, kad iš  $x \in A$  ir  $\varphi(x) \in O$  išplaukia (2.16). Reiškia, iš  $\varphi(x) \in O$  išplaukia (2.16) arba  $x \notin A$ . Taigi

$$P\{\varphi(X) \in O\} \leq P\left\{X \in \bigcup_{k \geq 1} \text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)\right\} + P\{X \notin A\}.$$

Tačiau pagal vieną iš teoremos sąlygų  $P\{X \notin A\} = 0$ .

**39.** Kodėl aibės  $\text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)$  didėja?

Kuo daugiau aibių sukertu, tuo mažesnę aibę gaunu. Reiškia,

$$\text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O) \subset \text{Int} \bigcap_{n \geq k+1} \varphi_n^{-1}(O).$$

Kita vertus, kuo didesnė aibė, tuo didesnis jos vidus.

**40.** Kodėl su tam tikru  $k$  teisinga (2.18) formulė? Lebego teorema apie monotonišką konvergavimą sako, kad jei  $A_k \uparrow A$  (t.y. jei  $A_k$  aibės didėja ir  $A = \bigcup_k A_k$ ), tai  $P(A_k) \uparrow P(A)$ . Reiškia, su tam tikru  $k$

$$P(A_k) \geq P\left(\bigcup_k A_k\right) - \varepsilon.$$

Aš panaudoju šį faktą su  $\{X \in \text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)\}$  vietoje  $A_k$ .

**41.** Kodėl teisingi sąryšiai (2.19) grandinėje?

Pirma nelygybė: suskaičiavau apatines ribas (2.17) nelygybėje ir pasirėmiau Portmanto lemos  $1 \Rightarrow 3$  implikacija su  $\text{Int} \bigcap_{n \geq k} \varphi_n^{-1}(O)$  vietoje  $O$  (taip daryti turiu teisę, nes bet kokios aibės vidus yra atvira aibė).

Antra nelygybė: pasirėmiau tuo, kad  $\text{Int} A \subset A$  su bet kokia  $A$ .

Trečia nelygybė: pasirėmiau tuo, kad  $\bigcap_{n \geq k} A_n \subset A_n$ , kai  $n \geq k$  (o nuo pirmų sekos narių apatinė riba nepriklauso).

Paskutinis sąryšis: pagal pirmavaizdžio apibrėžimą

$$x \in \varphi_n^{-1}(O) \iff \varphi_n(x) \in O.$$

**42.** Kodėl įrodymo gale daroma išvada  $\varphi_n(X_n) \rightarrow \varphi(X)$ ?

Pasirėmiau Portmanto lema.

### 2.4.3 Komentariai

**43.** Kai  $\varphi_n = \varphi$  su visais  $n$ , sąlyga  $x_n \rightarrow x \in A \Rightarrow \varphi_n(x_n) \rightarrow \varphi(x)$  reiškia, kad kiekviename taške  $x \in A$  funkcija  $\varphi$  tolydi. Todėl iš įrodytos teoremos išplaukia tokia išvada: jei  $X_n \rightarrow X$ ,  $P\{X \in A\} = 1$  ir  $\varphi$  tolydi  $A$  aibėje, tai  $\varphi(X_n) \rightarrow \varphi(X)$ .

Jei  $T_n \rightarrow T$ ,  $U_n^{(1)} \rightarrow u_1, \dots, U_n^{(k)} \rightarrow u_k$ , tai iš praeito skyrelio rezultatų išplaukia, kad

$$(T_n, U_n^{(1)}, \dots, U_n^{(k)}) \rightarrow (T, u_1, \dots, u_k).$$

Todėl

$$\varphi(T_n, U_n^{(1)}, \dots, U_n^{(k)}) \rightarrow \varphi(T, u_1, \dots, u_k),$$

jei  $\varphi$  tolydi kiekviename taške  $(t, u_1, \dots, u_k)$  su  $t \in A$ ; čia  $A$  — tokia aibė, kad  $P\{T \in A\} = 1$ . Tai ir yra tolydaus atvaizdžio principas, kurį naudojome pirmame skyriuje.

**44.** Iš įrodytos teoremos galima gauti ir delta metodo pagrindimą. Tegu  $b_n \rightarrow \infty$ ,  $b_n(T_n - a) \rightarrow T$ , o  $g$  — diferencijuojama  $a$  taške funkcija. Įrodysiu, kad tada  $b_n(g(T_n) - g(a)) \rightarrow g'(a)T$ .

Kairioji šio sąryšio pusė lygi  $\varphi_n(U_n)$  su  $U_n = b_n(T_n - a)$  ir tam tikra funkcija  $\varphi_n$ . Kad rasčiau  $\varphi_n$ , išsireiškiu

$$T_n = a + b_n^{-1}U_n;$$

tada

$$b_n(g(T_n) - g(a)) = b_n(g(a + b_n^{-1}U_n) - g(a)).$$

Taigi

$$\varphi_n(u) = b_n(g(a + b_n^{-1}u) - g(a)).$$

Jei  $u_n \rightarrow u$ , tai

$$\varphi_n(u_n) = \frac{g(a + u_n/b_n) - g(a)}{u_n/b_n} u_n \rightarrow g'(a)u.$$

Iš tolydaus atvaizdžio principo tada išplaukia  $\varphi_n(U_n) \rightarrow g'(a)T$ .

## 2.5 *O*-simbolika

Matematinėje analizėje plačiai naudojami *o* ir *O* simboliai. Primenu, kad *o*(1) simboliu žymimos artėjančios į 0 sekos, o *O*(1) simboliu — aprėžtos sekos. Toje pat formulėje gali būti keli *o* ir *O* ženklai ir tada jie žymi nebūtinai tą pačią seką. Jei rašome lygybę, kurios abiejose pusėse yra *o* ir *O* simboliai, suprantame, kad bet kokia seką, kurią galima užrašyti kairėje pusėje parašytu pavidalu, galima užrašyti ir dešinės pusės pavidalu. Pavyzdžiui,

$$O(1)o(1) = o(1)$$

lygybė reiškia, kad aprėžtos ir artėjančios į 0 sekos sandauga artėja į 0.

Stochastinėje analizėje naudojami panašūs  $o_P$  ir  $O_P$  simboliai. Simboliu  $o_P(1)$  žymima bet kokia atsitiktinių dydžių (arba vektorių) seka, artėjanti pagal tikimybę (= pagal pasiskirstymą) į 0. Simboliu  $O_P(1)$  žymima bet kokia *aprėžta pagal tikimybę* atsitiktinių dydžių (vektorių) seka, t.y. bet kokia seka  $(X_n)$ , kuriai

$$\sup_n P\{\|X_n\| \geq k\} \xrightarrow{k \rightarrow \infty} 0.$$

Įrodysiu keletą teiginių su naujais simboliais.

1.  $o_P(1) + o_P(1) = o_P(1)$ . Kitaip tariant, jei  $X_n \rightarrow 0$ ,  $Y_n \rightarrow 0$ , tai  $X_n + Y_n \rightarrow 0$ . Tai išplaukia iš tolydaus atvaizdžio principo.

2. Jei  $X_n \rightarrow X$ , tai  $X_n = O_P(1)$ . Fiksuoju  $\varepsilon$  ir randu tokį  $c$ , kad

$$P\{\|X\| \geq c\} < \varepsilon \quad \text{ir} \quad P\{\|X\| = c\} = 0.$$

Tada  $P\{\|X_n\| \geq c\} \rightarrow P\{\|X\| \geq c\}$ ; todėl atsiras toks  $n_1$ , kad su visais  $n \geq n_1$

$$P\{\|X_n\| \geq c\} < \varepsilon.$$

Dabar su kiekvienu  $i = 1, \dots, n_1 - 1$  randu tokį  $c_i$ , kad

$$P\{\|X_n\| \geq c_i\} < \varepsilon.$$

Tegu  $k$  yra bet koks skaičius didesnis už  $c$  ir visus  $c_i$ . Tada

$$P\{\|X_n\| \geq k\} < \varepsilon$$

su visais  $n$ , t.y.

$$\sup_n P\{\|X_n\| \geq k\} \leq \varepsilon.$$

Šį teiginį naudoju pirmame šio skyriaus skyrelyje, norėdamas įrodyti, kad kokia nors atsitiktinių dydžių seka neturi ribos pagal pasiskirstymą. Iš jo taip pat išplaukia  $o_P(1) = O_P(1)$  lygybė, t.y. kad kiekviena artėjanti į 0 atsitiktinių vektorių seka aprėžta pagal tikimybę.

3.  $O_P(1) + O_P(1) = O_P(1)$ . Kitaip tariant, dviejų aprėžtų pagal tikimybę sekų suma vėl yra aprėžta pagal tikimybę. Tegu  $X_n = O_P(1)$  ir  $Y_n = O_P(1)$ . Fiksuoju  $\varepsilon$  ir randu tokius  $k_1$  ir  $k_2$ , kad

$$\sup_n P\{\|X_n\| \geq k_1\} < \varepsilon \quad \text{ir} \quad \sup_n P\{\|Y_n\| \geq k_2\} < \varepsilon.$$

Tada su visais  $k \geq k_1 + k_2$  ir visais  $n$

$$P\{\|X_n + Y_n\| \geq k\} \leq P\{\|X_n\| \geq k_1\} + P\{\|Y_n\| \geq k_2\} < 2\varepsilon.$$

Jei bent viena iš sekų skaliarinė, analogiškai įrodoma ir  $O_P(1)O_P(1) = O_P(1)$  lygybė.

4. Jei viena iš sekų skaliarinė, tai  $O_P(1)o_P(1) = o_P(1)$ . Tegu, pavyzdžiui,  $X_n = O_P(1)$ ,  $Y_n = o_P(1)$  ir  $X_n$  seka skaliarinė. Fiksuoju  $\varepsilon$  ir randu tokį  $k$ , kad

$$\sup_n P\{|X_n| \geq k\} < \varepsilon.$$

Tada su bet koku  $\delta$

$$P\{\|X_n Y_n\| \geq \delta\} \leq P\{|X_n| \geq k\} + P\{\|Y_n\| \geq \delta/k\} \leq \varepsilon + o(1).$$

Taigi

$$\overline{\lim}_{n \rightarrow \infty} P\{\|X_n Y_n\| \geq \delta\} \leq \varepsilon.$$

Kadangi  $\varepsilon$  pasirinkau laisvai, iš čia išplaukia  $P\{\|X_n Y_n\| \geq \delta\} \rightarrow 0$ .

## 3 skyrius

# Asimptotiniai skirstiniai (tęsinys)

### 3.1 Vektorinis delta metodas

#### 3.1.1 Matricinė notacija

Vektorių  $x = (x_1, \dots, x_k)$  aš mėgstu užrašyti kaip vieno stulpelio  $k \times 1$  matricą:

$$x = (x_1, \dots, x_k) = \begin{pmatrix} x_1 \\ \vdots \\ x_k \end{pmatrix}.$$

Vienos eilutės matrica yra visai kitas objektas:

$$(x_1, \dots, x_k) \neq (x_1 \ \cdots \ x_k).$$

Skirtumas tarp simbolių kairėje ir dešinėje tas, kad vektoriaus komponentes aš vieną nuo kitos atskiriu kableliais, o  $1 \times k$  matricos komponentes — tarpais.

Jei  $g(x_1, \dots, x_k)$  yra  $k$  kintamųjų realioji funkcija, tai jos išvestine vadinama  $1 \times k$  matrica, sudaryta iš tos funkcijos dalinių išvestinių:

$$g'(x) = \left( \frac{\partial g}{\partial x_1}(x) \ \cdots \ \frac{\partial g}{\partial x_k}(x) \right).$$

Analogiška  $k \times 1$  matrica (t.y.  $k$ -matis vektorius) vadinamas funkcijos gradientu ir žymimas  $\nabla g$ :

$$\nabla g(x) = \left( \frac{\partial g}{\partial x_1}(x), \dots, \frac{\partial g}{\partial x_k}(x) \right) = \begin{pmatrix} \frac{\partial g}{\partial x_1}(x) \\ \vdots \\ \frac{\partial g}{\partial x_k}(x) \end{pmatrix}.$$

Pavyzdžiui, jei

$$g(x, y, z) = \frac{x}{y - z^2},$$

tai

$$g' = \left( \frac{1}{y-x^2} \quad -\frac{x}{(y-z^2)^2} \quad \frac{2xz}{(y-z^2)^2} \right), \quad \nabla g = \begin{pmatrix} \frac{1}{y-x^2} \\ -\frac{x}{(y-z^2)^2} \\ \frac{2xz}{(y-z^2)^2} \end{pmatrix}.$$

Jei  $g(x) = g(x_1, \dots, x_k)$  yra  $k$  kintamųjų vektorinė funkcija (su reikšmėmis  $\mathbb{R}^l$  erdvėje), tai ji yra

$$(g_1(x), \dots, g_l(x)) = \begin{pmatrix} g_1(x) \\ \vdots \\ g_l(x) \end{pmatrix}$$

pavidalo; čia  $g_j(x)$  yra skaliarinės funkcijos, vadinamos  $g$  funkcijos komponentėmis. Tokios funkcijos išvestinė yra  $l \times k$  matrica

$$g'(x) = \begin{pmatrix} \frac{\partial g_1}{\partial x_1}(x) & \cdots & \frac{\partial g_1}{\partial x_k}(x) \\ \vdots & \ddots & \vdots \\ \frac{\partial g_l}{\partial x_1}(x) & \cdots & \frac{\partial g_l}{\partial x_k}(x) \end{pmatrix}.$$

### 3.1.2 Atsitiktinių matricių vidurkiai

Jei  $X$  yra atsitiktinė matrica (atskiru atveju —  $k \times 1$  matrica, t.y. vektorius), jos vidurkiu vadinama skaičių matrica, sudaryta iš atitinkamų  $X$  matricos komponentžių vidurkių. Taigi, pavyzdžiui,

$$\mathbb{E} \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} = \begin{pmatrix} \mathbb{E} X_1 \\ \mathbb{E} X_2 \\ \mathbb{E} X_3 \end{pmatrix}, \quad \mathbb{E} \begin{pmatrix} X_{11} & X_{12} \\ X_{21} & X_{22} \end{pmatrix} = \begin{pmatrix} \mathbb{E} X_{11} & \mathbb{E} X_{12} \\ \mathbb{E} X_{21} & \mathbb{E} X_{22} \end{pmatrix}$$

ir pan.

Pagrindinės vektorinių vidurkių savybės tokios pat, kaip skaliarinių vidurkių: konstantos vidurkis lygus jai pačiai, sumos vidurkis lygus vidurkių sumai, pastovų daugiklį galima iškelti už vidurkio ženklą (kadangi matricių daugyba nekomutatyvi, pastaroji savybė užrašoma dviem lygybėmis):

$$\mathbb{E} C = C, \quad \mathbb{E} X + Y = \mathbb{E} X + \mathbb{E} Y, \quad \mathbb{E} AX = A \mathbb{E} X, \quad \mathbb{E} XB = (\mathbb{E} X)B.$$

Transponuotos matricos vidurkis gaunamas transponuojant vidurkių matricą:

$$\mathbb{E} X^\top = (\mathbb{E} X)^\top.$$

Dispersijos vaidmenį daugiamatėje teorijoje atlieka *kovariacijų matrica*, kurią aš žymėsiu  $V$  simboliu: jei  $X = (X_1, \dots, X_k)$  yra atsitiktinis vektorius, tai

$$V(X) = \mathbb{E}(X - \mathbb{E} X)(X - \mathbb{E} X)^\top = \mathbb{E}(XX^\top) - (\mathbb{E} X)(\mathbb{E} X)^\top.$$

Kovariacijų matricos elementai yra kovariacijos tarp  $X$  vektoriaus komponentžių:

$$V(X) = \begin{pmatrix} \text{cov}(X_1, X_1) & \cdots & \text{cov}(X_1, X_k) \\ \vdots & \ddots & \vdots \\ \text{cov}(X_k, X_1) & \cdots & \text{cov}(X_k, X_k) \end{pmatrix};$$

čia

$$\text{cov}(X_i, X_j) = \mathbb{E}(X_i - \mathbb{E} X_i)(X_j - \mathbb{E} X_j) = \mathbb{E} X_i X_j - \mathbb{E} X_i \mathbb{E} X_j.$$

Iš vidurkio savybių nesunkiai gaunamos tokios kovariacijų matricos savybės:

$$V(X + C) = V X, \quad V(AX) = A V(X) A^\top.$$



### 3.1.3 Normalusis skirstinys

Simboliu  $N(\mu, \Sigma)$  aš žymiu atsitiktinį vektorių, pasiskirsčiusį normaliai su vidurkiu  $\mu$  ir kovariacijų matrica  $\Sigma$ . Gerai žinoma, kad jei  $X$  turi tokį skirstinį, tai  $A + BX$  taip pat pasiskirsęs normaliai, tik su kitais parametrais: vidurkiu  $A + B\mu$  ir kovariacijų matrica  $B\Sigma B^\top$ . Todėl aš dažnai rašau

$$A + BN(\mu, \Sigma) = N(A + B\mu, B\Sigma B^\top).$$

Dažniausiai  $\mu = 0$ ,  $A = 0$ , o  $B$  yra vienos eilutės matrica; tada  $B\Sigma B^\top$  yra skaičius: jei  $\Sigma = (\sigma_{ij} \mid 1 \leq i, j \leq k)$ ,  $B = (b_1 \cdots b_k)$ , tai

$$BN(0, \Sigma) = N(0, \sigma^2);$$

čia

$$\sigma^2 = B\Sigma B^\top = \sum_{i,j=1}^k \sigma_{ij} b_i b_j$$

### 3.1.4 Empiriniai vidurkiai

Tegu  $X_1, \dots, X_n$  yra nepriklausomos atsitiktinio  $k$ -mačio vektoriaus  $X$  kopijos,  $f$  — funkcija iš  $\mathbb{R}^k$  į  $\mathbb{R}^l$  ir  $f_j$  — tos funkcijos komponentės. Tada simboliu  $\overline{f(X)}$  žymėsiu empirinį vidurkį:

$$\overline{f(X)} = \frac{1}{n} \sum_{i=1}^n f(X_i).$$

Aišku, kad  $\overline{f(X)}$  yra  $l$ -matis vektorius, kurio komponentės yra empiriniai vidurkiai, atitinkantys  $f$  funkcijos komponentes:

$$\overline{f(X)} = (\overline{f_1(X)}, \dots, \overline{f_l(X)}) = \begin{pmatrix} \overline{f_1(X)} \\ \vdots \\ \overline{f_l(X)} \end{pmatrix}.$$

Dažniausiai susidursime su situacija, kai  $X$  yra atsitiktinis dydis (skaliaras), o  $f$  — vektorinė funkcija iš  $\mathbb{R}$  į  $\mathbb{R}^l$ . Pavyzdžiui, jei  $f(x) = (x, x^2)$ , tai

$$\overline{f(X)} = \overline{(X, X^2)} = (\overline{X}, \overline{X^2}) = \begin{pmatrix} \overline{X} \\ \overline{X^2} \end{pmatrix} = \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n X_i \\ \frac{1}{n} \sum_{i=1}^n X_i^2 \end{pmatrix} = \frac{1}{n} \sum_{i=1}^n \begin{pmatrix} X_i \\ X_i^2 \end{pmatrix}.$$

Pagrindinės empirinio vidurkio savybės panašios į paprasto vidurkio: konstantos vidurkis lygus tai konstantai, sumos vidurkis lygus vidurkių sumai, pastovų daugiklį galima iškelti iš vidurkio. Kitaip tariant,

$$\overline{c} = c, \quad \overline{f(X) + g(X)} = \overline{f(X)} + \overline{g(X)}, \quad \overline{Af(X)} = A\overline{f(X)}, \quad \overline{f(X)B} = \overline{f(X)}B.$$

### 3.1.5 Asimptotikų ieškojimo metodai

Pagrindinių teiginių, kuriais remiamės ieškome asimptotinių skirstinių, analogai vektoriniu atveju skamba taip:

- (didžiųjų skaičių dėsnis) jei  $EX = a$ , tai

$$\overline{X} \rightarrow a;$$

- (centrinė ribinė teorema) jei  $EX = a$ ,  $V(X) = \Sigma$ , tai

$$\sqrt{n}(\overline{X} - a) \rightarrow N(0, \Sigma);$$

- (tolydaus atvaizdžio principas) jei  $T_n \rightarrow T$ ,  $U_n^{(1)} \rightarrow u_1, \dots, U_n^{(k)} \rightarrow u_k$ , tai

$$\varphi(T_n, U_n^{(1)}, \dots, U_n^{(k)}) \rightarrow \varphi(T, u_1, \dots, u_k);$$

- (delta metodas) jei  $b_n \rightarrow \infty$  ir  $b_n(T_n - a) \rightarrow T$ , tai

$$b_n(g(T_n) - g(a)) \rightarrow g'(a)T.$$

Pakomentuosiu paskutinį teiginį. Vektorinio delta metodo aprašymas nesiskiria nuo skaliarinio, bet tie patys simboliai dabar žymi nebe skaliarinius, o vektorinius dydžius (arba matricas). Tegu  $g$  yra skaliarinė  $k$  kintamųjų funkcija  $g(t_1, \dots, t_k)$  (šis atvejis bus dažniausiai sutinkamas). Tada  $T_n$  turi būti  $k$ -matis atsitiktinis vektorius:

$$T_n = \begin{pmatrix} T_{n1} \\ \vdots \\ T_{nk} \end{pmatrix}.$$

Sąryšis  $b_n(T_n - a)$  paprastai gaunamas iš vektorinės centrinės ribinės teoremos; tada  $T$  yra normaliai pasiskirstęs atsitiktinis vektorius — koks nors  $N(0, \Sigma)$ . Simbolis  $g'(a)$  žymi  $g$  funkcijos dalinių išvestinių matricą; nagrinėjamu atveju ji sudaryta iš vienos eilutės. Tada

$$g'(a)T = g'(a)N(0, \Sigma) = N(0, \sigma^2)$$

su

$$\sigma^2 = g'(a)\Sigma g'(a)^\top = \sum_{i,j=1}^k \sigma_{ij} \partial_i \partial_j;$$

čia  $\sigma_{ij}$  yra  $\Sigma$  matricos komponentės, o

$$\partial_i = \frac{\partial g}{\partial t_i}(a).$$

### 3.1.6 Pavyzdžiai

3.1 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio

|     |     |     |     |
|-----|-----|-----|-----|
| $X$ | 1   | 2   | 3   |
|     | 0.2 | 0.3 | 0.5 |

Raskite statistikos

$$T_n = \frac{N_3 - N_1}{\sqrt{N_1 N_3}}$$

asimptotinį skirstinį; čia  $N_j$  žymi  $j$  reikšmės pasikartojimų skaičių imtyje.

Sprendimas. Turime:

$$T_n = \frac{N_3/n - N_1/n}{\sqrt{N_3/n \cdot N_1/n}} = g(\overline{1_{\{X=1\}}}, \overline{1_{\{X=3\}}});$$

čia

$$g(u, v) = \frac{v - u}{\sqrt{uv}}.$$

Taigi iš pradžių reikia rasti vektorinės sekos

$$(\overline{1_{\{X=3\}}}, \overline{1_{\{X=1\}}}) = (\overline{1_{\{X=3\}}}, \overline{1_{\{X=1\}}})$$

asimptotiką, o po to pritaikyti vektorinį delta metodą.

Kadangi

$$E 1_{\{X=1\}}^2 = E 1_{\{X=1\}} = 0.2,$$

$$E 1_{\{X=3\}}^2 = E 1_{\{X=3\}} = 0.5,$$

$$E 1_{\{X=1\}} 1_{\{X=3\}} = 0,$$

gaunu

$$\text{cov}(1_{\{X=1\}}, 1_{\{X=1\}}) = 0.2 - 0.04 = 0.16,$$

$$\text{cov}(1_{\{X=3\}}, 1_{\{X=3\}}) = 0.5 - 0.25 = 0.25,$$

$$\text{cov}(1_{\{X=1\}}, 1_{\{X=3\}}) = 0 - 0.1 = -0.1.$$

Reiškia,

$$\sqrt{n} \left[ \begin{pmatrix} \overline{1_{\{X=1\}}} \\ \overline{1_{\{X=3\}}} \end{pmatrix} - \begin{pmatrix} 0.2 \\ 0.5 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 0.16 & -0.1 \\ -0.1 & 0.25 \end{pmatrix}.$$

Dabar taikau vektorinį delta metodą. Iš pradžių randu dalines  $g$  funkcijos išvestines:

$$\frac{\partial g}{\partial u} = \frac{-\sqrt{uv} - (v - u) \frac{v}{2\sqrt{uv}}}{uv} = -\frac{uv + v^2}{2(uv)^{3/2}},$$

$$\frac{\partial g}{\partial v} = \frac{\sqrt{uv} - (v - u) \frac{u}{2\sqrt{uv}}}{uv} = \frac{uv + u^2}{2(uv)^{3/2}}.$$

Taigi

$$g(0.2, 0.5) = \frac{0.3}{\sqrt{0.1}} = 0.3\sqrt{10},$$

$$g'(0.2, 0.5) = \frac{1}{2 \cdot 0.1^{3/2}} (-0.1 - 0.25 \ 0.1 + 0.04) = \frac{1}{2 \cdot 0.1^{3/2}} (-0.35 \ 0.14)$$

ir pagal delta metodą

$$\sqrt{n}(T_n - 0.3\sqrt{10}) \rightarrow N(0, \sigma^2);$$

čia

$$\begin{aligned}\sigma^2 &= \frac{1}{4 \cdot 0.1^3} (-0.35 \ 0.14) \begin{pmatrix} 0.16 & -0.1 \\ -0.1 & 0.25 \end{pmatrix} \begin{pmatrix} -0.35 \\ 0.14 \end{pmatrix} \\ &= 250 (-0.35 \ 0.14) \begin{pmatrix} -0.07 \\ 0.07 \end{pmatrix} \\ &= 250 \cdot 0.0343 \\ &= 8.575.\end{aligned}$$

3.2 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš tolygaus  $(0; 1)$  intervale skirstinio ir

$$T_n = \frac{\bar{X}}{\sqrt{\bar{X}^2 - \overline{X^2}}}.$$

Raskite  $T_n$  statistikos asimptotinį skirstinį.

*Sprendimas.* Aišku, kad  $T_n = g(\bar{X}, \overline{X^2})$ ; čia

$$g(u, v) = \frac{u}{\sqrt{v - u^2}}.$$

Kadangi

$$\begin{aligned}\mathbb{E} X &= \int_0^1 x dx = \frac{x^2}{2} \Big|_0^1 = \frac{1}{2}, \\ \mathbb{E} X^2 &= \int_0^1 x^2 dx = \frac{x^3}{3} \Big|_0^1 = \frac{1}{3}, \\ \mathbb{E} X^3 &= \int_0^1 x^3 dx = \frac{x^4}{4} \Big|_0^1 = \frac{1}{4}, \\ \mathbb{E} X^4 &= \int_0^1 x^4 dx = \frac{x^5}{5} \Big|_0^1 = \frac{1}{5},\end{aligned}$$

gaunu

$$\begin{aligned}\text{cov}(X, X) &= \frac{1}{3} - \frac{1}{4} = \frac{1}{12}, \\ \text{cov}(X, X^2) &= \frac{1}{4} - \frac{1}{6} = \frac{1}{12}, \\ \text{cov}(X^2, X^2) &= \frac{1}{5} - \frac{1}{9} = \frac{4}{45}.\end{aligned}$$

Todėl iš centrinės ribinės teoremos

$$\sqrt{n} \left[ \begin{pmatrix} \bar{X} \\ \overline{X^2} \end{pmatrix} - \begin{pmatrix} 1/2 \\ 1/3 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 1/12 & 1/12 \\ 1/12 & 4/45 \end{pmatrix}.$$

Randu  $g$  funkcijos išvestines:

$$\frac{\partial g}{\partial u} = \frac{\sqrt{v-u^2} - u \frac{-2u}{2\sqrt{v-u^2}}}{v-u^2} = \frac{v}{(v-u^2)^{3/2}},$$

$$\frac{\partial g}{\partial v} = -\frac{u}{2(v-u^2)^{3/2}}.$$

Taigi

$$g(1/2, 1/3) = \frac{1/2}{\sqrt{1/3 - 1/4}} = \sqrt{3},$$

$$g'(1/2, 1/3) = 12^{3/2}(1/3 - 1/4) = 2\sqrt{3}(4 - 3)$$

ir pagal delta metodą

$$\sqrt{n}(T_n - \sqrt{3}) \rightarrow N(0, \sigma^2);$$

čia

$$\begin{aligned} \sigma^2 &= 12(4 - 3) \begin{pmatrix} 1/12 & 1/12 \\ 1/12 & 4/45 \end{pmatrix} \begin{pmatrix} 4 \\ -3 \end{pmatrix} \\ &= 12(4 - 3) \begin{pmatrix} 1/12 \\ 1/15 \end{pmatrix} \\ &= 12 \cdot \frac{2}{15} \\ &= \frac{8}{5}. \end{aligned}$$

## 3.2 Ypatingi atvejai

### 3.2.1 Atvejis, kai $g'(a) = 0$

Primenu, kad užduotis rasti asimptotinę  $T_n$  sekos skirstinį reiškia, jog reikia rasti tokias skaičių sekas  $a_n$  ir  $b_n$ , kad  $b_n(T_n - a_n)$  konverguotų į neišsigimusį atsitiktinį dydį  $T$ . Jei  $T_n = g(U_n)$  ir  $b_n(U_n - a) \rightarrow U$ , tai taikydamas delta metodą gaunu

$$b_n(T_n - g(a)) \rightarrow g'(a)U.$$

Deja, dydis  $g'(a)U$  išsigimęs, jei  $g'(a) = 0$ . Ką daryti tokiu atveju?

Tarkime,  $g''(a) \neq 0$ . Pažymėjęs

$$V_n = b_n(U_n - a),$$

gaunu

$$T_n = g(a + V_n/b_n) = g(a) + \frac{\varphi_n(V_n)}{b_n^2};$$

čia

$$\varphi_n(x) = b_n^2 [g(a + x/b_n) - g(a)].$$

Iš Teiloro formulės

$$g(a + h) = g(a) + g'(a)h + \frac{1}{2}g''(a)h^2 + h^2r(h) = g(a) + \frac{1}{2}g''(a)h^2 + h^2r(h)$$

su tam tikra funkcija  $r(h)$ , artėjančia į 0, kai  $h \rightarrow 0$ . Taigi jei  $x_n \rightarrow x$ , tai

$$\varphi_n(x_n) = b_n^2 \left[ \frac{1}{2} (g''(a) + r(x_n/b_n)) \frac{x_n^2}{b_n^2} \right] = \frac{x_n^2}{2} (g''(a) + r(x_n/b_n)) \rightarrow \frac{g''(a)x^2}{2}.$$

Taigi iš tolydaus atvaizdžio principo

$$b_n^2 (T_n - g(a)) = \varphi_n(V_n) \rightarrow \frac{g''(a)U^2}{2}.$$

Tai ir yra ieškomoji  $T_n$  asimptotika, jei  $g''(a) \neq 0$ .

Jei ir  $g''(a) = 0$  tektų taikyti Teiloro formulę su didesniu skaičiumi narių. Bet praktikoje tokie uždaviniai pasitaiko retai.

Jei ne tik  $g'(a) = 0$ , bet ir  $g(a) = 0$ , tai asimptotinį skirstinį galima rasti žymiai greičiau, nenaudojant Teiloro formulės. Štai pavyzdys. Tegu  $X_1, \dots, X_n$  yra imtis iš tolygaus  $(-1; 1)$  intervale skirstinio ir  $T_n = \overline{X}^2$ . Reikia rasti  $(T_n)$  sekos asimptotiką.

Kadangi

$$E X = \int_{-1}^1 \frac{x}{2} dx = 0, \quad E X^2 = \int_{-1}^1 \frac{x^2}{2} dx = \frac{1}{3},$$

dispersija  $D X = 1/3$  ir iš centrinės ribinės teoremos gaunu

$$\sqrt{n}\overline{X} \rightarrow N(0, 1/3).$$

Tada iš tolydaus atvaizdžio principo iškart

$$n\overline{X}^2 \rightarrow N^2(0, 1/3) = \left[ \frac{1}{\sqrt{3}} N(0, 1) \right]^2 = \frac{1}{3} \chi^2(1).$$

Kitaip tariant,

$$3nT_n \rightarrow \chi^2(1).$$

Jei būčiau taikęs delta metodą su funkcija  $g(x) = x^2$ , būčiau gavęs

$$\sqrt{n}(T_n - 0) \rightarrow 0 \cdot N(0, 1),$$

t.y.  $\sqrt{n}T_n \rightarrow 0$  (nes šiuo atveju  $a = 0$ ,  $g(0) = 0$  ir  $g'(0) = 2 \cdot 0 = 0$ ). Tada „antros eilės delta metodas“ duotų tą patį atsakymą, kurį gavau iškart:  $nT_n \rightarrow N^2(0, 1/3)$  (nes  $g''(0)/2 = 1$ ).

### 3.2.2 Atvejis, kai $g$ priklauso nuo $n$

Jei  $T_n = g_n(U_n)$  ir  $b_n(U_n - a) \rightarrow U$ , kažkokios bendros teorijos nėra. Tenka tiesiog kartoti delta metodo pagrindimą ir uždavinį suvesti į tokį pavidalą, kad būtų galima taikyti tolydaus atvaizdžio principą. Todėl iškart panagrinėsiu pavyzdį.

Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio

|     |     |     |     |     |
|-----|-----|-----|-----|-----|
| $X$ | -1  | 0   | 1   | 2   |
|     | 0.2 | 0.2 | 0.2 | 0.4 |

Reikia rasti statistikos

$$T_n = \frac{\sqrt{N^2 + 1}}{N + 1}$$

asimptotinį skirstinį; čia  $N$  yra teigiamų narių skaičius imtyje.

Aišku, kad

$$T_n = \frac{\sqrt{(N/n)^2 + 1/n^2}}{N/n + 1/n} = g_n(N/n);$$

čia

$$g_n(t) = \frac{\sqrt{t^2 + 1/n^2}}{t + 1/n}.$$

Kadangi  $N/n = \overline{1_{\{X>0\}}}$  ir

$$E 1_{\{X>0\}} = E 1_{\{X>0\}}^2 = 0.6,$$

iš centrinės ribinės teoremos gaunu

$$U_n = \sqrt{n}(\overline{1_{\{X>0\}}} - 0.6) \rightarrow N(0, 0.24).$$

Be to,  $\overline{1_{\{X>0\}}} = 0.6 + U_n/\sqrt{n}$  ir

$$T_n = g_n(0.6 + U_n/\sqrt{n}).$$

Randu reiškinio  $g_n(0.6 + u_n/\sqrt{n})$  asimptotiką, kai  $u_n \rightarrow u$ :

$$\begin{aligned} & g_n(0.6 + u_n/\sqrt{n}) \\ &= \frac{\sqrt{0.36 + 1.2u_n/\sqrt{n} + u_n^2/n + 1/n^2}}{0.6 + u_n/\sqrt{n} + 1/n} \\ &= \left(1 + \frac{10u_n}{3\sqrt{n}} + \frac{25u_n^2}{9n} + \frac{25}{9n^2}\right)^{1/2} \left(1 + \frac{5u_n}{3\sqrt{n}} + \frac{5}{3n}\right)^{-1} \\ &= \left[1 + \frac{1}{2}\left(\frac{10u_n}{3\sqrt{n}} + \frac{25u_n^2}{9n} + \frac{25}{9n^2}\right) - \frac{1}{8}\left(\frac{10u_n}{3\sqrt{n}} + \frac{25u_n^2}{9n} + \frac{25}{9n^2}\right)^2 \right. \\ &\quad \left. + \frac{1}{16}\left(\frac{10u_n}{3\sqrt{n}} + \frac{25u_n^2}{9n} + \frac{25}{9n^2}\right)^3 + o(n^{-3/2})\right] \\ &\quad \times \left[1 - \left(\frac{5u_n}{3\sqrt{n}} + \frac{5}{3n}\right) + \left(\frac{5u_n}{3\sqrt{n}} + \frac{5}{3n}\right)^2 - \left(\frac{5u_n}{3\sqrt{n}} + \frac{5}{3n}\right)^3 + o(n^{-3/2})\right] \\ &= \left[1 + \frac{5u_n}{3\sqrt{n}} + o(n^{-3/2})\right] \\ &\quad \times \left[1 - \frac{5u_n}{3\sqrt{n}} - \frac{5}{3n} + \frac{25u_n^2}{9n} + \frac{50u_n}{9n^{3/2}} - \frac{125u_n^3}{27n^{3/2}} + o(n^{-3/2})\right] \\ &= 1 - \frac{5}{3n} + \frac{25u_n}{9n^{3/2}} + o(n^{-3/2}). \end{aligned}$$

Kitaip tariant, jei  $u_n \rightarrow u$ , tai

$$n^{3/2}\left(g_n(0.6 + u_n/\sqrt{n}) - 1 + \frac{5}{3n}\right) \rightarrow \frac{25u}{9}.$$

Tada iš tolydaus atvaizdžio principo:

$$n^{3/2}\left(T_n - 1 + \frac{5}{3n}\right) \rightarrow \frac{25}{9}N(0, 0.24) = N(0, 50/27).$$

### 3.3 Pavyzdžiai

3.3 PAVYZDYS.  $X$  ir  $Y$  yra nepriklausomi vienodai pasiskirstę atsitiktiniai dydžiai, kurių skirstinys aprašomas lentele

|        |     |     |
|--------|-----|-----|
| $X, Y$ | 1   | 2   |
|        | 0.4 | 0.6 |

Tegu  $(X_1, Y_1), \dots, (X_n, Y_n)$  yra nepriklausomos  $(X, Y)$  kopijos, o  $N_{jk}$  žymi poros  $(j, k)$  pasikartojimų skaičių imtyje. Raskite nurodytų statistikų asimptotinius skirstinius:

a)  $T_n = \frac{N_{12} - N_{21}}{N_{11} + N_{22}};$

b)  $T_n = \frac{N_{11}}{N_{11}^2 + N_{22}^2}.$

*Sprendimas.* a. Kadangi  $N_{11} + N_{22} = n - N_{11} - N_{21}$ ,  $T_n$  statistiką galime užrašyti taip:

$$T_n = \frac{N_{12} - N_{21}}{n - N_{12} - N_{21}} = \frac{N_{12}/n - N_{21}/n}{1 - N_{12}/n - N_{21}/n} = g(\overline{1_{\{X=1, Y=2\}}}, \overline{1_{\{X=2, Y=1\}}});$$

čia

$$g(u, v) = \frac{u - v}{1 - u - v}.$$

Bendras  $(X, Y)$  skirstinys aprašomas lentele

|     |     |      |      |     |
|-----|-----|------|------|-----|
| $X$ | $Y$ | 1    | 2    |     |
| 1   |     | 0.16 | 0.24 | 0.4 |
| 2   |     | 0.24 | 0.36 | 0.6 |
|     |     | 0.4  | 0.6  |     |

Iš jos matyti, kad

$$\begin{aligned} E 1_{\{X=1, Y=2\}} &= E 1_{\{X=1, Y=2\}}^2 = E 1_{\{X=2, Y=1\}} = E 1_{\{X=2, Y=1\}}^2 = 0.24, \\ E 1_{X=1, Y=2} 1_{X=2, Y=1} &= E 0 = 0. \end{aligned}$$

Reiškia,

$$D 1_{\{X=1, Y=2\}} = D 1_{\{X=2, Y=1\}} = \frac{114}{625}, \quad \text{cov}(1_{\{X=1, Y=2\}}, 1_{\{X=2, Y=1\}}) = -\frac{36}{625}.$$

Tada iš centrinės ribinės teoremos

$$\sqrt{n} \left[ \begin{pmatrix} \overline{1_{\{X=1, Y=2\}}} \\ \overline{1_{\{X=2, Y=1\}}} \end{pmatrix} - \begin{pmatrix} 6/25 \\ 6/25 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 114/625 & -36/625 \\ -36/625 & 114/625 \end{pmatrix}.$$

Taikau vektorinį delta metodą. Iš pradžių randu  $g$  funkcijos išvestines:

$$\frac{\partial g}{\partial u} = \frac{1 - u - v + (u - v)}{(1 - u - v)^2} = \frac{1 - 2v}{(1 - u - v)^2},$$



$$\frac{\partial g}{\partial v} = \frac{-(1-u-v) + (u-v)}{(1-u-v)^2} = \frac{-1+2u}{(1-u-v)^2}.$$

Istatęs  $u = v = 0.24$ , gaunu  $g(0.24, 0.24) = 0$  ir

$$g'(0.24, 0.24) = \left(\frac{25}{13} \quad -\frac{25}{13}\right).$$

Taigi

$$\sqrt{n}T_n \rightarrow N(0, \sigma^2);$$

čia

$$\begin{aligned} \sigma^2 &= \begin{pmatrix} \frac{25}{13} & -\frac{25}{13} \\ -\frac{25}{13} & \frac{25}{13} \end{pmatrix} \begin{pmatrix} 114/625 & -36/625 \\ -36/625 & 114/625 \end{pmatrix} \begin{pmatrix} \frac{25}{13} \\ -\frac{25}{13} \end{pmatrix} \\ &= \frac{1}{169} \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} 150 \\ -150 \end{pmatrix} = \frac{300}{169}. \end{aligned}$$

b. Turiu

$$nT_n = \frac{nN_{11}}{N_{11}^2 + N_{22}^2} = \frac{N_{11}/n}{(N_{11}/n)^2 + (N_{22}/n)^2} = g(\overline{1_{\{X=Y=1\}}}, \overline{1_{\{X=Y=2\}}});$$

čia

$$g(u, v) = \frac{u}{u^2 + v^2}.$$

Iš  $(X, Y)$  skirstinio lentelės matyti, kad

$$\begin{aligned} E 1_{\{X=Y=1\}} &= \frac{4}{25}, & D 1_{\{X=Y=1\}} &= \frac{84}{625}, \\ E 1_{\{X=Y=2\}} &= \frac{9}{25}, & D 1_{\{X=Y=2\}} &= \frac{144}{625}, \\ \text{cov}(1_{\{X=Y=1\}}, 1_{\{X=Y=2\}}) &= -\frac{36}{625}. \end{aligned}$$

Tada iš centrinės ribinės teoremos

$$\sqrt{n} \left[ \begin{pmatrix} \overline{1_{\{X=Y=1\}}} \\ \overline{1_{\{X=Y=2\}}} \end{pmatrix} - \begin{pmatrix} 4/25 \\ 9/25 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 84/625 & -36/625 \\ -36/625 & 144/625 \end{pmatrix}.$$

Taikau vektorinį delta metodą. Iš pradžių randu  $g$  funkcijos išvestines:

$$\begin{aligned} \frac{\partial g}{\partial u} &= \frac{u^2 + v^2 - 2u^2}{(u^2 + v^2)^2} = \frac{v^2 - u^2}{(u^2 + v^2)^2}, \\ \frac{\partial g}{\partial v} &= -\frac{2v}{(u^2 + v^2)^2}. \end{aligned}$$

Istatęs  $u = 0.16$  ir  $v = 0.36$ , gaunu  $g(0.16, 0.36) = \frac{100}{97}$  ir

$$g'(0.16, 0.36) = \frac{625}{97^2} \begin{pmatrix} 65 & -450 \end{pmatrix}.$$

Taigi

$$\sqrt{n}\left(nT_n - \frac{100}{97}\right) \rightarrow N(0, \sigma^2);$$

čia

$$\begin{aligned} \sigma^2 &= \frac{625}{97^4} (65 \quad -450) \begin{pmatrix} 84 & -36 \\ -36 & 144 \end{pmatrix} \begin{pmatrix} 65 \\ -450 \end{pmatrix} \\ &= \frac{625}{97^4} (65 \quad -450) \begin{pmatrix} 21660 \\ -67140 \end{pmatrix} = \frac{625}{97^4} 31620900 \approx 223. \end{aligned}$$

3.4 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio, aprašomo tankio funkcija

$$p(x) = \begin{cases} 2/3, & \text{kai } 0 < x < 1; \\ 1/x^4, & \text{kai } x > 1. \end{cases}$$

Raskite nurodytų statistikų asimptotinius skirstinius:

a)  $T_n = \frac{N_{>1}}{N_{<2}};$

b)  $T_n = \frac{N_{>1}}{N_{>1} + \bar{X}};$

čia  $N_{>1}$  (atitinkamai,  $N_{<2}$ ) yra skaičius imties narių, didesnių už 1 (atitinkamai, mažesnių už 2).

*Sprendimas.* a. Aišku, kad

$$T_n = g(\overline{1_{\{X>1\}}}, \overline{1_{\{X<2\}}});$$

čia  $g(u, v) = u/v$ .

Kadangi

$$\begin{aligned} E 1_{\{X>1\}}^2 &= E 1_{\{X>1\}} = \int_1^\infty \frac{dx}{x^4} = -\frac{x^{-3}}{3} \Big|_1^\infty = \frac{1}{3}, \\ E 1_{\{X<2\}}^2 &= E 1_{\{X<2\}} = \int_0^1 \frac{2}{3} dx + \int_1^2 \frac{dx}{x^4} = \frac{2}{3} - \frac{x^{-3}}{3} \Big|_1^2 = \frac{2}{3} - \frac{1}{24} + \frac{1}{3} = \frac{23}{24}, \\ E 1_{\{X>1\}} 1_{\{X<2\}} &= \int_1^2 \frac{dx}{x^4} = -\frac{x^{-3}}{3} \Big|_1^2 = -\frac{1}{24} + \frac{1}{3} = \frac{7}{24}, \end{aligned}$$

gaunu

$$D 1_{\{X>1\}} = \frac{2}{9}, \quad D 1_{\{X<2\}} = \frac{23}{24^2}, \quad \text{cov}(1_{\{X>1\}}, 1_{\{X<2\}}) = -\frac{1}{36}.$$

Todėl iš centrinės ribinės teoremos

$$\sqrt{n} \left[ \begin{pmatrix} \overline{1_{\{X>1\}}} \\ \overline{1_{\{X<2\}}} \end{pmatrix} - \begin{pmatrix} 1/3 \\ 23/24 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 2/9 & -1/36 \\ -1/36 & 23/24^2 \end{pmatrix}.$$

Taikau vektorinį delta metodą. Iš pradžių randu  $g$  funkcijos išvestines:

$$\frac{\partial g}{\partial u} = \frac{1}{v}, \quad \frac{\partial g}{\partial v} = -\frac{u}{v^2}.$$

Istatęs  $u = 1/3$  ir  $v = 23/24$ , gaunu  $g(1/3, 23/24) = 8/23$  ir

$$g'(1/3, 23/24) = \begin{pmatrix} 24/23 & -8 \cdot 24/23^2 \end{pmatrix} = \frac{24}{23^2} \begin{pmatrix} 23 & -8 \end{pmatrix}.$$

Taigi

$$\sqrt{n} \left( T_n - \frac{8}{23} \right) \rightarrow N(0, \sigma^2);$$

čia

$$\begin{aligned} \sigma^2 &= \frac{1}{23^4} \begin{pmatrix} 23 & -8 \end{pmatrix} \begin{pmatrix} 128 & -16 \\ -16 & 23 \end{pmatrix} \begin{pmatrix} 23 \\ -8 \end{pmatrix} \\ &= \frac{1}{23^4} \begin{pmatrix} 23 & -8 \end{pmatrix} \begin{pmatrix} 3072 \\ -552 \end{pmatrix} = \frac{3264}{23^3} \approx 0.27. \end{aligned}$$

b. Aišku, kad

$$T_n = \frac{N_{>1}/n}{N_{>1}/n + \bar{X}/n} = g_n(\overline{1_{\{X>1\}}}, \bar{X});$$

čia

$$g_n(u, v) = \frac{u}{u + v/n}.$$

Kadangi

$$\begin{aligned} E 1_{\{X>1\}}^2 &= E 1_{\{X>1\}} = \int_1^\infty \frac{dx}{x^4} = -\frac{x^{-3}}{3} \Big|_1^\infty = \frac{1}{3}, \\ E X &= \int_0^1 \frac{2x}{3} dx + \int_1^\infty \frac{dx}{x^3} = \frac{x^2}{3} \Big|_0^1 - \frac{x^{-2}}{2} \Big|_1^\infty = \frac{1}{3} + \frac{1}{2} = \frac{5}{6}, \\ E X^2 &= \int_0^1 \frac{2x^2}{3} dx + \int_1^\infty \frac{dx}{x^2} = \frac{2x^3}{9} \Big|_0^1 - \frac{1}{x} \Big|_1^\infty = \frac{2}{9} + 1 = \frac{11}{9}, \\ E X 1_{\{X>1\}} &= \int_1^\infty \frac{dx}{x^4} = -\frac{x^{-3}}{3} \Big|_1^\infty = \frac{1}{3}, \end{aligned}$$

gaunu

$$D 1_{\{X>1\}} = \frac{2}{9}, \quad D X = \frac{19}{36}, \quad \text{cov}(1_{\{X>1\}}, X) = \frac{1}{18}.$$

Reiškia,

$$\sqrt{n} \left[ \begin{pmatrix} \overline{1_{\{X>1\}}} \\ \bar{X} \end{pmatrix} - \begin{pmatrix} 1/3 \\ 5/6 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 2/9 & 1/18 \\ 1/18 & 19/36 \end{pmatrix}.$$

Pažymiu  $U_n = \sqrt{n}(\overline{1_{\{X>1\}}} - 1/3)$  ir  $V_n = \sqrt{n}(\bar{X} - 5/6)$ ; tada

$$\overline{1_{\{X>1\}}} = \frac{1}{3} + \frac{U_n}{\sqrt{n}}, \quad \bar{X} = \frac{5}{6} + \frac{V_n}{\sqrt{n}}.$$

Randu sekos  $g_n(1/3 + u_n/\sqrt{n}, 5/6 + v_n/\sqrt{n})$  asimptotiką, kai  $u_n \rightarrow u$  ir  $v_n \rightarrow v$ :

$$\begin{aligned}
& g_n(1/3 + u_n/\sqrt{n}, 5/6 + v_n/\sqrt{n}) \\
&= \frac{1/3 + u_n/\sqrt{n}}{1/3 + u_n/\sqrt{n} + 5/(6n) + v_n/n^{3/2}} \\
&= \left[1 + \frac{3u_n}{\sqrt{n}}\right] \left[1 + \frac{3u_n}{\sqrt{n}} + \frac{5}{2n} + \frac{3v_n}{n^{3/2}}\right]^{-1} \\
&= \left[1 + \frac{3u_n}{\sqrt{n}}\right] \left[1 - \left(\frac{3u_n}{\sqrt{n}} + \frac{5}{2n} + \frac{3v_n}{n^{3/2}}\right) + \left(\frac{3u_n}{\sqrt{n}} + \frac{5}{2n} + \frac{3v_n}{n^{3/2}}\right)^2 \right. \\
&\quad \left. - \left(\frac{3u_n}{\sqrt{n}} + \frac{5}{2n} + \frac{3v_n}{n^{3/2}}\right)^3 + o(n^{-3/2})\right] \\
&= \left[1 + \frac{3u_n}{\sqrt{n}}\right] \left[1 - \frac{3u_n}{\sqrt{n}} - \frac{5}{2n} - \frac{3v_n}{n^{3/2}} + \frac{9u_n^2}{n} + \frac{15u_n}{n^{3/2}} - \frac{27u_n^3}{n^{3/2}} + o(n^{-3/2})\right] \\
&= 1 - \frac{5}{2n} + \frac{15u_n - 6v_n}{2n^{3/2}} + o(n^{-3/2}).
\end{aligned}$$

Kitaip tariant,

$$n^{3/2} [g_n(1/3 + u_n/\sqrt{n}, 5/6 + v_n/\sqrt{n}) - 1 + 5/(2n)] \rightarrow \frac{15u - 6v}{2}.$$

Iš tolydaus atvaizdžio principo dabar išplaukia, kad

$$n^{3/2} \left[T_n - 1 + \frac{5}{2n}\right] \rightarrow \frac{3}{2} \begin{pmatrix} 5 & -2 \end{pmatrix} N(0, \Sigma) = N(0, \sigma^2);$$

čia

$$\sigma^2 = \frac{1}{16} \begin{pmatrix} 5 & -2 \end{pmatrix} \begin{pmatrix} 8 & 2 \\ 2 & 19 \end{pmatrix} \begin{pmatrix} 5 \\ -2 \end{pmatrix} = \frac{1}{16} \begin{pmatrix} 5 & -2 \end{pmatrix} \begin{pmatrix} 36 & -28 \end{pmatrix} = \frac{59}{4}.$$

## 4 skyrius

# Taikymai

### 4.1 Pasikliautiniai intervalai

#### 4.1.1 Uždavinio formulavimas

Tegu  $X_1, \dots, X_n$  yra nepriklausomi vienodai pasiskirstę atsitiktiniai dydžiai. Apie jų skirstinį yra žinoma tik tiek, kad jis priklauso tam tikrai skirstinių šeimai ( $F_\theta \mid \theta \in \Theta$ ), priklausančiai nuo realaus parametro  $\theta$ . Reikia įvertinti nežinomą parametro reikšmę  $\theta$ , t.y. rasti tokias statistikas  $\theta_*(x_1, \dots, x_n)$  ir  $\theta^*(x_1, \dots, x_n)$ , kad

$$P\{\theta_*(X_1, \dots, X_n) \leq \theta \leq \theta^*(X_1, \dots, X_n)\} \geq 1 - \alpha; \quad (4.1)$$

čia  $\alpha$  yra tam tikras mažas skaičius. Paprastai imama  $\alpha = 5\% = 0.05$ ; tada intervalas  $[\theta_*; \theta^*]$  vadinamas 95% lygmens pasikliautiniu intervalu.

Jei paimtume

$$\theta_*(x_1, \dots, x_n) = \theta^*(x_1, \dots, x_n) = \theta,$$

(4.1) formulė būtų teisinga ir su  $\alpha = 0$ . Tačiau  $[\theta; \theta]$  nevadinamas pasikliautiniu intervalu, nes tokių funkcijų  $\theta_*$  ir  $\theta^*$  neįmanoma apskaičiuoti, nežinant tikrosios parametro reikšmės, ir todėl jos nevadinamos statistikomis. Griežtai dėstant matematinę statistiką, tikrosios parametro reikšmės nežinojimas formalizuojamas taip.  $\theta$  laikomas kintamuoju, o atsitiktiniai dydžiai  $X_i$  — priklausančiais nuo to kintamojo:  $X_i = X_i(\theta)$ . Ieškome tokių statistikų  $\theta_*(x_1, \dots, x_n)$  ir  $\theta^*(x_1, \dots, x_n)$ , kad (4.1) būtų teisinga su visais  $\theta$ . Dabar niekas netrukdo paimti, pavyzdžiui,

$$\theta_*(x_1, \dots, x_n) = \theta^*(x_1, \dots, x_n) = 2.5,$$

bet tada (4.1) bus teisinga tik su  $\theta = 2.5$ . Todėl  $[2.5; 2.5]$  nėra pasikliautinas intervalas.

#### 4.1.2 Standartinė procedūra

Konkrečiuose modeliuose pasikliautiniai intervalai paprastai konstruojami taip. Iš pradžių randamas pagrįstas nežinomo parametro įvertis — tokia statistika  $\hat{\theta}(x_1, \dots, x_n)$ , kad su visais  $\theta$

$$\hat{\theta}(X_1, \dots, X_n) \rightarrow \theta.$$

Po to randamas asimptotinis  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  skirstinys; paprastai normalusis:

$$\sqrt{n}(\hat{\theta} - \theta) \rightarrow N(0, \sigma^2(\theta)).$$

Pažymima  $\hat{\sigma} = \sigma(\hat{\theta})$ . Jei funkcija  $\sigma(\theta)$  tolydi, tai pagal tolydaus atvaizdžio principą

$$\hat{\sigma} \rightarrow \sigma(\theta)$$

ir

$$\sqrt{n} \frac{\hat{\theta} - \theta}{\hat{\sigma}} \rightarrow N(0, 1).$$

Tegu  $z_{\alpha/2}$  yra standartinio normalaus skirstinio  $(\alpha/2)$ -kritinė reikšmė; tada

$$\begin{aligned} P\{N(0, 1) > z_{\alpha/2}\} &= \alpha/2, \\ P\{|N(0, 1)| \leq z_{\alpha/2}\} &= 1 - \alpha \end{aligned}$$

ir

$$P\left\{\sqrt{n} \frac{|\hat{\theta} - \theta|}{\hat{\sigma}} \leq z_{\alpha/2}\right\} \rightarrow 1 - \alpha.$$

Reiškia, kai  $n$  didelis, su  $\approx 1 - \alpha$  tikimybe

$$\sqrt{n} \frac{|\hat{\theta} - \theta|}{\hat{\sigma}} \leq z_{\alpha/2}$$

ir

$$\hat{\theta} - z_{\alpha/2} \frac{\hat{\sigma}}{\sqrt{n}} \leq \theta \leq \hat{\theta} + z_{\alpha/2} \frac{\hat{\sigma}}{\sqrt{n}}.$$

Taigi

$$\left[\hat{\theta} - z_{\alpha/2} \frac{\hat{\sigma}}{\sqrt{n}}; \hat{\theta} + z_{\alpha/2} \frac{\hat{\sigma}}{\sqrt{n}}\right]$$

yra asimptotinis  $(1 - \alpha)$  lygmens pasikliautinas intervalas.

### 4.1.3 Modifikuota procedūra

Vienas iš aukščiau aprašytos procedūros trūkumų — gaunamas pasikliautinas intervalas nebūtinai yra aibės  $\Theta$  poaibis. Pavyzdžiui, jei  $\theta$  yra kokio nors įvykio tikimybė, tai  $\Theta = (0; 1)$ . Įvertis  $\hat{\theta}$  dažniausiai priklauso tam intervalui, bet kairysis pasikliautino intervalo kraštas  $\hat{\theta} - z_{\alpha/2} \hat{\sigma} / \sqrt{n}$  nebūtinai teigiamas, o dešinysis kraštas gali būti didesnis už 1.

Jei standartinė procedūra dėl aukščiau aprašytų priežasčių mums nepatinka, galima naudoti tokią jos modifikaciją. Pasirenkame kokią nors griežtai didėjančią tolydžiai diferencijuojamą funkciją  $g: \Theta \rightarrow \mathbb{R}$  ir naudodami standartinę procedūrą randame pasikliautiną intervalą  $[\gamma_*; \gamma^*]$  parametrui  $\gamma = g(\theta)$ . Tada suskaičiuojame  $\theta_* = g^{-1}(\gamma_*)$ ,  $\theta^* = g^{-1}(\gamma^*)$  ir gauname pasikliautiną intervalą  $[\theta_*; \theta^*] \subset \Theta$  parametrui  $\theta$ .

4.1 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio

|     |       |       |         |
|-----|-------|-------|---------|
| $X$ | 1     | 2     | 3       |
|     | $p/2$ | $p/2$ | $1 - p$ |

Reikia įvertinti  $p$ .

*Sprendimas.* Pažymiu

$$\hat{p} = \frac{N_1 + N_2}{n} = \overline{1_{\{X \leq 2\}}};$$

čia  $N_j$  žymi  $j$  reikšmės pasikartojimų skaičių imtyje. Kadangi

$$E 1_{\{X \leq 2\}} = E 1_{\{X \leq 2\}}^2 = p,$$

gaunu  $D 1_{\{X \leq 2\}} = p - p^2 = p(1 - p)$  ir iš centrinės ribinės teoremos

$$\sqrt{n}(\hat{p} - p) \rightarrow N(0, p(1 - p)).$$

Tada

$$\sqrt{n} \frac{\hat{p} - p}{\hat{p}(1 - \hat{p})} \rightarrow N(0, 1);$$

todėl

$$\left[ \hat{p} - 1.96 \frac{\sqrt{\hat{p}(1 - \hat{p})}}{\sqrt{n}}; \hat{p} + 1.96 \frac{\sqrt{\hat{p}(1 - \hat{p})}}{\sqrt{n}} \right]$$

yra 95% lygmens pasikliautinas intervalas.

Jei pasikliautiną intervalą konstruočiau iš duomenų

$$1, 2, 3, 3, 3, 3, 3, 3, 3, 3,$$

(t.y. jei  $n = 10$ ,  $\hat{p} = 0.2$ ), gaučiau intervalą  $[-0.25; 0.45]$ , kurio kairysis kraštas neigiamas. Kad to išvengčiau, taikysiu modifikuotą procedūrą su funkcija

$$g(p) = \ln \frac{p}{1 - p}.$$

Kadangi

$$g'(p) = [\ln p - \ln(1 - p)]' = \frac{1}{p} + \frac{1}{1 - p} = \frac{1}{p(1 - p)},$$

$g$  funkcija yra griežtai didėjanti. Atvirkštinė funkcija gaunama išsprendus lygtį

$$\gamma = \ln \frac{p}{1 - p}$$

kintamojo  $p$  atžvilgiu:

$$\begin{aligned} \frac{p}{1 - p} &= e^\gamma; \\ p &= (1 - p)e^\gamma; \\ p(1 + e^\gamma) &= e^\gamma; \\ p &= \frac{e^\gamma}{1 + e^\gamma}. \end{aligned}$$

Pažymiu  $\hat{\gamma} = g(\hat{p})$ . Tada pagal delta metodą

$$\sqrt{n}(\hat{\gamma} - \gamma) \rightarrow N(0, \sigma^2)$$

su

$$\sigma^2 = [g'(p)]^2 p(1-p) = \frac{1}{p(1-p)}.$$

Taigi

$$[\gamma_*; \gamma^*] = \left[ \hat{\gamma} - \frac{1.96}{\sqrt{n\hat{p}(1-\hat{p})}}; \hat{\gamma} + \frac{1.96}{\sqrt{n\hat{p}(1-\hat{p})}} \right]$$

yra 95% pasikliautinas intervalas parametru  $\gamma$ , o

$$\left[ \frac{e^{\gamma_*}}{1+e^{\gamma_*}}; \frac{e^{\gamma^*}}{1+e^{\gamma^*}} \right] \quad \text{—}$$

95% pasikliautinas intervalas parametru  $p$ .

Jei, kaip ir aukščiau,  $n = 10$  ir  $\hat{p} = 0.2$ , tai

$$\hat{\gamma} = -1.386, \quad [\gamma_*; \gamma^*] = [-2.936; 0.114] \quad \text{ir} \quad [p_*; p^*] = [0.050; 0.528].$$

#### 4.1.4 Dispersijos stabilizavimo metodas

Taikant modifikuotą pasikliautinų intervalų konstravimo procedūrą, funkciją  $g$  kartais galima parinkti taip, kad parametro  $\gamma = g(\theta)$  asimptotinė dispersija nebepriklaustų nuo nežinomo parametro. Tokia funkcija vadinama *stabilizuojančia dispersija*.

Kadangi asimptotinė parametro  $\gamma$  dispersija lygi  $[g'(\theta)]^2 \sigma^2(\theta)$ , norėdami rasti dispersiją stabilizuojančią transformaciją, turime išspręsti diferencialinę lygtį

$$[g'(\theta)]^2 \sigma^2(\theta) = 1,$$

t.y. suskaičiuoti integralą

$$g(\theta) = \int \frac{d\theta}{\sigma(\theta)}.$$

Jei  $\gamma = g(\theta)$ , tai pasikliautinas intervalas  $\gamma$  parametru yra

$$[\gamma_*; \gamma^*] = \left[ \hat{\gamma} - \frac{z_{\alpha/2}}{\sqrt{n}}; \hat{\gamma} + \frac{z_{\alpha/2}}{\sqrt{n}} \right] \quad (4.2)$$

pavidalo; čia  $\hat{\gamma} = g(\hat{\theta})$ .

4.2 PAVYZDYS. Tarkime, turime imtį iš to paties skirstinio, kaip ankstesniame pavyzdyje. Reikia įvertinti nežinomą parametru  $p$ , taikant dispersijos stabilizavimo metodą.

*Sprendimas.* Ankstesniame pavyzdyje suskaičiavau, kad jei  $\hat{p} = (N_1 + N_2)/n$ , tai

$$\sqrt{n}(\hat{p} - p) \rightarrow N(0, p(1-p)).$$

Taigi dispersiją stabilizuojanti transformacija

$$\begin{aligned} g(p) &= \int \frac{dp}{\sqrt{p(1-p)}} = \int \frac{2dp}{\sqrt{1-(2p-1)^2}} = [t = 2p-1] \\ &= \int \frac{dt}{\sqrt{1-t^2}} = \arcsin t = \arcsin(2p-1). \end{aligned}$$



Atvirkštinė transformacija gaunama išsprendus lygtį

$$\gamma = \arcsin(2p - 1)$$

$p$  atžvilgiu:

$$(2p - 1) = \sin \gamma;$$

$$p = \frac{1 + \sin \gamma}{2}.$$

Tačiau reikia turėti omenyje, kad ši funkcija yra  $g$  funkcijos atvirkštinė tik jei jos apibrėžimo sritį susiaurinsime iki  $g$  funkcijos reikšmių srities, t.y. — iki  $[-\pi/2; \pi/2]$  intervalo. Kitaip tariant,

$$\gamma_* \leq \gamma \leq \gamma^* \iff \frac{1 + \sin \gamma_*}{2} \leq p \leq \frac{1 + \sin \gamma^*}{2}$$

tik tada, jei  $\gamma_*, \gamma^* \in [-\pi/2; \pi/2]$ . Todėl jei pagal (4.2) formulę gaunamas rėžis  $\gamma_* < -\pi/2$  (atitinkamai,  $\gamma^* > \pi/2$ ), reikia imti  $\gamma_* = -\pi/2$  (atitinkamai,  $\gamma^* = \pi/2$ ).

Tegu, pavyzdžiui,  $n = 10$  ir  $\hat{p} = 0.2$ . Tada  $\hat{\gamma} = \arcsin(-0.8) = -0.644$  ir pagal (4.2) formulę gaunu

$$[\gamma_*; \gamma^*] = [-1.264; -0.024].$$

Kadangi  $-1.264 > -\pi/2$ , pasikliautinas intervalas  $p$  parametrui yra

$$\left[ \frac{1 + \sin(-1.264)}{2}; \frac{1 + \sin(-0.024)}{2} \right] = [0.023; 0.488].$$

Jei  $\hat{p} = 0$ , pagal (4.2) formulę gaučiau

$$[\gamma_*; \gamma^*] = [-2.191; -0.951].$$

Šiuo atveju  $\gamma_* < \pi/2$ ; todėl pasikliautinas intervalas  $p$  parametrui yra  $[0; 0.093]$ , nors  $(1 + \sin(-2.191))/2 = 0.093$ .

## 4.2 Hipotezių tikrinimas

### 4.2.1 Bendra teorija

Tarkime,  $X_1, \dots, X_n$  yra imtis iš kokio nors nežinomo skirstinio ir reikia patikrinti tam tikrą statistinę hipotezę apie tą skirstinį. Hipotezės tikrinimo kriterijus apibrėžiamas, nurodant tam tikrą galimų imties reikšmių poaibį  $A$ ; jei  $(X_1, \dots, X_n) \in A$ , hipotezė atmetama, priešingu atveju ji priimama.

Minimalus reikalavimas bet kokiam kriterijui — jo pirmos rūšies klaidos tikimybė turi neviršyti tam tikro mažo skaičiaus  $\alpha$ , vadinamo kriterijaus reikšmingumo lygmeniu. Kitaip tariant, jei imtis yra iš skirstinio, tenkinančio hipotezę, tai turi būti teisinga nelygybė

$$P\{(X_1, \dots, X_n) \in A\} \leq \alpha.$$

Jei nelygybė teisinga tik asimptotiškai, t.y. jei

$$\overline{\lim}_{n \rightarrow \infty} P\{(X_1, \dots, X_n) \in A\} \leq \alpha,$$

$\alpha$  vadinamas asimptotiniu reikšmingumo lygmeniu.

Kriterijai paprastai konstruojami taip. Parenkama kokia nors statistika  $T_n$  ir randamas jos asimptotinis skirstinys, t.y. įrodomas

$$b_n(T_n - a_n) \rightarrow T$$

pavidalo teiginys. Statistika  $T_n$  turi būti tokia, kad jei hipotezė teisinga, skaičiai  $a_n$ ,  $b_n$  ir  $T$  dydžio skirstinys nepriklausytų nuo nežinomo imties skirstinio. Tada hipotezę galima atmesti, kai  $b_n(T_n - a_n) \in A$ ; čia  $A$  aibė parenkama taip, kad

$$P\{T \in A\} \leq \alpha.$$

### 4.2.2 Nepriklausomumo tikrinimas, remiantis empiriniu koreliacijos koeficientu

4.3 PAVYZDYS. Tegu  $(X_1, Y_1), \dots, (X_n, Y_n)$  yra nepriklausomos atsitiktinio vektoriaus  $(X, Y)$  kopijos ir  $EX^4 < \infty$ ,  $EY^4 < \infty$ . Reikia patikrinti hipotezę, kad  $X$  ir  $Y$  nepriklausomi.

*Sprendimas.* Sukonstruosiu kriterijų, besiremiantį empiriniu koreliacijos koeficientu

$$\hat{\rho} = \frac{\overline{(X - \bar{X})(Y - \bar{Y})}}{\sqrt{\overline{(X - \bar{X})^2}} \sqrt{\overline{(Y - \bar{Y})^2}}} = \frac{\overline{XY} - \bar{X}\bar{Y}}{\sqrt{\overline{X^2} - \bar{X}^2} \sqrt{\overline{Y^2} - \bar{Y}^2}}.$$

Iš pradžių rasiu asimptotinį  $\hat{\rho}$  skirstinį, kai hipotezė teisinga, t.y. kai  $X$  ir  $Y$  nepriklausomi. Pažymiu  $a_{jk} = EX^j Y^k$ . Tada

$$\begin{aligned} DX &= EX^2 - (EX)^2 = a_{20} - a_{10}^2, \\ \text{cov}(X, Y) &= EXY - EXEY = a_{11} - a_{10}a_{01}, \\ \text{cov}(X, X^2) &= EX^3 - EXEX^2 = a_{30} - a_{10}a_{20}, \\ \text{cov}(X, Y^2) &= EXY^2 - EXEY^2 = a_{12} - a_{10}a_{02}, \\ \text{cov}(X, XY) &= EX^2Y - EXEXY = a_{21} - a_{10}a_{11}, \\ DY &= EY^2 - (EY)^2 = a_{02} - a_{01}^2, \\ \text{cov}(Y, X^2) &= EX^2Y - EX^2EY = a_{21} - a_{20}a_{01}, \\ \text{cov}(Y, Y^2) &= EY^3 - EYEY^2 = a_{03} - a_{01}a_{02}, \\ \text{cov}(Y, XY) &= EXY^2 - EYEY^2 = a_{12} - a_{01}a_{11}, \\ D(X^2) &= EX^4 - (EX^2)^2 = a_{40} - a_{20}^2, \\ \text{cov}(X^2, Y^2) &= EX^2Y^2 - EX^2EY^2 = a_{22} - a_{20}a_{02}, \\ \text{cov}(X^2, XY) &= EX^3Y - EX^2EY = a_{31} - a_{20}a_{01}, \\ D(Y^2) &= EY^4 - (EY^2)^2 = a_{04} - a_{02}^2, \\ \text{cov}(Y^2, XY) &= EXY^3 - EY^2EXY = a_{13} - a_{02}a_{11}, \\ D(XY) &= EX^2Y^2 - (EXY)^2 = a_{22} - a_{11}^2. \end{aligned}$$

Pradėsiu nuo atskiro atvejo, kai

$$EX = EY = 0, \quad EX^2 = EY^2 = 1. \quad (4.3)$$

Vėliau matysime, kad bendrą atvejį nesunku suvesti į išnagrinėtąjį. Taigi  $a_{10} = a_{01} = 0$ ,  $a_{20} = a_{02} = 1$ . Be to, jei hipotezė teisinga,  $a_{jk} = a_{j0}a_{0k}$ . Taigi iš centrinės ribinės teoremos

$$\sqrt{n} \left[ \begin{pmatrix} \overline{X} \\ \overline{Y} \\ \overline{X^2} \\ \overline{Y^2} \\ \overline{XY} \end{pmatrix} - \begin{pmatrix} 0 \\ 0 \\ 1 \\ 1 \\ 0 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} 1 & 0 & a_{30} & 0 & 0 \\ 0 & 1 & 0 & a_{03} & 0 \\ a_{30} & 0 & a_{40} - 1 & 0 & 0 \\ 0 & a_{03} & 0 & a_{04} - 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}.$$

Dabar taikau vektorinį delta metodą. Aišku, kad  $\hat{\rho} = g(\overline{X}, \overline{Y}, \overline{X^2}, \overline{Y^2}, \overline{XY})$ ;  
čia

$$g(u) = \frac{u_{11} - u_{10}u_{01}}{\sqrt{u_{20} - u_{10}^2} \sqrt{u_{02} - u_{01}^2}},$$

kai  $u = (u_{10}, u_{01}, u_{20}, u_{02}, u_{11})$ . Pažymiu

$$a = (a_{10}, a_{01}, a_{20}, a_{02}, a_{11}) = (0, 0, 1, 1, 0).$$

Kadangi

$$\begin{aligned} \frac{\partial g}{\partial u_{10}} &= -\frac{u_{01}}{\sqrt{u_{20} - u_{10}^2} \sqrt{u_{02} - u_{01}^2}} - \frac{u_{11} - u_{10}u_{01}}{2\sqrt{u_{02} - u_{01}^2}} (u_{20} - u_{10}^2)^{-3/2} (-2u_{10}), \\ \frac{\partial g}{\partial u_{20}} &= -\frac{u_{11} - u_{10}u_{01}}{2\sqrt{u_{02} - u_{01}^2}} (u_{20} - u_{10}^2)^{-3/2}, \\ \frac{\partial g}{\partial u_{11}} &= \frac{1}{\sqrt{u_{20} - u_{10}^2} \sqrt{u_{02} - u_{01}^2}} \end{aligned}$$

gaunu

$$\frac{\partial g}{\partial u_{10}}(a) = 0, \quad \frac{\partial g}{\partial u_{20}}(a) = 0, \quad \frac{\partial g}{\partial u_{11}}(a) = 1$$

ir analogiškai

$$\frac{\partial g}{\partial u_{01}}(a) = 0, \quad \frac{\partial g}{\partial u_{02}}(a) = 0.$$

Reiškia,

$$\sqrt{n}(\hat{\rho} - 0) \rightarrow N(0, \sigma^2);$$

čia

$$\sigma^2 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} a_{30} & 0 & a_{40} - 1 & 0 & 0 \\ a_{30} & 0 & a_{40} - 1 & 0 & 0 \\ 0 & a_{03} & 0 & a_{04} - 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{pmatrix}$$

$$= (0 \ 0 \ 0 \ 0 \ 1) \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{pmatrix} \\ = 1.$$

Kitaip tariant, jei hipotezė teisinga ir teisingos (4.3) lygybės, tai

$$\sqrt{n}\hat{\rho} \rightarrow N(0, 1).$$

Dabar išnagrinėsiu bendrą atvejį:  $X$  ir  $Y$  nepriklausomi, bet (4.3) lygybės nebūtinai teisingos. Pažymiu

$$U_i = \frac{X_i - EX}{\sqrt{DX}}, \quad V_i = \frac{Y_i - EY}{\sqrt{DY}}.$$

Aišku, kad  $(U_i, V_i)$  yra nepriklausomos vektoriaus  $(U, V)$  kopijos; čia

$$U = \frac{X - EX}{\sqrt{DX}}, \quad V = \frac{Y - EY}{\sqrt{DY}}.$$

Jei hipotezė teisinga, t.y.  $X$  ir  $Y$  nepriklausomi, tai dydžiai  $U$  ir  $V$  taip pat nepriklausomi; be to,

$$EU = \frac{E(X - EX)}{\sqrt{DX}} = \frac{EX - EX}{\sqrt{DX}} = 0, \\ EU^2 = \frac{E(X - EX)^2}{DX} = \frac{DX}{DX} = 1$$

ir analogiškai

$$EV = 0, \quad EV^2 = 1.$$

Taigi  $U$  ir  $V$  tenkina (4.3) sąlygas; todėl pagal išnagrinėtą atvejį

$$\sqrt{n} \frac{\overline{(U - \bar{U})(V - \bar{V})}}{\sqrt{\overline{(U - \bar{U})^2}} \sqrt{\overline{(V - \bar{V})^2}}} \rightarrow N(0, 1).$$

Kita vertus, jei su kokiomis nors konstantomis  $a > 0$ ,  $c > 0$ ,  $b$  ir  $d$

$$U = aX + b, \quad V = cY + d$$

(mūsų atveju taip ir yra:  $a = 1/\sqrt{DX}$ ,  $b = -EX/\sqrt{DX}$ ,  $c = 1/\sqrt{DY}$ ,  $d = -EY/\sqrt{DY}$ ), tai

$$EU = aEX + b, \quad EV = cEY + d;$$

todėl

$$\frac{\overline{(U - \bar{U})(V - \bar{V})}}{\sqrt{\overline{(U - \bar{U})^2}} \sqrt{\overline{(V - \bar{V})^2}}} = \frac{ac \overline{(X - \bar{X})(Y - \bar{Y})}}{\sqrt{a^2 \overline{(X - \bar{X})^2}} \sqrt{c^2 \overline{(Y - \bar{Y})^2}}} = \hat{\rho}.$$

Reiškia,

$$\sqrt{n}\hat{\rho} \rightarrow N(0, 1) \quad (4.4)$$

ir bendruoju atveju.

Nepriklausomumo hipotezės tikrinimo kriterijus dabar gali būti aprašytas taip: hipotezė atmetama, kai  $\sqrt{n}|\hat{\rho}| > c$ ; čia  $c$  — tokia konstanta, kad

$$P\{|N(0, 1)| > c\} = \alpha.$$

Jei hipotezė teisinga, tai iš (4.4) išplaukia, kad jos atmetimo tikimybė

$$P\{\sqrt{n}|\hat{\rho}| > c\} \rightarrow P\{|N(0, 1)| > c\} = \alpha.$$

Reiškia,  $\alpha$  asimptotinis tokio kriterijaus reikšmingumo lygmuo.

### 4.3 Klaidingos modelio specifikacijos efektas

#### 4.3.1 Hipotezės apie dispersiją tikrinimas

**Uždavinio formulavimas.** Tegū  $X_1, \dots, X_n$  yra imtis iš normalaus skirstinio su nežinomu vidurkiu  $\mu$  ir dispersija  $\sigma^2$  ir reikia patikrinti hipotezę  $\sigma = \sigma^*$ ; čia  $\sigma^*$  — koks nors fiksuotas skaičius. Paprastai tai daroma taip: apskaičiuojamos statistika

$$Q_n = \frac{1}{\sigma^{*2}} \sum_{i=1}^n (X_i - \bar{X})^2$$

ir hipotezė atmetama, jei  $Q_n > \chi_\alpha^2(n-1)$ ; čia  $\chi_\alpha^2(n-1)$  yra  $\chi^2(n-1)$  skirstinio  $\alpha$  lygmens kritinė reikšmė, t.y. toks skaičius  $c$ , kad

$$P\{\chi^2(n-1) > c\} = \alpha.$$

Aprašytas kriterijus pagrindžiamas taip: jei hipotezė teisinga, tai  $Q_n$  statistika pasiskirsčiusi pagal  $\chi^2(n-1)$  dėsnį; todėl hipotezės atmetimo tikimybė lygi  $P\{\chi^2(n-1) > \chi_\alpha^2(n-1)\} = \alpha$ . Taigi kriterijaus pirmos rūšies klaidos tikimybė yra  $\alpha$ .

Jei  $X_1, \dots, X_n$  skirstinys nenormalus,  $Q$  skirstinys jau nebus  $\chi^2(n-1)$ , net jei hipotezė  $\sigma = \sigma^*$  teisinga (t.y. jei  $X_i$  dispersija lygi  $\sigma^{*2}$ ). Todėl kriterijaus pirmos rūšies klaidos tikimybė jau nėra tiksliai  $\alpha$ . Bet galima tikėtis, kad ji bus apytiksliai lygi  $\alpha$ , jei  $n$  pakankamai didelis. Išsiaiškinkime, ar tikrai.

Kad būtų paprasčiau, laikysiu  $\sigma^* = 1$ . Tarkime, hipotezė teisinga, t.y.  $X_1, \dots, X_n$  yra imtis iš skirstinio su dispersija 1. Reikia apskaičiuoti ribą

$$\lim_{n \rightarrow \infty} P\{Q_n > \chi_\alpha^2(n-1)\};$$

čia  $Q_n$  yra ta pati statistika, kaip aukščiau. Norėdamas rasti tą ribą, iš pradžių rasiu  $Q_n$  asimptotiką, o po to — skaičių sekos  $\chi_\alpha^2(n-1)$  asimptotiką, kai  $n \rightarrow \infty$ .

**$Q_n$  asimptotika.** Aišku, kad

$$\begin{aligned} Q_n/n &= \overline{(X - \bar{X})^2} = \overline{X^2 - 2X\bar{X} + \bar{X}^2} \\ &= \overline{X^2} - 2\overline{X\bar{X}} + \overline{\bar{X}^2} = \overline{X^2} - \bar{X}^2 = g(u, v); \end{aligned}$$

čia  $g(u, v) = v - u^2$ .

Su  $j \geq 1$  pažymiu  $a_j = E X^j$ . Tada

$$\begin{aligned} D X &= E X^2 - (E X)^2 = a_2 - a_1^2; \\ D X^2 &= E X^4 - (E X^2)^2 = a_4 - a_2^2; \\ \text{cov}(X, X^2) &= E X^3 - E X E X^2 = a_3 - a_1 a_2. \end{aligned}$$

Jei hipotezė teisinga, tai  $D X = a_2 - a_1^2 = 1$ , t.y.

$$a_2 = a_1^2 + 1.$$

Taigi iš centrinės ribinės teoremos

$$\sqrt{n} \left[ \begin{pmatrix} \bar{X} \\ \bar{X}^2 \end{pmatrix} - \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \right] \rightarrow N(0, \Sigma);$$

čia

$$\Sigma = \begin{pmatrix} a_2 - a_1^2 & a_3 - a_1 a_2 \\ a_3 - a_1 a_2 & a_4 - a_2^2 \end{pmatrix} = \begin{pmatrix} 1 & a_3 - a_1^3 - a_1 \\ a_3 - a_1^3 - a_1 & a_4 - a_1^4 - 2a_1^2 - 1 \end{pmatrix}.$$

Dabar taikau vektorinį delta metodą. Kadangi  $g(a_1, a_2) = a_2 - a_1^2 = 1$  ir

$$\frac{\partial g}{\partial u} = -2u, \quad \frac{\partial g}{\partial v} = 1,$$

gaunu

$$\sqrt{n} [Q_n/n - 1] \rightarrow N(0, \sigma^2);$$

čia

$$\begin{aligned} \sigma^2 &= \begin{pmatrix} -2a_1 & 1 \end{pmatrix} \begin{pmatrix} 1 & a_3 - a_1^3 - a_1 \\ a_3 - a_1^3 - a_1 & a_4 - a_1^4 - 2a_1^2 - 1 \end{pmatrix} \begin{pmatrix} -2a_1 \\ 1 \end{pmatrix} \\ &= \begin{pmatrix} -2a_1 & 1 \end{pmatrix} \begin{pmatrix} a_3 - a_1^3 - 3a_1 \\ a_4 - 2a_1 a_3 + a_1^4 - 1 \end{pmatrix} \\ &= a_4 - 4a_1 a_3 + 3a_1^4 + 6a_1^2 - 1 \end{aligned}$$

$\chi_\alpha^2(n-1)$  **asimptotika.** Pažymiu  $c_{n-1} = \chi_\alpha^2(n-1)$ . Pagal apibrėžimą  $c_n$  yra toks skaičius, kad

$$P\{\chi^2(n) > c_n\} = \alpha.$$

Kita vertus,  $\chi^2(n)$  yra sumos  $Y_1^2 + \dots + Y_n^2 = n\bar{Y}^2$  skirstinys; čia  $Y_1, \dots, Y_n$  — nepriklausomi atsitiktiniai dydžiai, turintys standartinį normalų pasiskirstymą.

Kadangi  $E Y = 0$ ,  $E Y^2 = D Y = 1$  ir

$$\begin{aligned} E Y^4 &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^4 e^{-x^2/2} dx \\ &= \frac{2}{\sqrt{2\pi}} \int_0^{\infty} x^4 e^{-x^2} dx \\ &= \frac{4}{\sqrt{\pi}} \int_0^{\infty} y^{3/2} e^{-y} dy \end{aligned} \quad \left[ \begin{array}{l} x^2/2 = y \\ x = \sqrt{2y} \\ dx = \frac{dy}{\sqrt{2y}} \end{array} \right]$$

$$\begin{aligned}
&= \frac{4}{\sqrt{\pi}} \Gamma(5/2) \\
&= \frac{4}{\sqrt{\pi}} \frac{3}{2} \frac{1}{2} \sqrt{\pi} \\
&= 3,
\end{aligned}$$

gaunu  $DY^2 = 3 - 1 = 2$  ir iš centrinės ribinės teoremos

$$\sqrt{n}(\overline{Y^2} - 1) \rightarrow N(0, 2).$$

Kitaip tariant,

$$\sqrt{n/2}(\overline{Y^2} - 1) \rightarrow N(0, 1).$$

Toliau:

$$\begin{aligned}
&P\{n\overline{Y^2} > c_n\} = \alpha; \\
&P\{\overline{Y^2} > c_n/n\} = \alpha; \\
&P\{\sqrt{n/2}(\overline{Y^2} - 1) > \sqrt{n/2}(c_n/n - 1)\} = \alpha.
\end{aligned}$$

Dydis  $\sqrt{n/2}(\overline{Y^2} - 1)$  konverguoja į  $N(0, 1)$ . Tam, kad tikimybė išliktų pastovi, dydis  $\sqrt{n/2}(c_n/n - 1)$  turi artėti į tokį skaičių  $c$ , su kuriuo

$$P\{N(0, 1) > c\} = \alpha.$$

Aišku, kad  $c$  yra standartinio normalaus skirstinio  $\alpha$  lygmens kritinė reikšmė. Paprastai ji žymima  $z_\alpha$ . Taigi

$$\sqrt{n/2}(c_n/n - 1) \rightarrow z_\alpha,$$

t.y.

$$\begin{aligned}
\sqrt{n/2}(c_n/n - 1) &= z_\alpha + o(1); \\
c_n/n &= 1 + \frac{\sqrt{2}z_\alpha}{\sqrt{n}} + o(n^{-1/2}); \\
c_n &= n + z_\alpha\sqrt{2n} + o(n^{1/2}).
\end{aligned}$$

Iš čia

$$c_{n-1} = n - 1 + z_\alpha\sqrt{2n - 2} + o(n^{1/2}) = n + z_\alpha\sqrt{2n} + o(n^{1/2}).$$

**Klaidos tikimybės asimptotika.** Jei hipotezė teisinga, tai pirmos rūšies klaidos tikimybė

$$\begin{aligned}
P\{Q_n > c_{n-1}\} &= P\left\{\sqrt{n}(Q_n/n - 1) > \sqrt{n}(c_{n-1}/n - 1)\right\} \\
&= P\left\{\sqrt{n}(Q_n/n - 1) > z_\alpha\sqrt{2} + o(1)\right\} \\
&= P\left\{\sqrt{n}(Q_n/n - 1) + o(1) > z_\alpha\sqrt{2}\right\} \\
&\rightarrow P\{N(0, \sigma^2) > z_\alpha\sqrt{2}\} \\
&= P\{N(0, 1) > z_\alpha\sqrt{2}/\sigma\}.
\end{aligned}$$

Reiškinys dešinėje pusėje lygus  $\alpha$  tik tada, kai

$$z_\alpha \sqrt{2}/\sigma = z_\alpha,$$

t.y.  $\sigma^2 = 2$ , t.y.

$$a_4 - 4a_1a_3 + 3a_1^4 + 6a_1^2 - 1 = 2.$$

Normalios imties atveju taip ir yra (pavyzdžiui, jei  $X_1, \dots, X_n$  yra imtis iš standartinio normalaus skirstinio, tai  $a_1 = 0$  ir  $a_4 = 3$ ). Tačiau apskritai  $\sigma^2$  gali būti bet koks. Reiškia, nagrinėjamo kriterijaus nenormalioms imtims taikyti negalima.



## 5 skyrius

# *M*-įvertiniai

### 5.1 Maksimalaus tikėtinumo įvertiniai

**Bendra teorija.** Tegū  $X_1, \dots, X_n$  yra imtis iš skirstinio su tankiu  $p_\theta(x)$  (kokio nors mato  $\mu$  atžvilgiu), priklausančio nuo nežinomo parametro  $\theta$ , kurį reikia įvertinti. Tegū  $\Theta$  yra galimų parametro reikšmių aibė,

$$l_\theta(x) = \ln p_\theta(x), \quad L(\theta) = \frac{1}{n} \sum_{i=1}^n l_\theta(X_i) = \overline{l_\theta(X)}$$

ir  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  — toks aibės  $\Theta$  taškas, kad

$$L(\hat{\theta}) = \max_{\theta \in \Theta} L(\theta).$$

Tada  $\hat{\theta}$  vadinamas  $\theta$  parametro *maksimalaus tikėtinumo įvertiniu*.

Išvestinę  $\theta$  parametro atžvilgiu žymėsiu tašku virš funkciją žyminčios raidės; pavyzdžiui,  $\dot{L}(\theta)$ . Jei  $\Theta$  aibė atvira, o  $L$  funkcija diferencijuojama, maksimalaus tikėtinumo įvertis yra lygties

$$\dot{L}(\theta) = 0$$

šaknis. Ši lygtis vadinama *maksimalaus tikėtinumo lygtimi*.

5.1 PAVYZDYS. Tegū  $X_1, \dots, X_n$  yra imtis iš skirstinio su tankiu

$$p_\theta(x) = \theta e^{-\theta x}, \quad \text{kai } x > 0;$$

čia  $\theta > 0$  — nežinomas parametras. Raskite jo maksimalaus tikėtinumo įvertinį.

*Sprendimas.* Šiuo atveju

$$\begin{aligned} l_\theta(x) &= \ln \theta - \theta x, \\ L(\theta) &= \overline{\ln \theta - \theta X} = \ln \theta - \theta \overline{X}, \\ \dot{L}(\theta) &= \frac{1}{\theta} - \overline{X}. \end{aligned}$$

Sprendžiu maksimalaus tikėtinumo lygtį:

$$\frac{1}{\theta} - \overline{X} = 0;$$

$$\frac{1}{\theta} = \overline{X};$$

$$\theta = \frac{1}{\overline{X}}.$$

Taigi  $\hat{\theta} = 1/\overline{X}$ .

**Atvejis, kai imtis iš diskretaus skirstinio.** Tegu  $X(\theta)$  žymi atsitiktinį dydį, kurio skirstinys priklauso nagrinėjamai skirstinių šeimai ir atitinka parametro reikšmę  $\theta$ . Jei visi  $X(\theta)$  įgyja tik sveikąsias reikšmes, vietoje  $\mu$  paprastai imamas skaičiuojantis matas. Tada

$$p_{\theta}(k) = P\{X(\theta) = k\},$$

o

$$L(\theta) = \frac{1}{n} \sum_k N_k \ln p_{\theta}(k);$$

čia  $N_k$  yra  $k$  reikšmės pasikartojimų skaičius imtyje:

$$N_k = \sum_{i=1}^n 1_{\{X_i=k\}}.$$

Taigi

$$L(\theta) = \sum_k \ln p_{\theta}(k) \overline{1_{\{X_i=k\}}}.$$

5.2 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio

|     |     |      |          |
|-----|-----|------|----------|
| $X$ | 1   | 2    | 3        |
|     | $p$ | $2p$ | $1 - 3p$ |

čia  $p \in (0; 1/3)$  — nežinomas parametras. Raskite jo maksimalaus tikėtinumo įvertį.

*Sprendimas.* Šiuo atveju

$$L(p) = N_1 \ln p + N_2 \ln(2p) + N_3 \ln(1 - 3p);$$

$$\dot{L}(p) = \frac{N_1}{p} + \frac{2N_2}{2p} - \frac{3N_3}{1 - 3p}.$$

Sprendžiu maksimalaus tikėtinumo lygtį:

$$\frac{N_1}{p} + \frac{2N_2}{2p} - \frac{3N_3}{1 - 3p} = 0;$$

$$\frac{N_1 + N_2}{p} = \frac{3N_3}{1 - 3p};$$

$$(N_1 + N_2)(1 - 3p) = 3N_3p;$$

$$3(N_1 + N_2 + N_3)p = N_1 + N_2;$$

$$3np = N_1 + N_2;$$

$$p = \frac{N_1 + N_2}{3n}.$$

Taigi  $\hat{p} = (N_1 + N_2)/(3n)$ .

**Vektorinio parametro atvejis.** Kai  $\theta = (\theta_1, \dots, \theta_k)$  yra vektorinis parametras,

$$\dot{L}(\theta) = \left( \frac{\partial L}{\partial \theta_1} \quad \dots \quad \frac{\partial L}{\partial \theta_k} \right).$$

Tuomet vektorinė maksimalaus tikėtinumo lygtis ekvivalenti tokiai skaliarinių lygčių sistemai:

$$\begin{cases} \frac{\partial L}{\partial \theta_1} = 0; \\ \vdots \\ \frac{\partial L}{\partial \theta_k} = 0. \end{cases}$$

5.3 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš normalaus skirstinio su nežinomu vidurkiu  $\mu$  ir nežinoma dispersija  $\sigma^2$ . Raskite abiejų parametų maksimalaus tikėtinumo įvertinius.

*Sprendimas.* Šiuo atveju

$$p_{\mu, \sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/(2\sigma^2)};$$

$$l_{\mu, \sigma}(X) = -\ln \sqrt{2\pi} - \ln \sigma - \frac{(X - \mu)^2}{2\sigma^2};$$

$$L(\mu, \sigma) = -\ln \sqrt{2\pi} - \ln \sigma - \frac{(\overline{X - \mu})^2}{2\sigma^2};$$

$$\dot{L}(\mu, \sigma) = \left( -\frac{2(\overline{X - \mu})}{2\sigma^2} \quad -\frac{1}{\sigma} + \frac{(\overline{X - \mu})^2}{\sigma^3} \right) = \left( \frac{\overline{X - \mu}}{\sigma^2} \quad -\frac{1}{\sigma} + \frac{(\overline{X - \mu})^2}{\sigma^3} \right).$$

Sprendžiu maksimalaus tikėtinumo lygtį:

$$\begin{cases} \frac{\overline{X - \mu}}{\sigma^2} = 0; \\ -\frac{1}{\sigma} + \frac{(\overline{X - \mu})^2}{\sigma^3} = 0. \end{cases}$$

Iš pirmos lygties

$$\overline{X - \mu} = 0;$$

$$\overline{X} - \mu = 0;$$

$$\mu = \overline{X}.$$

Tada iš antrosios

$$\frac{1}{\sigma} = \frac{(\overline{X - \mu})^2}{\sigma^3};$$

$$\sigma^2 = \overline{(X - \mu)^2} = \overline{(X - \overline{X})^2};$$

$$\sigma = \sqrt{\overline{(X - \overline{X})^2}}.$$

Taigi

$$\hat{\mu} = \overline{X}, \quad \sigma = \sqrt{\overline{(X - \overline{X})^2}}.$$

5.4 PAVYZDYS. Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio

|     |     |         |              |
|-----|-----|---------|--------------|
| $X$ | 1   | 2       | 3            |
|     | $p$ | $p + q$ | $1 - 2p - q$ |

čia  $p > 0$  ir  $q \in (-p; 1 - 2p)$  — nežinomi parametrai. Raskite jų maksimalaus tikėtimumo įverčius.

*Sprendimas.* Šiuo atveju

$$nL(p, q) = N_1 \ln p + N_2 \ln(p + q) + N_3 \ln(1 - 2p - q);$$

$$n\dot{L}(p, q) = \left( \frac{N_1}{p} + \frac{N_2}{p + q} - \frac{2N_3}{1 - 2p - q} - \frac{N_2}{p + q} - \frac{N_3}{1 - 2p - q} \right).$$

Sprendžiu maksimalaus tikėtimumo lygtį:

$$\begin{cases} \frac{N_1}{p} + \frac{N_2}{p + q} - \frac{2N_3}{1 - 2p - q} = 0; \\ \frac{N_2}{p + q} - \frac{N_3}{1 - 2p - q} = 0. \end{cases}$$

Iš antros lygties

$$\frac{N_3}{1 - 2p - q} = \frac{N_2}{p + q}. \quad (5.1)$$

Įstatęs į pirmąją, gaunu:

$$\begin{aligned} \frac{N_1}{p} + \frac{N_2}{p + q} - \frac{2N_2}{p + q} &= 0; \\ \frac{N_1}{p} &= \frac{N_2}{p + q}; \\ N_1(p + q) &= N_2p; \\ N_1q &= (N_2 - N_1)p; \\ q &= \frac{N_2 - N_1}{N_1}p. \end{aligned}$$

Iš čia

$$p + q = \frac{N_2}{N_1}p \quad \text{ir} \quad 1 - 2p - q = 1 - 2p - \frac{N_2 - N_1}{N_1}p;$$

todėl iš (5.1) gaunu

$$\begin{aligned} 1 - 2p - q &= \frac{N_3}{N_2}(p + q); \\ 1 - 2p - \frac{N_2 - N_1}{N_1}p &= \frac{N_3}{N_1}p; \\ \left(1 + \frac{N_2 + N_3}{N_1}\right)p &= 1; \\ \frac{N_1 + N_2 + N_3}{N_1}p &= 1; \\ \frac{n}{N_1}p &= 1; \\ p &= \frac{N_1}{n}. \end{aligned}$$

Tada

$$q = \frac{N_2 - N_1}{N_1} \cdot \frac{N_1}{n} = \frac{N_2 - N_1}{n}.$$

Taigi

$$\hat{p} = \frac{N_1}{n} \quad \text{ir} \quad \hat{q} = \frac{N_2 - N_1}{n}.$$

## 5.2 $M$ -įvertinių pagrindumas. Klasikinė teorema

### 5.2.1 $M$ -įvertiniai ir $Z$ -įvertiniai

Tegu  $X_1, \dots, X_n$  yra imtis iš skirstinio  $F_{\theta_0}$ , priklausančio skirstinių šeimai ( $F_{\theta} \mid \theta \in \Theta$ ) ir reikia įvertinti nežinomą parametro reikšmę  $\theta_0$ . Vienas iš plačiai naudojamų įvertinių konstravimo būdų yra toks. Pasirenkama funkcijų šeima  $m_{\theta}(x)$ , apibrėžiama

$$M_n(\theta) = \overline{m_{\theta}(X)} = \frac{m_{\theta}(X_1) + \dots + m_{\theta}(X_n)}{n}$$

ir randamas toks  $\hat{\theta}_n = \hat{\theta}_n(X_1, \dots, X_n)$ , kad

$$M_n(\hat{\theta}_n) = \sup_{\theta \in \Theta} M_n(\theta).$$

Tada  $\hat{\theta}$  vadinamas  $M$ -įvertiniu.

Pirmame skyrelyje nagrinėti maksimalaus tikėtimumo įvertiniai yra  $M$ -įvertiniai: jie atitinka funkciją

$$m_{\theta}(x) = \ln p_{\theta}(x);$$

čia  $p_{\theta}$  yra  $F_{\theta}$  skirstinio tankis kokio nors mato atžvilgiu.

Kad  $M$ -įvertinys tikrai vertintų tai, ką reikia, t.y. nežinomą parametro reikšmę  $\theta_0$ , funkcijos  $m_{\theta}(x)$  turi tenkinti tam tikrą sąlygą. Tikrai, iš didžiųjų skaičių dėsnio

$$M_n(\theta) = \overline{m_{\theta}(X)} \rightarrow M(\theta);$$

čia

$$M(\theta) = \mathbb{E} m_{\theta}(X).$$

$\hat{\theta}_n$  yra  $M_n(\theta)$  maksimumo taškas; todėl natūralu reikalauti, kad  $\theta_0$  būtų vienintelis funkcijos  $M(\theta)$  maksimumo taškas.

Jei  $\Theta$  yra atviras  $\mathbb{R}^k$  poaibis, o  $m_{\theta}(x)$  funkcijos tolydžiai diferencijuojamos  $\theta$  atžvilgiu, tai maksimumo taško ieškome prilygindami 0  $M_n(\theta)$  funkcijos išvestinę. Pažymiu

$$\psi_{\theta}(x) = \dot{m}_{\theta}(x), \quad \Psi_n(\theta) = \overline{\psi_{\theta}(X)}, \quad \Psi(\theta) = \mathbb{E} \psi_{\theta}(X).$$

Jei  $\theta_0$  yra vienintelis  $\Psi(\theta)$  funkcijos nulis, o  $\hat{\theta}_n$  — koks nors  $\Psi_n(\theta)$  funkcijos nulis, galima tikėtis, kad  $\hat{\theta}_n \rightarrow \theta_0$ . Statistika  $\hat{\theta}_n$  vadinama  $Z$ -įvertiniu.

### 5.2.2 Klasikinė teorema

**5.1 teorema.** Tegu  $\Theta$  yra atviras intervalas, su visais  $x$  funkcija  $m_\theta(x)$  tolydi  $\theta$  atžvilgiu ir  $\theta_0$  yra  $M$  funkcijos lokalaus maksimumo taškas. Tada egzistuoja tokie įvertiniai  $\hat{\theta}_n$  ir tokios aibės  $A_n$ , kad

- (i)  $P\{(X_1, \dots, X_n) \in A_n\} \rightarrow 1$ ;
- (ii) kai  $(x_1, \dots, x_n) \in A_n$ ,  $\hat{\theta}_n(x_1, \dots, x_n)$  yra  $M_n$  funkcijos lokalaus maksimumo taškas;
- (iii)  $\hat{\theta}_n \rightarrow \theta_0$ .

*Irodymas.* Fiksuoju  $\delta$ , su kuriuo  $M(\theta_0 - \delta) < M(\theta_0) > M(\theta_0 + \delta)$ . Pažymiu

$$\varepsilon = \min(M(\theta_0) - M(\theta_0 - \delta), M(\theta_0) - M(\theta_0 + \delta))$$

ir

$$B_n = \{(x_1, \dots, x_n) \mid |M_n(\theta) - M(\theta)| < \varepsilon/2 \text{ su } \theta = \theta_0, \theta_0 \pm \delta\}.$$

Tada  $P\{(X_1, \dots, X_n) \in B_n\} \rightarrow 1$  ir, kai  $(X_1, \dots, X_n) \in B_n$ ,

$$M_n(\theta_0 - \delta) < M_n(\theta_0) > M_n(\theta_0 + \delta). \quad (5.2)$$

Taigi

$$P\{M_n(\theta_0 - \delta) < M_n(\theta_0) > M_n(\theta_0 + \delta)\} \rightarrow 1.$$

Iš lemos, kurią įrodysiu žemiau, išplaukia, kad su tam tikra seka  $\delta_n$ , artėjančia į 0,

$$P\{M_n(\theta_0 - \delta_n) < M_n(\theta_0) > M_n(\theta_0 + \delta_n)\} \rightarrow 1.$$

Pažymiu

$$A_n = \{(x_1, \dots, x_n) \mid M_n(\theta_0 - \delta_n) < M_n(\theta_0) > M_n(\theta_0 + \delta_n)\}.$$

Funkcija  $M_n(\theta)$  yra tolydi; todėl  $[\theta_0 - \delta_n; \theta_0 + \delta_n]$  intervale įgyja didžiausią reikšmę. Jei  $(x_1, \dots, x_n) \in A_n$ , tai ta didžiausia reikšmė įgyjama intervalo viduje ir todėl yra lokalus funkcijos maksimumas. Pažymiu jį  $\hat{\theta}_n(x_1, \dots, x_n)$ . Jei  $(x_1, \dots, x_n) \notin A_n$ ,  $\hat{\theta}_n$  apibrėžiu bet kaip. Tada, kai  $n$  pakankamai didelis,

$$P\{|\hat{\theta}_n - \theta_0| \geq \delta\} \leq P\{|\hat{\theta}_n - \theta_0| \geq \delta_n\} \leq P\{(X_1, \dots, X_n) \notin A_n\} \rightarrow 0, \quad (5.3)$$

t.y.  $\hat{\theta}_n \rightarrow \theta_0$ .  $\square$

**5.1 lema.** Tegu  $h_n(\delta)$  yra tokia realiųjų funkcijų seka, kad  $h_n(\delta) \xrightarrow{n \rightarrow \infty} 1$  su kiekvienu  $\delta$ . Tada egzistuoja tokia seka  $\delta_n \rightarrow 0$ , kad  $h_n(\delta_n) \rightarrow 1$ .

*Irodymas.* Paimu  $n_0 = 1$  ir su kiekvienu  $k \geq 1$  randu tokį  $n_k > n_{k-1}$ , kad  $|h_n(1/k) - 1| < 1/k$  su  $n \geq n_k$ . Apibrėžiu

$$\delta_n = \begin{cases} 2, & \text{kai } n < n_1; \\ 1, & \text{kai } n_1 \leq n < n_2; \\ \vdots & \\ 1/k, & \text{kai } n_k \leq n < n_{k+1}; \\ \vdots & \end{cases}$$

Aišku, kad  $\delta_n \rightarrow 0$ . Jei  $n \geq n_k$ , tai  $n_l \leq n < n_{l+1}$  su tam tikru  $l \geq k$ , o tada

$$|h_n(\delta_n) - 1| = |h_n(1/l) - 1| < 1/l \leq 1/k. \quad (5.4)$$

Reiškia,  $h_n(\delta_n) \rightarrow 1$ .  $\square$

Kad 5.1 teoremą būtų galima pritaikyti maksimalaus tikėtinumo įvertiniams, reikalinga dar viena teorema.

**5.2 teorema.** Tegu skirstinių šeima  $(F_\theta \mid \theta \in \Theta)$  identifikuojama, t.y. skirtingus  $\theta$  atitinka skirtingi skirstiniai  $F_\theta$ . Tada  $\theta_0$  yra vienintelis funkcijos  $M(\theta) = E \ln p_\theta(X)$  maksimumo taškas.

*Irodymas.* Iš nelygybės  $\ln x \leq 2(\sqrt{x} - 1)$ , teisingos su  $x > 0$ , gaunu

$$\begin{aligned} M(\theta) - M(\theta_0) &= E \ln \frac{p_\theta(X)}{p_{\theta_0}(X)} \leq 2 E \left( \sqrt{\frac{p_\theta(X)}{p_{\theta_0}(X)}} - 1 \right) \\ &= 2 \left( \int (\sqrt{p_\theta p_{\theta_0}} d\mu - 1) \right) = - \int (\sqrt{p_\theta} - \sqrt{p_{\theta_0}})^2 d\mu \leq 0. \end{aligned} \quad (5.5)$$

Taigi  $M(\theta) \leq M(\theta_0)$  su visais  $\theta$ . Be to, nelygybė virsta lygybe tik tada, kai  $p_\theta = p_{\theta_0}$  beveik visur  $\mu$  atžvilgiu, t.y. kai  $\theta = \theta_0$ .  $\square$

### 5.2.3 Įrodymų paaiškinimai

**5.1 teorema.**

1. Kodėl  $P\{(X_1, \dots, X_n) \in B_n\} \rightarrow 1$ ?

$B_n^c = B_n^1 \cup B_n^2 \cup B_n^3$ ; čia

$$\begin{aligned} B_n^1 &= \{|M_n(\theta_0) - M(\theta_0)| \geq \varepsilon/2\}, \quad B_n^2 = \{|M_n(\theta_0 - \delta) - M(\theta_0 - \delta)| \geq \varepsilon/2\}, \\ B_n^3 &= \{|M_n(\theta_0 + \delta) - M(\theta_0 + \delta)| \geq \varepsilon/2\}. \end{aligned}$$

Iš didžiųjų skaičių dėsnio išplaukia, kad su visais  $\theta$

$$M_n(\theta) = \overline{m_\theta(X)} \rightarrow E m_\theta(X) = M(\theta);$$

todėl  $P\{(X_1, \dots, X_n) \in B_n^j\} \rightarrow 0$  su  $i = 1, 2, 3$ . Bet tada

$$\begin{aligned} &P\{(X_1, \dots, X_n) \notin B_n\} \\ &\leq P\{(X_1, \dots, X_n) \in B_n^1\} + P\{(X_1, \dots, X_n) \in B_n^2\} + P\{(X_1, \dots, X_n) \in B_n^3\} \\ &\rightarrow 0, \end{aligned}$$

t.y.  $P\{(X_1, \dots, X_n) \in B_n\} \rightarrow 1$ .

2. Kodėl teisingos (5.2) nelygybės?

Jei  $(x_1, \dots, x_n) \in B_n$ , tai

$$M_n(\theta_0) \geq M(\theta_0) - \varepsilon/2, \quad M_n(\theta_0 - \delta) < M(\theta_0 - \delta) + \varepsilon/2;$$

todėl

$$M_n(\theta_0) - M_n(\theta_0 - \delta) > M(\theta_0) - \varepsilon/2 - M(\theta_0 - \delta) - \varepsilon/2 = M(\theta_0) - M(\theta_0 - \delta) - \varepsilon.$$

Dešinė pusė neneigiama pagal  $\varepsilon$  apibrėžimą. Taigi  $M_n(\theta_0) > M_n(\theta_0 - \delta)$ . Antra nelygybė įrodoma panašiai.

**3.** Kodėl  $M_n(\theta)$  tolydi?

Nes

$$M_n(\theta) = \frac{m_\theta(x_1) + \dots + m_\theta(x_n)}{n}$$

ir visos  $m_\theta(x_i)$  funkcijos tolydžios  $\theta$  atžvilgiu.

**4.** Paaškindite smulkiau, kodėl  $\hat{\theta}_n$  yra lokalaus maksimumo taškas.

Kadangi  $M_n(\theta_0 - \delta) < M_n(\theta_0)$ ,  $\hat{\theta}_n \neq \theta_0 - \delta$ . Dėl panašios priežasties  $\hat{\theta}_n \neq \theta_0 + \delta$ . Taigi  $\hat{\theta}_n \in (\theta_0 - \delta; \theta_0 + \delta)$ . Tada  $(\theta_0 - \delta; \theta_0 + \delta)$  yra  $\hat{\theta}_n$  aplinka ir su visais  $\theta$  iš tos aplinkos  $M_n(\theta) \leq M_n(\theta_0)$ . Tai ir reiškia, kad  $\hat{\theta}_n$  yra lokalaus maksimumo taškas.

**5.** Kodėl teisingi sąryšiai (5.3) grandinėje?

Iš  $\delta_n \rightarrow 0$  išplaukia, kad  $\delta_n < \delta$ , kai  $n$  pakankamai didelis. Tada

$$|\hat{\theta}_n - \theta_0| \geq \delta \Rightarrow |\hat{\theta}_n - \theta_0| \geq \delta_n;$$

todėl  $P\{|\hat{\theta}_n - \theta_0| \geq \delta\} \leq P\{|\hat{\theta}_n - \theta_0| \geq \delta_n\}$ .

Jei  $(x_1, \dots, x_n) \in A_n$ , tai pagal apibrėžimą  $\hat{\theta}_n \in (\theta_0 - \delta_n; \theta_0 + \delta_n)$ , t.y.  $|\hat{\theta}_n - \theta_0| < \delta$ . Reiškia,

$$|\hat{\theta}_n - \theta_0| \geq \delta \Rightarrow (X_1, \dots, X_n) \notin A_n;$$

todėl  $P\{|\hat{\theta}_n - \theta_0| \geq \delta_n\} \leq P\{(X_1, \dots, X_n) \notin A_n\}$ .

Trečias sąryšis išplaukia iš

$$P\{(X_1, \dots, X_n) \notin A_n\} = 1 - P\{(X_1, \dots, X_n) \in A_n\}$$

ir  $P\{(X_1, \dots, X_n) \in A_n\} \rightarrow 1$ .

### 5.1 lema.

**6.** Kodėl egzistuoja tokie  $n_k$ ?

Nes  $h_n(1/k) \xrightarrow{n \rightarrow \infty} 1$ .

**7.** Kodėl  $\delta_n \rightarrow 0$ ?

Nes  $0 < \delta_n \leq 1/k$ , kai  $n \geq n_k$ .

**8.** Kodėl teisingi sąryšiai (5.4) grandinėje?

Pirma lygybė — todėl, kad  $\delta_n = 1/l$ , kai  $n_l \leq n < n_{l+1}$ . Antra nelygybė — todėl, kad  $|h_n(1/l) - 1| < 1/l$ , kai  $n \geq n_l$ . Trečia nelygybė — todėl, kad  $l \geq k$ .

### 5.2 teorema.

**9.** Įrodykite, kad  $\ln x \leq 2(\sqrt{x} - 1)$ , kai  $x > 0$ .

Pažymiu  $f(x) = \ln x - 2(\sqrt{x} - 1)$ . Tada

$$f'(x) = \frac{1}{x} - \frac{2}{2\sqrt{x}} = \frac{1}{x} - \frac{1}{\sqrt{x}}.$$

Išvestinė lygi 0 tik viename taške —  $x = 1$ . Kai  $x < 1$ , išvestinė teigiama; kai  $x > 1$ , išvestinė neigiama. Reiškia, kritiniame taške yra funkcijos maksimumas. Todėl

$$f(x) \leq f(1) = 0$$



su visais  $x$ .

**10.** Kodėl teisingi sąryšiai (5.5) grandinėje?

Pirma lygybė išplaukia iš

$$\begin{aligned} M(\theta) - M(\theta_0) &= E \ln p_\theta(X) - E \ln p_{\theta_0}(X) \\ &= E[\ln p_\theta(X) - \ln p_{\theta_0}(X)] = E \ln \frac{p_\theta(X)}{p_{\theta_0}(X)}. \end{aligned}$$

Antras sąryšis — iš nelygybės  $\ln x \leq 2(\sqrt{x} - 1)$ .

Kadangi  $p_{\theta_0}$  yra  $X$  tankis  $\mu$  mato atžvilgiu,  $E f(X) = \int f p_{\theta_0} d\mu$  su bet kokia funkcija  $f$ . Reiškia,

$$\begin{aligned} E\left(\sqrt{\frac{p_\theta(X)}{p_{\theta_0}(X)}} - 1\right) &= E\sqrt{\frac{p_\theta(X)}{p_{\theta_0}(X)}} - 1 \\ &= \int \sqrt{\frac{p_\theta}{p_{\theta_0}}} p_{\theta_0} d\mu - 1 = \int \sqrt{p_\theta p_{\theta_0}} d\mu - 1. \end{aligned}$$

Ketvirta lygybė teisinga, nes

$$\begin{aligned} \int (\sqrt{p_\theta} - \sqrt{p_{\theta_0}})^2 d\mu &= \int [p_\theta - 2\sqrt{p_\theta p_{\theta_0}} + p_{\theta_0}] d\mu \\ &= \int p_\theta d\mu - 2 \int \sqrt{p_\theta p_{\theta_0}} d\mu + \int p_{\theta_0} d\mu = 1 - 2 \int \sqrt{p_\theta p_{\theta_0}} d\mu + 1. \end{aligned}$$

Paskutinė nelygybė išplaukia iš to, kad neneigiamos funkcijos integralas neneigiamas.

### 5.2.4 Komentariai

**11.** Dažnai tvirtinama, kad 5.1 teorema įrodo  $M$ -įvertinių pagrįstumą. Deja, taip nėra. Jei  $M_n(\theta)$  funkcija turi keletą lokalių maksimumų, iš teoremos neišplaukia, kad bet kokia parametro reikšmių, kuriuose pasiekiamas lokalus maksimumas, seka artėja prie  $\theta_0$ . Taigi jei  $\hat{\theta}_n$  yra  $M_n(\theta)$  globalaus maksimumo taškas, visiškai neaišku, ar  $\hat{\theta}_n \rightarrow \theta_0$ .

**12.** Teoremoje sukonstruotų dydžių  $\hat{\theta}_n$  netgi negalima vadinti statistikomis. Pagal konstrukciją  $\hat{\theta}_n$  yra lokalaus maksimumo taškas iš  $(\theta_0 - \delta_n; \theta_0 + \delta_n)$  intervalo; taigi norėdami pasirinkti  $\hat{\theta}_n$  mes turime žinoti  $\theta_0$ .

## 5.3 Valdo teorema

### 5.3.1 Valdo teorema

**5.3 teorema.** Tarkime,  $\Theta$  yra kompaktiška metrinė erdvė, su kiekvienu  $x$  funkcija  $m_\theta(x)$  tolydi  $\theta$  atžvilgiu ir su kiekvienu  $\theta \in \Theta$  egzistuoja toks  $r > 0$ , kad

$$E\left[\sup_{\theta' \in U(\theta, r)} m_{\theta'}(X)\right]^+ < \infty. \quad (5.6)$$

Jei  $\theta_0$  yra vienintelis funkcijos  $M(\theta)$  maksimumo taškas, o  $\hat{\theta}_n$  — funkcijos  $M_n(\theta)$  globalaus maksimumo taškas, tai  $\hat{\theta}_n \rightarrow \theta_0$ .

*Irodymas.* Kad būtų trumpiau, su bet kokia  $A \subset \Theta$  pažymiu

$$m_A(x) = \sup_{\theta \in A} m_\theta(x).$$

Iš  $\theta \in U(\theta, r)$  išplaukia

$$\begin{aligned} m_\theta(x) &\leq m_{U(\theta, r)}(x); \\ [m_\theta(x)]^+ &\leq [m_{U(\theta, r)}(x)]^+; \\ E[m_\theta(X)]^+ &\leq E[m_{U(\theta, r)}(X)]^+ < \infty. \end{aligned}$$

Taigi vidurkiai  $E m_\theta(X)$  ir  $E m_{U(\theta, r)}(X)$  apibrėžti, nors, gal būt, lygūs  $-\infty$ .

Kadangi  $m_{U(\theta, r/n)} \downarrow m_\theta(x)$ , iš (5.6) išplaukia, kad su kiekvienu  $\theta$

$$E m_{U(\theta, r/n)}(X) \downarrow M(\theta). \quad (5.7)$$

Pažymiu  $B = \{\theta \in \Theta \mid d(\theta, \theta_0) \geq \varepsilon\}$ . Tada su kiekvienu  $\theta \in B$  egzistuoja toks  $r(\theta)$ , kad

$$E m_{U(\theta, r(\theta))}(X) < M(\theta_0).$$

$B$  aibė kompaktiška, o rutuliai  $U(\theta, r(\theta))$ ,  $\theta \in \Theta$ , ją dengia. Reiškia, egzistuoja tokie  $\theta_1, \dots, \theta_k \in \Theta$ , kad

$$B \subset U(\theta_1, r(\theta_1)) \cup \dots \cup U(\theta_k, r(\theta_k)).$$

Kad būtų trumpiau, pažymiu  $U_j = U(\theta_j, r(\theta_j))$ . Tada  $B \subset U_1 \cup \dots \cup U_k$  ir  $E m_{U_j}(X) < M(\theta_0)$  su visais  $j = 1, \dots, k$ .

Jei  $E m_{U_j}(X) < q_j < M(\theta_0)$ , tai

$$P\{\overline{m_{U_j}(X)} \geq q_j\} \xrightarrow{n \rightarrow \infty} 0 \quad \text{ir} \quad P\{M_n(\theta_0) \leq q_j\} \xrightarrow{n \rightarrow \infty} 0; \quad (5.8)$$

todėl

$$P\{\overline{m_{U_j}(X)} < M_n(\theta_0)\} \xrightarrow{n \rightarrow \infty} 1. \quad (5.9)$$

Jei  $\hat{\theta}_n \in U_j$ , tai

$$M_n(\theta_0) \leq M_n(\hat{\theta}_n) \leq \overline{m_{U_j}(X)}; \quad (5.10)$$

todėl  $P\{\hat{\theta}_n \in U_j\} \rightarrow 0$ . Iš čia  $P\{\hat{\theta}_n \in B\} \rightarrow 0$ , t.y.  $\hat{\theta}_n \rightarrow \theta_0$ .  $\square$

### 5.3.2 Įrodymo paaiškinimai

**13.** Kodėl  $m_{U(\theta, r/n)} \downarrow m_\theta(x)$ ?

Jei  $n$  didėja, tai aibė  $U(\theta, r/n)$  mažėja, o kuo mažesnė aibė, tuo mažesnis jos supremumas. Todėl seka  $m_{U(\theta, r/n)}$  nedidėjanti.

Fiksuoju  $\varepsilon$ . Dėl  $m_\theta(x)$  funkcijos tolydumo atsiras toks  $\delta$ , kad su visais  $\theta' \in U(\theta, \delta)$

$$|m_{\theta'}(x) - m_\theta(x)| < \varepsilon.$$

Tada

$$m_{\theta'}(x) \leq m_\theta(x) + \varepsilon$$

su visais  $\theta' \in U(\theta, \delta)$ ; todėl

$$m_{U(\theta, \delta)}(x) \leq m_\theta(x) + \varepsilon.$$

Iš čia

$$m_\theta(x) \leq m_{U(\theta, r/n)}(x) \leq m_\theta(x) + \varepsilon,$$

kai  $n$  pakankamai didelis (kai  $1/n < \delta$ ). Reiškia,  $m_{U(\theta, r/n)}(x) \rightarrow m_\theta(x)$ .

**14.** Paaiškinkite smulkiau, kodėl teisingas (5.7) sąryšis.

Pažymiu  $Y_n = m_{U(\theta, r/n)}(X)$  ir  $Y = m_\theta(X)$ . Tada  $Y_n \downarrow Y$  ir  $EY_1^+ < \infty$ .

Funkcija  $y \mapsto y^+$  nemažėjanti ir tolydi; todėl  $Y_n^+ \downarrow Y^+$ . Be to,  $|Y_n^+| = Y_n^+ \leq Y_1^+$  ir  $EY_1^+ < \infty$ ; todėl iš Lebego teoremos apie aprėžtą konvergavimą  $EY_n^+ \rightarrow EY^+$ .

Funkcija  $y \mapsto y^-$  nedidėjanti ir tolydi; todėl  $Y_n^- \uparrow Y^-$ . Tada iš Lebego teoremos apie monotonišką konvergavimą išplaukia  $EY_n^- \rightarrow EY^-$ . Reiškia,

$$EY_n = EY_n^+ - EY_n^- \rightarrow EY^+ - EY^- = EY.$$

**15.** Kodėl egzistuoja toks  $r(\theta)$ ?

Jei  $\theta \in B$ , tai  $\theta \neq \theta_0$ ; todėl  $M(\theta) < M(\theta_0)$ . Tada

$$E m_{U(\theta, r/n)}(X) \rightarrow M(\theta) < M(\theta_0);$$

todėl  $E m_{U(\theta, r/n)}(X) < M(\theta_0)$ , kai  $n$  pakankamai didelis. Belieka pažymėti  $r(\theta) = r/n$ .

**16.** Kodėl  $B$  kompaktiška?

Funkcija  $\theta \mapsto d(\theta, \theta_0)$  tolydi, o  $B$  yra uždaro aibės  $[\varepsilon; \infty)$  pirmavaizdis tos funkcijos atžvilgiu. Todėl  $B$  uždara. KOMPaktiškoje erdvėje visi uždari poaibiai kompaktiški; todėl  $B$  kompaktiška.

**17.** Kodėl  $U(\theta, r(\theta))$  rutuliai dengia  $B$ ?

Kiekvienas  $\theta \in B$  yra rutulyje  $U(\theta, r(\theta))$ .

**18.** Kodėl teisingi (5.8) sąryšiai?

Todėl, kad iš didžiųjų skaičių dėsnio

$$\overline{m_{U_j}(X)} \rightarrow E m_{U_j}(X) < q_j \quad \text{ir} \quad M_n(\theta_0) \rightarrow M(\theta_0) > q_j.$$

**19.** Kaip iš (5.8) išplaukia (5.9)?

$$\begin{aligned} P\{\overline{m_{U_j}(X)} < M_n(\theta_0)\} &\geq P\{\overline{m_{U_j}(X)} < q_j < M_n(\theta_0)\} \\ &= 1 - P\{\overline{m_{U_j}(X)} \geq q_j \text{ arba } q_j \geq M_n(\theta_0)\} \\ &\geq 1 - P\{\overline{m_{U_j}(X)} \geq q_j\} - P\{q_j \geq M_n(\theta_0)\} \rightarrow 1. \end{aligned}$$

**20.** Kodėl teisingos nelygybės (5.10) grandinėje?

Pirma nelygybė — todėl, kad  $\hat{\theta}_n$  yra globalaus  $M_n(\theta)$  funkcijos maksimumo taškas. Antra nelygybė — todėl, kad iš  $\theta_n \in U_j$  išplaukia  $m_\theta(x) \leq m_{U_j}(x)$  su visais  $x$  ir, reiškia,

$$M_n(\theta) \leq \overline{m_{U_j}(X)}.$$

**21.** Kodėl  $P\{\hat{\theta}_n \in B\} \rightarrow 0$  ir kodėl iš to daroma išvada, kad  $\hat{\theta}_n \rightarrow \theta_0$ ?

Iš  $B \subset U_1 \cup \dots \cup U_k$  išplaukia

$$P\{\hat{\theta}_n \in B\} \leq \sum_{j=1}^k P\{\hat{\theta}_n \in U_j\} \rightarrow 0.$$

Iš  $B$  aibės apibrėžimo tada gaunu

$$P\{d(\hat{\theta}_n, \theta_0) \geq \varepsilon\} \rightarrow 0.$$

Tai teisinga su bet koku  $\varepsilon$ ; todėl  $\hat{\theta}_n \rightarrow \theta_0$ .

## 5.4 Kitos teoremos

### 5.4.1 Teoremos

**5.4 teorema.** Tarkime,  $\Theta$  yra intervalas, funkcija  $\psi_\theta(x)$  tolydi  $\theta$  atžvilgiu su visais  $x$ ,  $\hat{\theta}_n$  — vienintelis funkcijos  $\Psi_n(\theta)$  nulis ir  $\Psi(\theta_0 - \varepsilon) < 0 < \Psi(\theta_0 + \varepsilon)$  su visais  $\varepsilon$ . Tada  $\hat{\theta}_n \rightarrow \theta_0$ .

*Irodymas.* Fiksuojame  $\varepsilon$ . Iš paskutiniosios teoremos sąlygos išplaukia, kad

$$P\{\Psi_n(\theta_0 - \varepsilon) < 0 < \Psi_n(\theta_0 + \varepsilon)\} \rightarrow 1. \quad (5.11)$$

Bet jei  $\Psi_n(\theta_0 - \varepsilon) < 0 < \Psi_n(\theta_0 + \varepsilon)$ , tai  $(\theta_0 - \varepsilon; \theta_0 + \varepsilon)$  intervale yra  $\Psi_n(\theta)$  funkcijos nulis, t.y.  $\hat{\theta}_n$  taškas. Taigi

$$P\{|\hat{\theta}_n - \theta_0| < \varepsilon\} \rightarrow 1.$$

□

**5.5 teorema.** Tarkime,  $\Theta$  yra intervalas ir  $\psi_\theta(x)$  — nemažėjanti  $\theta$  atžvilgiu funkcija su visais  $x$ . Jei  $\Psi(\theta_0 - \varepsilon) < 0 < \Psi(\theta_0 + \varepsilon)$  su visais  $\varepsilon$ , o  $\Psi_n(\hat{\theta}_n) \rightarrow 0$ , tai  $\hat{\theta}_n \rightarrow \theta_0$ .

*Irodymas.* Fiksuojame  $\varepsilon$ . Tada

$$\begin{aligned} & P\{|\hat{\theta}_n - \theta_0| \geq \varepsilon\} \\ & \leq P\{\hat{\theta}_n \leq \theta_0 - \varepsilon\} + P\{\hat{\theta}_n \geq \theta_0 + \varepsilon\} \\ & \leq P\{\Psi_n(\hat{\theta}_n) \leq \Psi_n(\theta_0 - \varepsilon)\} + P\{\Psi_n(\hat{\theta}_n) \geq \Psi_n(\theta_0 + \varepsilon)\} \\ & \rightarrow 0. \end{aligned} \quad (5.12)$$

□

**5.6 teorema.** Jei

$$\sup_{\theta \in \Theta} |M_n(\theta) - M(\theta)| \rightarrow 0,$$

su visais  $\varepsilon$

$$\sup_{d(\theta, \theta_0) \geq \varepsilon} M(\theta) < M(\theta_0)$$

ir  $\hat{\theta}_n$  yra  $M_n(\theta)$  funkcijos maksimumo taškas, tai  $\hat{\theta}_n \rightarrow \theta_0$ .

*Irodymas.* Fiksuoju  $\varepsilon$  ir pažymiu

$$\delta = M(\theta_0) - \sup_{d(\theta, \theta_0) \geq \varepsilon} M(\theta).$$

Jei  $d(\hat{\theta}_n, \theta_0) \geq \varepsilon$ , tai  $M(\hat{\theta}_n) < M(\theta_0) - \delta$ . Todėl

$$\begin{aligned} & P\{d(\hat{\theta}_n, \theta_0) \geq \varepsilon\} \\ & \leq P\{M(\hat{\theta}_n) < M(\theta_0) - \delta\} \\ & \leq P\{M_n(\hat{\theta}_n) < M(\theta_0) - \delta/2\} + P\{|M_n(\hat{\theta}_n) - M(\hat{\theta}_n)| > \delta/2\} \\ & \leq P\{M_n(\theta_0) < M(\theta_0) - \delta/2\} + P\{\sup_{\theta} |M_n(\theta) - M(\theta)| \geq \delta/2\} \\ & \rightarrow 0. \end{aligned} \quad (5.13)$$

□

### 5.4.2 Įrodymų paaiškinimai

#### 5.4 teorema.

**22.** Paaiškinkite smulkiau, kaip gaunamas (5.11) sąryšis.

Jei  $Z_n \rightarrow a < b$ , tai  $P\{Z_n \geq b\} \leq P\{|Z_n - a| \geq b - a\} \rightarrow 0$ . Analogiškai įrodoma, kad jei  $Z_n \rightarrow a > b$ , tai  $P\{Z_n \leq b\} \rightarrow 0$ . Taigi

$$P\{\Psi_n(\theta_0 - \varepsilon) \geq 0\} \rightarrow 0 \quad \text{ir} \quad P\{\Psi_n(\theta_0 + \varepsilon) \leq 0\} \rightarrow 0,$$

nes  $\Psi_n(\theta_0 \pm \varepsilon) \rightarrow \Psi(\theta_0 \pm \varepsilon)$  ir

$$\Psi(\theta_0 - \varepsilon) < 0 < \Psi(\theta_0 + \varepsilon).$$

Bet tada

$$\begin{aligned} & P\{\Psi_n(\theta_0 - \varepsilon) \geq 0 \text{ arba } \Psi_n(\theta_0 + \varepsilon) \leq 0\} \\ & \leq P\{\Psi_n(\theta_0 - \varepsilon) \geq 0\} + P\{\Psi_n(\theta_0 + \varepsilon) \leq 0\} \rightarrow 0, \end{aligned}$$

t.y.  $P\{\Psi_n(\theta_0 - \varepsilon) < 0 < \Psi_n(\theta_0 + \varepsilon)\} \rightarrow 1$ .

**23.** Paaiškinkite smulkiau, kodėl  $\hat{\theta}_n \in (\theta_0 - \varepsilon; \theta_0 + \varepsilon)$ .

Jei  $\psi_{\theta}(x)$  tolydi  $\theta$  atžvilgiu su visais  $x$ , tai ir

$$\Psi_n(\theta) = \frac{\psi_{\theta}(X_1) + \cdots + \psi_{\theta}(X_n)}{n}$$

funkcija tolydi. Jei  $\theta_0 - \varepsilon$  taške jos reikšmė neigiama, o  $\theta_0 + \varepsilon$  taške — teigiama, tai kažkokiam taške  $\theta^* \in (\theta_0 - \varepsilon; \theta_0 + \varepsilon)$  jos reikšmė yra 0. Bet  $\hat{\theta}_n$  yra vienintelis taškas, kuriame funkcija lygi 0. Reiškia,  $\hat{\theta}_n = \theta^* \in (\theta_0 - \varepsilon; \theta_0 + \varepsilon)$ .

#### 5.5 teorema.

**24.** Kodėl teisingi sąryšiai (5.12) grandinėje?

Pirma nelygybė: jei  $|\hat{\theta}_n - \theta_0| \geq \varepsilon$ , tai arba  $\hat{\theta}_n \leq \theta_0 - \varepsilon$ , arba  $\hat{\theta}_n \geq \theta_0 + \varepsilon$ . Be to,  $P(A \cup B) \leq P(A) + P(B)$ .

Antra nelygybė: kadangi  $\Psi_n(\theta)$  nemažėjanti  $\theta$  atžvilgiu (nes  $\psi_\theta(x)$  nemažėjanti su visais  $x$ ), iš  $\hat{\theta}_n \leq \theta_0 - \varepsilon$  išplaukia  $\Psi_n(\hat{\theta}_n) \leq \Psi_n(\theta_0 - \varepsilon)$ , o iš  $\hat{\theta}_n \geq \theta_0 + \varepsilon$  —  $\Psi_n(\hat{\theta}_n) \geq \Psi_n(\theta_0 + \varepsilon)$ . Be to, jei  $A \Rightarrow B$ , tai  $P(A) \leq P(B)$ .

Trečias sąryšis: iš

$$\Psi_n(\hat{\theta}_n) - \Psi_n(\theta_0 - \varepsilon) \rightarrow -\Psi(\theta_0 - \varepsilon) > 0$$

išplaukia  $P\{\Psi_n(\hat{\theta}_n) - \Psi_n(\theta_0 - \varepsilon) \leq 0\} \rightarrow 0$ , o iš

$$\Psi_n(\hat{\theta}_n) - \Psi_n(\theta_0 + \varepsilon) \rightarrow -\Psi(\theta_0 + \varepsilon) < 0$$

gaunu  $P\{\Psi_n(\hat{\theta}_n) - \Psi_n(\theta_0 + \varepsilon) \geq 0\} \rightarrow 0$ .

### 5.6 teorema.

**25.** Kodėl teisingi sąryšiai (5.13) grandinėje?

Pirma nelygybė: paaiškinta įrodyme.

Antra nelygybė: iš  $M(\hat{\theta}_n) < M(\theta_0) - \delta$  išplaukia

$$M_n(\hat{\theta}_n) < M(\theta_0) - \delta/2 \text{ arba } |M_n(\hat{\theta}_n) - M(\hat{\theta}_n)| > \delta/2,$$

nes jei ir  $M_n(\hat{\theta}_n) \geq M(\theta_0) - \delta/2$ , ir  $|M_n(\hat{\theta}_n) - M(\hat{\theta}_n)| \leq \delta/2$ , tai

$$M(\hat{\theta}_n) = M_n(\hat{\theta}_n) - [M_n(\hat{\theta}_n) - M(\hat{\theta}_n)] \geq M(\theta_0) - \delta/2 - \delta/2 = M(\theta_0) - \delta.$$

Trečia nelygybė:  $M_n(\hat{\theta}_n) \geq M_n(\theta_0)$ , nes  $\hat{\theta}_n$  yra  $M_n(\theta)$  funkcijos maksimumo taškas. Todėl

$$M_n(\hat{\theta}_n) < M(\theta_0) - \delta/2 \Rightarrow M_n(\theta_0) < M(\theta_0) - \delta/2$$

ir

$$P\{M_n(\hat{\theta}_n) < M(\theta_0) - \delta/2\} \leq P\{M_n(\theta_0) < M(\theta_0) - \delta/2\}.$$

Be to, akivaizdu, kad

$$|M_n(\hat{\theta}_n) - M(\hat{\theta}_n)| > \delta/2 \Rightarrow \sup_{\theta} |M_n(\theta) - M(\theta)| > \delta/2;$$

todėl

$$P\{|M_n(\hat{\theta}_n) - M(\hat{\theta}_n)| > \delta/2\} \leq P\{\sup_{\theta} |M_n(\theta) - M(\theta)| > \delta/2\}.$$

Ketvirtas sąryšis: pirmas dėmuo artėja į 0, nes

$$M_n(\theta_0) \rightarrow M(\theta_0) > M(\theta_0 - \delta/2);$$

antras dėmuo — dėl to, kad  $\sup_{\theta} |M_n(\theta) - M(\theta)| \rightarrow 0$ .