

## IV skyrius. MATEMATINĖS STATISTIKOS PRADMENYS

### 1. MATEMATINĖS STATISTIKOS UŽDAVINIAI

Matematinė statistika nagrinėja stebėjimo rezultatų matematinio aprašymo ir analizavimo būdus. Tipiškas matematinės statistikos uždavinys gali būti nusakytas šitaip. Sakykime, turime aibę objektų, kuriuos tiriamo pagal kuriuos nors požymius, o pačius požymius galime charakterizuoti skaičiais. Tų skaičių arba vektorių (jei tiriamo keletą požymių) aibę įprasta vadinti *generaline aibe*. Paprastai tiriamojo požymio pasiskirstymas generalinėje aibėje nėra žinomas. Norint jį nustatyti, reikėtų ištirti visus generalinės aibės objektus. Tai gali pareikalauti daug darbo ir lėšų, o kartais toks tyrimas iš principo nėra galimas. Tarkime, kad automatinės staklės gamina kokias nors pigias detales. Mums rūpi tų detalių svorio pasiskirstymas visoje vienos dienos produkcijoje. Tektų sverti kiekvieną detalę. Šis darbas kainuotų daugiau negu pati detalių partija. Kitas pavyzdys. Fabrikas gamina elektros lemputes. Reikia sužinoti, kiek laiko vidutiniškai jos dega. Norint patikrinti visų per dieną pagamintų lempučių degimo trukmę, reikėtų jas žibinti tol, kol perdegs. Taip sugadintume visą produkciją. Todėl elgiamasi kitaip: atsitiktinai parenkama generalinės aibės objektų dalis, ištiriamas reikiamo požymio pasiskirstymas tame poaibyje ir iš jo sprendžiama apie to požymio pasiskirstymą visoje generalinėje aibėje. Parinktoji generalinės aibės dalis vadinama *imtimi*. Taikant matematinės statistikos metodus, galima įvertinti tiriamojo požymio pasiskirstymą generalinėje aibėje, kai žinomas to požymio pasiskirstymas imtyje.

Matematinės statistikos metodai tinka tik tada, kai imtis yra *reprezentatyvi*, t. y. kai ji teisingai atspindi tiriamojo požymio galimų reikšmių proporcijas generalinėje aibėje.

Imtį galima sudaryti įvairiai. Galima atsitiktinai imti kurį nors generalinės aibės objektą, po to grąžinti jį į generalinę aibę ir toliau vėl atsitiktinai imti bet kurį tos aibės objektą. Tačiau galima kiekvieno parinkto objekto į generalinę aibę nebegrąžinti. Parinkimai gali būti nepriklausomi, bet gali būti ir priklausomi.

Matematinėje statistikoje stengiamasi imtis aprašyti atsitiktinių dydžių terminais. Paprasčiausiu atveju tinka šitokia schema. Tiriamo atsitiktinį dydį su nežinoma pasiskirstymo funkcija. Stebime tą dydį  $n$  kartų. Gauname  $n$  stebėjimo rezultatų – imtį. Iš jos reikia spręsti apie nežinomą pasiskirstymo funkciją. Toliau visur stebėjimus laikysime nepriklausomais. Sudarysime vienamačio atsitiktinio dydžio  $n$  nepriklausomų stebėjimų matematinį modelį.

Kaip žinome, atsitiktinis dydis yra mati funkcija, atvaizduojanti pirmąją tikimybinę erdvę mačioje erdvėje  $\{R, \mathcal{B}\}$ . Tačiau tiriant to dydžio reikšmių pasiskirstymą, nebūtina žinoti pirmąją tikimybinę erdvę – galima operuoti erdve  $\{R, \mathcal{B}\}$  ir atsitiktinio dydžio indukuotu tikimybinio pasiskirstymu toje erdvėje (žr. II.2 skyrelį).

Sakykime, stebime atsitiktinį dydį, indukuojantį tikimybinę erdvę  $\{R, \mathcal{B}, P_\theta\}$ . Apie to dydžio tikimybinį pasiskirstymą  $P_\theta$  žinome tik tiek, kad jis priklauso pasiskirstymų klasei  $\{P_\theta, \theta \in \Theta\}$ ; čia  $\Theta$  gali būti realiųjų skaičių, arba erdvės  $R^s$ ,  $s > 1$ , taškų, arba ir dar sudėtingesnė aibė. Sakykime, žinome, kad stebimasis atsitiktinis dydis yra pasiskirstęs pagal Puasono dėsnį su nežinomu parametru  $\lambda$ ; tada aibe  $\Theta$  galime laikyti visų realiųjų teigiamų skaičių aibę  $(0, \infty)$ . Jei atsitiktinis dydis pasiskirstęs pagal normalųjį dėsnį  $N(a, \sigma^2)$  su nežinomu vidurkiu  $a$  ir nežinoma dispersija  $\sigma^2$ , tai aibė  $\Theta$  gali būti erdvės  $R^2$  aibė  $R \times (0, \infty)$ . Tačiau apie atsitiktinį dydį galime turėti ir mažiau informacijos. Sakysime, galime žinoti, tik kad jis yra diskretusis arba tolydusis. Tada  $\Theta$  teks laikyti daug sudėtingesne aibe.

Atsitiktinio dydžio  $n$  stebėjimų bus  $n$ -matis atsitiktinis vektorius  $X = (X_1, \dots, X_n)$ . Kadangi stebėjimai yra nepriklausomi, tai  $X_1, \dots, X_n$  bus nepriklausomi atsitiktiniai dydžiai.  $X$  pasiskirstymą nusakys jo indukuota tikimybinė erdvė

$$\{R^n, \mathcal{B}^n, P_\theta\} = \{R^n, \mathcal{B}^n, P_\theta^n\} = \{R, \mathcal{B}, P_\theta\}^n$$

(žr. V.10 skyrelį). Atsitiktinis dydis  $X_k$  atitinka  $k$ -ąjį stebėjimą, o vektorius  $X = (X_1, \dots, X_n)$  yra *atsitiktinė*, arba *matematinė*, *imtis*. Konkreti to vektoriaus reikšmė  $x = (x_1, \dots, x_n)$  yra konkreti imtis arba atsitiktinės imties  $X = (X_1, \dots, X_n)$  *realizacija*. Erdvė  $\{R, \mathcal{B}, P_\theta\}^n$  paprastai vadinama *imčių erdve*.

Kartais stebėjimų skaičius  $n$  yra labai didelis. Tada tikslinga kalbėti apie begalinę nepriklausomų stebėjimų seką. Jos matematinis modelis yra erdvė  $\{R, \mathcal{B}, P_\theta\}^\infty$ . Kiekvienam  $n$  erdvę  $\{R, \mathcal{B}, P_\theta\}^n$  galima traktuoti kaip begalinės erdvių sandaugos poerdvį.

Didžioji dalis klausimų, kuriuos tenka spręsti matematinėje statistikoje, yra dviejų tipų.

1. *Įvertinimų teorija*. Jos tikslas – nurodyti metodus, kuriais galima būtų įvertinti stebimojo atsitiktinio dydžio pasiskirstymo funkciją arba kitas pasiskirstymo charakteristikas: vidurkį, dispersiją ir pan. Dažnai, remiantis kokiais nors teoriniais samprotavimais ar praktine patirtimi, galima teigti, kad pasiskirstymo funkcija yra žinomo analizinio pavidalo, bet priklauso nuo vieno arba kelių nežinomų parametrų  $\theta$ . Reikia tuos parametrus įvertinti.

Panagrinėsime pavyzdį. Metame monetą. Realios monetos nėra simetriškos. Iš stebėjimo rezultatų reikia įvertinti herbo atsivertimo tikimybę  $p$ . Su monetos metimu galime susieti atsitiktinį dydį, įgyjantį reikšmę 1, kai atsiverčia herbas, ir 0, kai atsiverčia kita monetos pusė. To dydžio pasiskirstymo

funkcija

$$(1 - p)\varepsilon(y) + p\varepsilon(y - 1)$$

priklauso nuo nežinomo parametro  $p$ ; čia  $\varepsilon(y)$  yra III.7.2 teoremos įrodyme nusakyma vienietinė pasiskirstymo funkcija.

Suprantama, iš stebėjimo rezultatų negalime tiksliai nusakyti nežinomu pasiskirstymo charakteristikų, galime tik apytiksliai jas įvertinti.

2. **H i p o t e z i ų t i k r i n i m a s.** Bet kokią prielaidą apie stebimojo atsitiktinio dydžio pasiskirstymo dėsnį vadiname *statistine hipoteze*. Reikia patikrinti, ar stebėjimo duomenys neprieštarauja tai prielaidai. Matematiškai tą uždavinį galime formuluoti šitaip. Tarkime, kad stebimojo atsitiktinio dydžio pasiskirstymas  $P_\theta$  priklauso klasei  $\{P_\theta, \theta \in \Theta\}$ . Statistine hipoteze vadinsime prielaidą, kad  $\theta \in \Theta_0$ ; čia  $\Theta_0$  yra aibės  $\Theta$  tikrinis poaibis. Rašoma  $H : \theta \in \Theta_0$ . Hipotezė vadinama *paprastąja*, kai  $\Theta_0$  yra sudaryta tik iš vieno elemento, ir *sudėtingąja*, kai aibėje  $\Theta_0$  yra daugiau elementų. Tikrinamoji hipotezė, kad  $\theta \in \Theta_0$ , dar vadinama *nuline hipoteze*  $H_0$ , o hipotezė  $H_1 : \theta \in \Theta \setminus \Theta_0$  vadinama *alternatyviaja hipoteze*, arba tiesiog *alternatyva*.

Grįžkime prie jau minėto pavyzdžio apie monetą. Hipotezė  $p = 1/2$  (moneta simetriška) yra paprastoji; jos alternatyva yra  $p \neq 1/2$ . Hipotezė  $p > 1/2$  yra sudėtingoji.

Čia paminėjome tik porą pagrindinių matematinės statistikos uždavinių – su kitais susipažinsime kituose skyreliuose. Tačiau ir ten pateiksime tik mažą dalį uždavinių, kuriuos nagrinėja matematinė statistika. Šis skyrius yra tik trumpas įvadas į matematinės statistikos idėjas ir metodus.

## 2. ATSITIKTINIO DYDŽIO EMPIRINĖS CHARAKTERISTIKOS

Statistinėms išvadoms daryti iš stebėjimo rezultatų naudojamos įvairios imties funkcijos, iš tradicijos vadinamos statistikomis. Su jomis tenka atlikinėti algebrines bei analizines operacijas. Todėl natūralu reikalauti, kad tos funkcijos būtų mačios. Apibrėšime jas tiksliai.

Tarkime, kad, be erdvės  $\{R, \mathcal{B}, P_\theta\}^n$ , tiriamo dar ir mačią erdvę  $\{\Gamma, \mathcal{E}\}$ , ir funkcija  $T : R^n \rightarrow \Gamma$  yra  $(\mathcal{B}^n, \mathcal{E})$  mati, t. y.  $T^{-1}(A) \in \mathcal{B}^n$  kiekvienai  $A \in \mathcal{E}$ . Tada imties funkcija  $T(X) = T(X_1, \dots, X_n)$  yra vadinama *statistika*. Paprastai erdvė  $\{\Gamma, \mathcal{E}\}$  yra  $\{R^s, \mathcal{B}^s\}$ , atskiru atveju  $\{R, \mathcal{B}\}$ . Todėl statistika  $T(X)$  yra daugiamatis, arba atskiru atveju vienamatis, atsitiktinis dydis. Kai  $x = (x_1, \dots, x_n)$  yra konkreti imtis,  $T(x) = T(x_1, \dots, x_n)$  yra konkreti statistikos reikšmė, jos *realizacija*.

Viena iš pagrindinių statistikų yra vadinamoji *empirinė pasiskirstymo funkcija*  $\mathcal{F}_n(y)$ . Ji apibrėžiama šitaip:

$$\mathcal{F}_n(y) = \frac{1}{n} \sum_{X_k < y} 1,$$

kitaip tariant, tai yra mažesnių už  $y$  imties elementų  $X_k$  skaičius, padalytas iš  $n$ . Tą funkciją galime ir kitaip apibrėžti. Surašykime imties elementus didėjančia tvarka. Gausime vadinamąją *variacinę seką*

$$X_1^* \leq X_2^* \leq \dots \leq X_n^*.$$

Tarkime, kad  $Y_1 < Y_2 < \dots < Y_r$  yra skirtingi imties elementai, pasikartojantys atitinkamai  $N_1, N_2, \dots, N_r$  kartų. Tada empirinę pasiskirstymo funkciją galime užrašyti pavidalu

$$\mathcal{F}_n(y) = \sum_{Y_k < y} \frac{N_k}{n}.$$

Atkreipsime dėmesį, kad šioje formulėje  $N_k$  ir  $r$  yra atsitiktiniai dydžiai.

Pasiskirstymo funkcija kiekvienam  $y \in R$ , aišku, yra atsitiktinis dydis. Jei  $(x_1, \dots, x_n)$  yra konkreti imtis, tai  $\mathcal{F}_n(y)$  realizacija bus pasiskirstymo funkcija

$$F_n(y) = \frac{1}{n} \sum_{x_k < y} 1 = \sum_{y_m < y} \frac{n_m}{n};$$

čia  $y_1, \dots, y_s$  – skirtingi variacinės sekos realizacijos elementai, pasikartojantys atitinkamai  $n_1, \dots, n_r$  kartų.

Apibrėšime *empirinius momentus*. Analogiškai II.9 skyreliui (pradiniu) *empiriniu l-uoju momentu* vadinsime

$$A_l = \int_{-\infty}^{\infty} y^l d\mathcal{F}_n(y) = \frac{1}{n} \sum_{k=1}^n X_k^l \quad (l = 1, 2, \dots).$$

Visi jie, aišku, egzistuoja. Pirmasis empirinis momentas, arba *empirinis vidurkis*, paprastai žymimas  $\bar{X}$ :

$$\bar{X} = \frac{X_1 + \dots + X_n}{n}.$$

*l-uoju empiriniu centriniu momentu* vadinsime

$$M_l = \int_{-\infty}^{\infty} (y - \bar{X})^l d\mathcal{F}_n(y) = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^l \quad (l = 1, 2, \dots).$$

Antrąjį empirinį centrinį momentą, arba *empirinę dispersiją*, žymėsime

$$S^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^2.$$

Iš dispersijos savybių (žr. II.9 skyrelį) išplaukia

$$S^2 = \frac{1}{n} \sum_{k=1}^n X_k^2 - \bar{X}^2.$$

Dydis

$$S = \left( \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^2 \right)^{1/2}$$

vadinamas *empiriniu vidutiniu kvadratinu*, arba *empiriniu standartiniu, nuokrypiu*. Visi tie dydžiai yra atsitiktiniai. Konkrečioms imtims  $(x_1, \dots, x_n)$  gauname tų dydžių realizacijas

$$a_l = \frac{1}{n} \sum_{k=1}^n x_k^l \quad (l = 1, 2, \dots),$$

$$\bar{x} = \frac{x_1 + \dots + x_n}{n},$$

$$m_l = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^l \quad (l = 1, 2, \dots),$$

$$s^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2,$$

$$s = \left( \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \right)^{1/2}.$$

Tarkime, kad  $0 < p < 1$ . *Empiriniu p-quantiliu* laikome atsitiktinį dydį

$$\hat{X}_p = X_{[np]+1}^*;$$

čia  $[np]$  yra skaičiaus  $np$  sveikoji dalis, o  $X_{[np]+1}^*$  – variacinės sekos narys su numeriu  $[np] + 1$ . Kai  $p = 1/2$ , turime *empirinę medianą*; kai  $p = 1/4, 3/4$ , turime *apatinį* ir *viršutinį empirinius kvartilius*. Kartais dar vartojami empiriniai deciliai, procentiliai ir pan.

Paminėsime dar vieną empirinę charakteristiką – *imties plotį*

$$\max_{1 \leq k \leq n} X_k - \min_{1 \leq k \leq n} X_k = X_n^* - X_1^*.$$

Vartojamos ir kitokios empirinės charakteristikos.

### 3. STEBĖJIMO DUOMENŲ GRUPAVIMAS

Stebėjimo duomenys retai būna "gražūs" skaičiai. Tokie jie būna tik vidurinių mokyklų matematikos uždavinynuose, o praktiniuose uždaviniuose – paprastai labai "negražūs". Todėl, kai stebėjimo duomenų daug, juos apdoroti gana sunku. Skaičiavimams palengvinti stebėjimo duomenys paprastai apvalinami ir grupuojami.

Intervalas, kuriame telpa stebėjimo duomenys  $x_1, \dots, x_n$ , paprastai skaidomas į intervalus  $[\tau_l - h/2, \tau_l + h/2)$ ; čia  $\tau_l = \tau_0 + hl$  ( $l = 0, \pm 1, \dots$ ),  $h$  – atitinkamai parinktas skaičius. Duomenys, patekę į intervalą  $[\tau_l - h/2, \tau_l + h/2)$ , pakeičiami skaičiais  $\tau_l$ . Taip elgiantis, galima gerokai suprastinti skaičiavimus, jei tik skaičiai  $\tau_0$  ir  $h$  tinkamai parinkti. Skaičius  $\tau_l$  reikia parinkti kuo "gražesnius". Kuo skaičius  $h$  bus didesnis, tuo paprastesni skaičiavimai, bet tuo didesnė bus padaryta paklaida. Ir atvirkščiai, kuo mažesnis  $h$ , tuo skaičiavimai sudėtingesni, bet paklaida mažesnė.

Panagrinėsimė, kaip apskaičiuojami empiriniai momentai, naudojantis sugrupuotais duomenimis. Pradinius momentus, gautus iš sugrupuotų duomenų, žymėsime  $a'_j$ , centrinius momentus –  $m'_j$ . Tarkime, kad intervale  $[\tau_l - h/2, \tau_l + h/2)$  yra  $n_l$  stebėjimo duomenų. Tada

$$a'_j = \frac{1}{n} \sum_l n_l \tau_l^j;$$

sumuojame pagal visus intervalus, kuriuose yra stebėjimo duomenų. Analogiškai

$$m'_j = \frac{1}{n} \sum_l n_l (\tau_l - a'_1)^j.$$

Tos formulės rodo, kad skaičiavimai su sugrupuotais duomenimis yra paprastesni. Tačiau, kaip minėjome, padarome paklaidas. Šepardas<sup>1</sup> pasiūlė apytiksles formules

$$m'_j \approx \frac{1}{j+1} \sum_{r=0}^{[j/2]} \binom{j+1}{2r+1} \left(\frac{h}{2}\right)^{2r} m_{j-2r},$$

kuriomis naudojantis, dažniausiai pasitaikančiais atvejais gaunamos mažesnės paklaidos. Iš čia, pasinaudoję ryšiu tarp centrinių ir pradinių momentų, galime gauti ir apytiksles formules pradiniam momentams. Tų formulių pagrindimą galima rasti [6] knygoje. Iš jų gauname

<sup>1</sup> W. F. Sheppard – anglų statistikas.

$$\begin{aligned}
 a_1 &\approx a'_1, \\
 a_2 &\approx a'_2 - \frac{1}{12}h^2, \\
 a_3 &\approx a'_3 - \frac{1}{4}a'_1h^2, \\
 a_4 &\approx a'_4 - \frac{1}{2}a'_2h^2 + \frac{7}{240}h^4, \\
 &\dots\dots\dots \\
 m_2 &\approx m'_2 - \frac{1}{12}h^2, \\
 m_3 &\approx m'_3, \\
 m_4 &\approx m'_4 - \frac{1}{2}m'_2h^2 + \frac{7}{240}h^4, \\
 &\dots\dots\dots
 \end{aligned}$$

Matome, kad  $a_j$  nuo  $a'_j$  bei  $m_j$  nuo  $m'_j$  skiriasi papildomais dėmenimis – Šepardo pataisomis.

Yra ir kitokių pataisų.

Stebėjimo duomenys dažnai vaizduojami grafiškai įvairiais būdais. Paminėsime tik vadinamąsias *histogramas*. Kiekvienam intervalui  $[\tau_l - h/2, \tau_l + h/2)$  brėžiame stačiakampį, kurio pagrindas yra tas intervalas, o plotas lygus  $n_l/n$  (kitaip tariant, aukštinė lygi  $n_l/(nh)$ ; žr. 33 pav.).

**P a v z d y s.** Automatinės staklės gamina rutuliukus. Iš vienos dienos produkcijos parinkome 60 rutuliukų (kiekvieną kartą gražindami rutuliuką atgal) ir išmatavome jų skersmenis. Matavimų duomenys šitokie (milimetrais):

7,38	7,29	7,43	7,40	7,36	7,41	7,35	7,31	7,26	7,37
7,28	7,37	7,36	7,35	7,24	7,33	7,42	7,36	7,39	7,35
7,45	7,36	7,42	7,40	7,28	7,38	7,25	7,34	7,33	7,32
7,33	7,30	7,32	7,30	7,39	7,34	7,38	7,39	7,27	7,35
7,35	7,32	7,35	7,27	7,34	7,32	7,38	7,41	7,36	7,44
7,32	7,37	7,31	7,46	7,35	7,35	7,29	7,34	7,30	7,40

Suskaičiausime pirmuosius keturis imties momentus. Po gana varginančių skaičiavimų galime gauti (autorius naudojami kišeniniu programuojamu kalkuliatoriumi)

$$\begin{aligned}
 a_1 = \bar{x} &= 7,3490; \quad a_2 \approx 54,10267; \quad a_3 \approx 396,957690; \quad a_4 \approx 2917,641561; \\
 m_2 = s^2 &\approx 0,002466; \quad m_3 \approx -0,000001; \quad m_4 \approx 0,000016.
 \end{aligned}$$

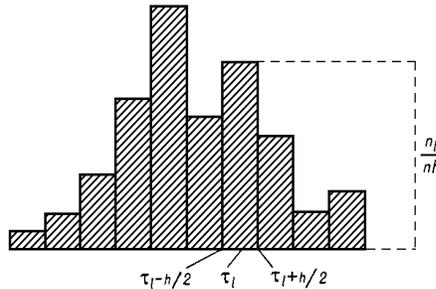
Skaičiavimus palengvinsime, sugrupavę duomenis. Grupavimo intervalo ilgi imsime lygų 0,04. Pasirinktus skaičius  $\tau_l$  ir  $n_l$  surašysime lentelėje:

$\tau_l$	7,26	7,30	7,34	7,38	7,42	7,46
$n_l$	5	9	20	14	9	3

Vėl apskaičiuosime pirmuosius keturis momentus. Skaičiavimai bus trumpesni. Gausime

$$a'_1 \approx 7,354667; a'_2 \approx 54,093733; a'_3 \approx 397,879800; a'_4 \approx 2926,697274;$$

$$m'_2 \approx 0,002612; m'_3 \approx 0,000008; m'_4 \approx 0,000017.$$



33 pav.

Kaip matome, gautos reikšmės nedaug skiriasi nuo anksčiau apskaičiuotųjų. Su Šepardo pataisomis turėtume

$$a''_2 \approx 54,093600; a''_3 \approx 397,876858; a''_4 \approx 2926,653999;$$

$$m''_2 \approx 0,002478; m''_4 \approx 0,000015.$$

Tos pataisos šiuo atveju nedaug padeda. Praktiniuose skaičiavimuose nereikėtų imti tiek daug skaitmenų po kablelio. Čia norėjome tik pademonstruoti metodo tikslumą.

#### 4. PAKANKAMOSIOS STATISTIKOS

Iš visų galimų statistikų išskirsime labai svarbią jų klasę – pakankamąsias statistikas. Šią sąvoką įvedė R. Fišeris.

Pamėginsime pakankamosios statistikos sąvoką paašškinti paprastu pavyzdžiu. Sakykime, turime  $n$  nepriklausomų eksperimentų. Po kiekvieno eksperimento gali įvykti kuris nors įvykis su nežinoma tikimybe  $p$  (Bernulio eksperimentai). Tarkime, kad  $X_k = 1$ , kai tas įvykis įvyko po  $k$ -ojo eksperimento, ir  $X_k = 0$ , kai jis neįvyko. Imtis  $(X_1, \dots, X_n)$  rodo skaičių  $T = X_1 + \dots + X_n$  ir numerius eksperimentų, kai stebimasis įvykis įvyko. Intuityviai aišku, kad tų numerių žinojimas neduoda jokios papildomos informacijos apie  $p$  reikšmę. Tai galima paašškinti ir šitaip. Imkime tokius skaičius

$x_k$  ( $k = 1, \dots, n$ ), lygius 0 arba 1, kad būtų  $x_1 + \dots + x_n = t$ . Sąlyginis  $(X_1, \dots, X_n)$  pasiskirstymas, kai  $T = t$ ,

$$\mathcal{P}(X_1 = x_1, \dots, X_n = x_n \mid T = t) = 1 / \binom{n}{t}$$

nepriklauso nuo  $p$ . Galime laikyti statistiką  $T = X_1 + \dots + X_n$  pakankama parametru  $p$  įvertinti.

Pateiksime griežtus apibrėžimus.

Nagrinėsime tikimybinį-statistinį modelį  $\{R^n, \mathcal{B}^n, \mathcal{P}_\theta\}$ ,  $\theta \in \Theta \subset R^s$ , aprašytą 1 skyrelyje. Tarkime, kad  $T : R^n \rightarrow R^s$  yra  $(\mathcal{B}^n, \mathcal{B}^s)$  mati funkcija. Sakysime, kad statistika  $T(X)$  yra *pakankama* pasiskirstymų klasei  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ , jei egzistuoja sąlyginės tikimybės variantas  $\mathcal{P}_\theta(B|T(X))$ , nepriklausantis nuo  $\theta$ . Taip pat sakoma, kad statistika  $T(X)$  yra pakankama parametru  $\theta$ , jei aišku apie kokią  $\Theta$  kalbama.

Teorijai suprastinti laikysime, kad tikimybinių pasiskirstymų klasė  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  tenkina reikalavimą: egzistuoja  $\sigma$  baigtinis matas  $\mu$ , apibrėžtas mačioje erdvėje  $\{R^n, \mathcal{B}^n\}$ , ir  $\mu$  integruojama funkcija  $\mathbf{p}_\theta(x)$ , apibrėžta erdvėje  $R^n$ , su sąlyga

$$\mathcal{P}_\theta(B) = \int_B \mathbf{p}_\theta(x) \mu(dx)$$

visiems  $\theta \in \Theta$  ir visoms  $B \in \mathcal{B}^n$ ; kitaip tariant, matai  $\mathcal{P}_\theta$  yra absoliučiai tolydūs mato  $\mu$  atžvilgiu (žr. V.9 skyrelį). Funkciją  $\mathbf{p}_\theta$  galime vadinti *tankiu mato  $\mu$  atžvilgiu*. Sakome, kad matas  $\mu$  *dominuoja* pasiskirstymų klasę  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ , o ta klasė yra *dominuota*.

Šios sąvokos vartojamos ir tada, kai  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  yra bet kuri tikimybinių pasiskirstymų klasė, nesujusi su minėtuoju tikimybinio-statistiniu modeliu.

Nors dominavimo reikalavimas šiek tiek susiaurina nagrinėjamų pasiskirstymų klasę, bet jį tenkina visi praktiniuose uždaviniuose pasitaikantys pasiskirstymai.

Panagrinėsime keletą pavyzdžių.

1 p a v y z d y s. Tarkime, kad stebimasis atsitiktinis dydis yra pasiskirstęs pagal normalųjį dėsnį  $N(a, \sigma^2)$  su nežinomais parametrais  $a \in R$ ,  $\sigma > 0$ . Tikimybinį matą  $\mathcal{P}_{(a, \sigma^2)}$ , remiantis Lebeگو integralu, galima užrašyti šitaip:

$$\mathcal{P}_{(a, \sigma^2)}(B) = \frac{1}{(\sigma\sqrt{2\pi})^n} \int_B \exp \left\{ -\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - a)^2 \right\} dx.$$

Taigi klasę  $\{\mathcal{P}_{(a, \sigma^2)}, a \in R, \sigma > 0\}$  dominuoja Lebeگو matas.

2 p a v y z d y s. Nesunku suvokti, kad ir bendresniu atveju, kai stebimasis atsitiktinis dydis yra absoliučiai tolydus ir jo tankis yra  $p_\theta(u)$ ,

$$\mathcal{P}_\theta(B) = \int_B p_\theta(x_1) \dots p_\theta(x_n) dx.$$

## 272 Matematinės statistikos pradmenys

Ir šiuo atveju Lebegeo matas dominuos klasę  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ .

3 p a v y z d y s. Tarkime, kad stebimasis atsitiktinis dydis yra pasiskirstęs pagal Puasono dėsnį su parametru  $\lambda > 0$ . Tada atsitiktinė imtis  $(X_1, \dots, X_n)$  įgyja reikšmes  $(x_1, \dots, x_n)$  su sveikomis neneigiamomis koordinatėmis ir tikimybėmis

$$\frac{\lambda^{x_1 + \dots + x_n}}{x_1! \dots x_n!} e^{-\lambda n}.$$

Imkime funkciją

$$\mathbf{p}_\lambda(x_1, \dots, x_n) = \frac{\lambda^{x_1 + \dots + x_n}}{x_1! \dots x_n!} e^{-\lambda n},$$

kai  $x_1, \dots, x_n$  yra sveikieji neneigiami skaičiai, ir lygia 0 kitais atvejais (arba bet kaip apibrėžta, kad tik  $\mathbf{p}_\lambda$  būtų Borelio funkcija). Visoms erdvės  $R^n$  Borelio aibėms pažymėkime  $\mu(B)$  skaičių taškų su sveikomis neneigiamomis koordinatėmis aibėje  $B$ . Ši aibės funkcija yra  $\sigma$  baigtinis matas mačioje erdvėje  $\{R^n, \mathcal{B}^n\}$ . Klasės  $\{\mathcal{P}_\lambda, \lambda > 0\}$  matus galime parašyti šitaip:

$$\mathcal{P}_\lambda(B) = \int_B \mathbf{p}_\lambda(x_1, \dots, x_n) \mu(dx).$$

Juos dominuoja matas  $\mu$ .

4 p a v y z d y s. Nagrinėkime bendresnį atvejį, kai stebimasis atsitiktinis dydis yra diskretusis ir įgyja reikšmes iš baigtinės arba skaičios aibės  $A$  su tikimybėmis  $p_\theta(u)$ ,  $u \in A$ ,  $\theta \in \Theta$ . Kiekvienai  $B \in \mathcal{B}^n$  pažymėkime  $\mu(B)$  skaičių taškų  $(x_1, \dots, x_n)$ , kurių koordinatės  $x_k \in A$  ( $k = 1, \dots, n$ ). Imkime funkciją  $\mathbf{p}_\theta(x_1, \dots, x_n) = p_\theta(x_1) \dots p_\theta(x_n)$ , kai  $x_k \in A$  ( $k = 1, \dots, n$ ), ir laikykime ją lygia 0 kitiems  $(x_1, \dots, x_n)$ . Tada

$$\mathcal{P}_\theta(B) = \int_B \mathbf{p}_\theta(x_1, \dots, x_n) \mu(dx).$$

Vėl turime dominuojamą pasiskirstymų klasę  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ .

Pakankamąsias statistikas apibrėžėme, remdamiesi sąlyginėmis tikimybėmis. Jomis ne visada patogiu operuoti. Tačiau dominuojamiems pasiskirstymams galima rasti gana paprastą vadinamąjį faktorizavimo kriterijų, nuskaitą šitokios teoremos.

**Teorema.** Tarkime, kad  $T : R^n \rightarrow R^s$  yra  $(\mathcal{B}^n, \mathcal{B}^s)$  mati funkcija.  $T(X)$  yra pakankama pasiskirstymų klasei  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ , dominuojamai mato  $\mu$  su tankiu  $\mathbf{p}_\theta$ , tada ir tik tada, kai visiems  $\theta \in \Theta$  egzistuoja tokia neneigiama  $(\mathcal{B}^s, \mathcal{B}^1)$  mati funkcija  $g_\theta : R^s \rightarrow R^1$  ir tokia Borelio funkcija  $h : R^n \rightarrow R^n$ , nepriklausanti nuo  $\theta$ , kad visiems  $\theta \in \Theta$

$$\mu\{\mathbf{p}_\theta(x) \neq g_\theta(T(x))h(x)\} = 0,$$

kitaip sakant,

$$(1) \quad \mathbf{p}_\theta(x) = g_\theta(T(x))h(x)$$

beveik visur mato  $\mu$  atžvilgiu.

Į r o d y m a s. Teoremą įrodinėsime tik diskretiesiems pasiskirstymams. (Bendrą jos įrodymą galima rasti, pvz., [20] knygoje.) Šiuo atveju, norint nustatyti pakankamąją statistiką, užtenka reikalauti, kad lygybės

$$(2) \quad \mathcal{P}_\theta(x) = g_\theta(T(x))h(x)$$

su pakankamosios statistikos apibrėžime nurodytomis funkcijomis  $g_\theta$  ir  $h$  būtų teisingos tiems  $x \in R^n$ , kuriems  $\mathcal{P}_\theta(x) > 0$ .

Pirmiausia įrodysime pakankamumą. Tarkime, kad (2) lygybė yra teisinga. Fiksuokime  $x$  ir  $t$ . Laikydami  $\mathcal{P}_\theta(T(X) = t) > 0$ , iš lygybės

$$\mathcal{P}_\theta(X = x|T(X) = t) = \frac{\mathcal{P}_\theta(X = x, T(X) = t)}{\mathcal{P}_\theta(T(X) = t)}$$

gauname

$$\mathcal{P}_\theta(X = x|T(X) = t) = 0,$$

kai  $T(x) \neq t$ , ir

$$\begin{aligned} \mathcal{P}_\theta(X = x|T(X) = t) &= \frac{\mathcal{P}_\theta(X = x)}{\mathcal{P}_\theta(T(X) = t)} = \\ &= \frac{g_\theta(t)h(x)}{g_\theta(t) \sum_{\{y:T(y)=t\}} h(y)} = \frac{h(x)}{\sum_{\{y:T(y)=t\}} h(y)}, \end{aligned}$$

kai  $T(x) = t$ . Matome, kad sąlyginė tikimybė  $\mathcal{P}_\theta(X = x|T(X) = t)$  nepriklauso nuo  $\theta$ . Nuo  $\theta$  nepriklauso ir  $\mathcal{P}_\theta(B|T(X) = t)$ .

Dabar įrodysime sąlygos būtinumą. Tarkime, kad sąlyginė tikimybė  $\mathcal{P}_\theta(X = x|T(X) = t)$  nepriklauso nuo  $\theta$  ir lygi, sakysime,  $w(x, t)$ . Jei  $T(x) = t$ , tai

$$\begin{aligned} \mathcal{P}_\theta(X = x) &= \mathcal{P}_\theta(X = x, T(X) = t) = \mathcal{P}_\theta(X = x, |T(X) = t) \times \\ &\times \mathcal{P}_\theta(T(X) = t) = w(x, t)\mathcal{P}_\theta(T(X) = t). \end{aligned}$$

Vadinasi,  $\mathcal{P}_\theta(X = x)$  tenkina (2) lygybę.  $\square$

(1) formulės dešinės pusės antrasis dauginamasis nuo  $\theta$  nepriklauso, o norint apskaičiuoti pirmąjį dauginamąjį, priklausantį nuo  $\theta$ , reikia žinoti tik statistikos  $T$  reikšmę ir visai nereikia konkrečių imties  $x$  reikšmių. Vaizdžiai kalbant, pakankamoji statistika turi tą pačią informaciją apie parametą  $\theta$ , kaip ir visi stebėjimo duomenys.

5 p a v y z d y s. Stebimasis atsitiktinis dydis įgyja reikšmę 1 su nežinoma tikimybe  $\alpha$ ,  $0 < \alpha < 1$ , ir reikšmę 0 su tikimybe  $1 - \alpha$ . Pagal 4 pavyzdį visiems  $x_k$  ( $k = 1, \dots, n$ ), lygiems 0 arba 1,

$$\begin{aligned} p_\alpha(x_1, \dots, x_n) &= \alpha^{x_1 + \dots + x_n} (1 - \alpha)^{n - (x_1 + \dots + x_n)} = \\ &= (1 - \alpha)^n \left( \frac{\alpha}{1 - \alpha} \right)^{x_1 + \dots + x_n}. \end{aligned}$$

Statistika  $X_1 + \dots + X_n$  yra pakankama parametru  $\alpha$ .

6 p a v y z d y s. Kai turime Puasono dėsnį su nežinomu parametru  $\lambda > 0$ , visiems sveikiesiems neneigiamiesiems  $x_k$  ( $k = 1, \dots, n$ ) (žr. 3 pvz.)

$$p_\lambda(x_1, \dots, x_n) = e^{-\lambda n} \lambda^{x_1 + \dots + x_n} (x_1! \dots x_n!)^{-1}.$$

Ir čia statistika  $X_1 + \dots + X_n$  yra pakankama parametru  $\lambda$ .

7 p a v y z d y s. Imkime normalųjį dėsnį  $N(a, \sigma^2)$ . Atsitiktinė imtis  $(X_1, \dots, X_n)$  turi tankį

$$(3) \quad \frac{1}{(\sigma\sqrt{2\pi})^n} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - a)^2 \right\}.$$

Jei  $a$  žinomas, o  $\sigma > 0$  – nežinomas, tai statistika

$$\sum_{k=1}^n (X_k - a)^2$$

yra pakankama parametru  $\sigma^2$ . Kai  $\sigma$  žinomas, o  $a \in R$  – nežinomas, užrašę (3) pavidalu

$$(4) \quad \frac{1}{(\sigma\sqrt{2\pi})^n} \exp \left\{ -\frac{na^2}{2\sigma^2} + \frac{a}{\sigma^2} \sum_{k=1}^n x_k \right\} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{k=1}^n x_k^2 \right\},$$

matome, kad statistika  $X_1 + \dots + X_n$  yra pakankama parametru  $a$ . Jei abu parametrai  $a \in R$  ir  $\sigma > 0$  yra nežinomi, tai iš (4) išplaukia, kad vektorinė statistika  $(T_1, T_2)$ , kur

$$T_1 = X_1 + \dots + X_n, \quad T_2 = X_1^2 + \dots + X_n^2,$$

yra pakankama parametrams  $(a, \sigma^2)$ .

## 5. SUDERINTIEJI IR NEPASLINKTIEJI ĮVERČIAI

Kaip minėjome 1 skyrelyje, vienas iš pagrindinių matematinės statistikos uždavinių yra nežinomų pasiskirstymo parametru įvertinimas. Dažnai, remdamiesi kokiais nors samprotavimais, galime pasirinkti nežinomos pasiskirstymo funkcijos pavidalą, bet į jį įeina nežinomi parametrai. Reikia įvertinti

tuos parametrus. Suprantama, remiamės stebėjimo rezultatais – tinkamai parinkta rezultatų funkcija.

Sakykime, turime tikimybinį-statistinį modelį  $\{R^n, \mathcal{B}^n, \mathcal{P}_\theta\}$ ,  $\theta \in \Theta$ . Tirsime atvejį, kai  $\Theta$  yra realiųjų skaičių aibė. Nežinomą parametą  $\theta$  reikia įvertinti, remiantis imtimi  $X = (X_1, \dots, X_n)$ . Kiekviena realiąją statistiką  $\theta^*(X) = \theta^*(X_1, \dots, X_n)$  vadinsime parametro  $\theta$  *įverčio funkcija*, arba tiesiog *įverčiu*. Žinoma, ne kiekviena statistika tiks tam reikalui. Ji turi būti kokia nors prasme artima nežinomojo parametro reikšmei. Išskirsime dvi R. Fišerio įvestas įverčių klases: suderintuosius ir nepaslinktuosius įverčius.

Tarkime, kad  $\theta_n^*(X_1, \dots, X_n)$  ( $n = 1, 2, \dots$ ) yra įverčių seka. Sakysime, jog ji yra suderinta, jei kiekvienam  $\varepsilon > 0$

$$\mathcal{P}_\theta(|\theta_n^*(X_1, \dots, X_n) - \theta| \geq \varepsilon) \rightarrow 0,$$

kai  $n \rightarrow \infty$ , visiems  $\theta \in \Theta$ , t. y.  $\theta_n^*$  konverguoja į  $\theta$  pagal tikimybę. Tai reiškia, kad su tikimybe, kiek norima artima 1,  $\theta_n^*(X)$  kiek norima mažai skirsis nuo  $\theta$ , jei tik  $n$  bus pakankamai didelis. Paprastai (nors tai ir nėra tikslu) ne tik seka, bet ir kiekvienas  $\theta_n^*$  vadinamas *suderintu*. Šiame apibrėžime tenka operuoti erdve  $\{R, \mathcal{B}, \mathcal{P}_\theta\}^\infty$ .

Galima kalbėti ne tik apie nežinomo parametro  $\theta$ , bet ir apie jo funkcijos  $\psi(\theta)$  suderintąjį įvertį. Tinka analogiškas apibrėžimas.

1 p a v y z d y s. Sakykime, stebime atsitiktinį dydį su nežinomu vidurkiu  $a \in R$ . Parodysime, kad  $\bar{X}$  yra suderintasis parametro  $a$  įvertis. Reikia įrodyti, kad  $\bar{X}$  konverguoja pagal tikimybę į  $a$ , kai  $n \rightarrow \infty$ , t. y. kiekvienam  $\varepsilon > 0$

$$\mathcal{P}_a\left\{\left|\frac{1}{n}(X_1 + \dots + X_n) - a\right| > \varepsilon\right\} \rightarrow 0,$$

kai  $n \rightarrow \infty$ . Tačiau šis teiginys išplaukia iš Chinčino III.3.3. (žr. taip pat III.10.3 pavyzdį) teoremos.

2 p a v y z d y s. Jei stebimasis atsitiktinis dydis turi žinomą vidurkį  $a$ , bet nežinomą dispersiją  $\sigma^2 > 0$ , tai statistika

$$S_0^2 = \frac{1}{n} \sum_{k=0}^n (X_k - a)^2$$

yra suderintas  $\sigma^2$  įvertis. Iš tikrųjų, pritaikę Chinčino teoremą atsitiktiniams dydžiams  $(X_k - a)^2$ , gauname, kad kiekvienam  $\varepsilon > 0$

$$\mathcal{P}_{\sigma^2}\left\{\left|\frac{1}{n} \sum_{k=1}^n (X_k - a)^2 - \sigma^2\right| \geq \varepsilon\right\} \rightarrow 0,$$

kai  $n \rightarrow \infty$ .

3 p a v y z d y s. Jei stebimasis atsitiktinis dydis turi nežinomą dispersiją  $\sigma^2 > 0$  ir jo vidurkis  $a \in R$  yra taip pat nežinomas, tai

$$S^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^2$$

yra suderintas parametro  $\sigma^2$  įvertis. Įrodysime tą teiginį.

Kadangi

$$\begin{aligned} S^2 &= \frac{1}{n} \sum_{k=1}^n ((X_k - a) - (\bar{X} - a))^2 = \frac{1}{n} \sum_{k=1}^n (X_k - a)^2 - (\bar{X} - a)^2 = \\ &= S_0^2 - (\bar{X} - a)^2, \end{aligned}$$

tai

$$\begin{aligned} \mathcal{P}_{(a, \sigma^2)} \left\{ \left| S^2 - \sigma^2 \right| \geq \varepsilon \right\} &\leq \mathcal{P}_{(a, \sigma^2)} \left\{ \left| S_0^2 - \sigma^2 \right| \geq \frac{\varepsilon}{2} \right\} + \\ &+ \mathcal{P}_{(a, \sigma^2)} \left\{ \left| \bar{X} - a \right| \geq \sqrt{\frac{\varepsilon}{2}} \right\}. \end{aligned}$$

Pasinaudoję 1 ir 2 pavyzdžių rezultatais, gauname reikiamą teiginį.

Sakykime, turime realiąją integruojamą statistiką  $\theta^* = \theta^*(X_1, \dots, X_n)$ , kuria norime įvertinti nežinomą parametą  $\theta \in \Theta$ . Dydį  $M_\theta \theta^*(X_1, \dots, X_n) - \theta$  natūralu vadinti *įverčio poslinkiu*, arba *sisteminė paklaida*. Čia indeksas  $\theta$  prie vidurkio ženklo  $M$  rodo, kad vidurkis imamas mato  $\mathcal{P}_\theta$  atžvilgiu. Jei visiems  $\theta \in \Theta$

$$M_\theta \theta^*(X_1, \dots, X_n) = \theta,$$

tai sakome, kad įvertis  $\theta^*$  yra *nepaslinktas*.

Panašiai galime apibūdinti ir parametro funkcijos  $\psi(\theta)$  įverčius.

4 p a v y z d y s.  $\bar{X}$  yra nepaslinktasis nežinomo vidurkio  $a$  įvertis, nes

$$M_a \bar{X} = \frac{1}{n} \sum_{k=1}^n M_a X_k = a.$$

5 p a v y z d y s. Jei atsitiktinis dydis turi žinomą vidurkį  $a$ , bet nežinomą dispersiją  $\sigma^2 > 0$ , tai statistika  $S_0^2$  yra nepaslinktasis  $\sigma^2$  įvertis. Iš tikrųjų

$$M_{\sigma^2} S_0^2 = \frac{1}{n} \sum_{k=1}^n M_{\sigma^2} (X_k - a)^2 = \sigma^2.$$

6 p a v y z d y s. Tarkime, kad stebimasis atsitiktinis dydis turi nežinomą vidurkį  $a \in R$  ir nežinomą dispersiją  $\sigma^2 > 0$ . Panagrinėsime statistiką

$$\begin{aligned}
 S^2 &= \frac{1}{n} \sum_{k=1}^n (X_k - a)^2 - \left( \frac{1}{n} \sum_{k=1}^n (X_k - a) \right)^2 = \\
 &= \frac{1}{n} \left( 1 - \frac{1}{n} \right) \sum_{k=1}^n (X_k - a)^2 - \frac{1}{n^2} \sum_{1 \leq j < k \leq n} (X_j - a)(X_k - a).
 \end{aligned}$$

Iš čia

$$M_{(a, \sigma^2)} S^2 = \left( 1 - \frac{1}{n} \right) \sigma^2.$$

Vadinasi,  $S^2$  nėra nepaslinktasis  $\sigma^2$  įvertis. Kuo mažesnis  $n$ , tuo didesnis poslinkis (kai  $n = 2$ ,  $M_{(a, \sigma^2)} S^2 = \sigma^2/2$ ). Dideliems  $n$  tas poslinkis yra nedidelis: jis konverguoja į nulį, kai  $n \rightarrow \infty$ . Todėl sakoma, kad įvertis  $S^2$  yra *asimptotiškai nepaslinktas*. Pastebėsime, kad

$$S_1^2 = \frac{n}{n-1} S^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2$$

yra nepaslinktasis  $\sigma^2$  įvertis.

Tam pačiam nežinomam parametrui įvertinti galime sudaryti daug nepaslinktųjų įverčių. Matėme, kad  $\bar{X}$  yra nepaslinktasis vidurkio  $a$  įvertis. Įkime kokius nors pastovius skaičius  $q_1, \dots, q_n$ , tenkinančius sąlygą  $q_1 + \dots + q_n = 1$ , ir sudarykime statistiką

$$V = q_1 X_1 + \dots + q_n X_n.$$

Kadangi

$$M_a V = \sum_{k=1}^n q_k M_a X_k = a \sum_{k=1}^n q_k = a,$$

tai  $V$  yra taip pat nepaslinktasis  $a$  įvertis.  $\bar{X}$  yra specialus jo atvejis, kai  $q_1 = \dots = q_n = 1/n$ . Įvairiai parinkdami skaičius  $q_1, \dots, q_n$ , galime gauti be galo daug nežinomo parametro  $a$  įverčių. Kuris iš jų geriausias?

Jei turime du nežinomo parametro  $\theta$  įverčius, tai natūralu laikyti geresniu tą, kurio reikšmės yra mažiau išsibarsčiusios apie parametą  $\theta$ . Išsibarstymo matą galime parinkti įvairiai. Patogus ir dažniausiai vartojamas yra antrasis momentas  $M_\theta(\theta^* - \theta)^2$ , jei jis egzistuoja. Jei įvertis  $\theta^*$  yra nepaslinktasis, tai tas dydis yra įverčio dispersija.

Tarkime, kad  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  yra netuščia tikimybinių matų sistema erdvėje  $\{R^n, \mathcal{B}^n\}$  ir  $\psi : \Theta \rightarrow R$ . Kiekvienam  $\theta_0 \in \Theta$  pažymėkime  $H_{\theta_0}$  klasę visų nepaslinktųjų  $\psi(\theta)$  įverčių  $T = T(X)$ , turinčių dispersiją  $D_{\theta_0} T$ . Sakome, kad  $\psi(\theta)$  įvertis  $T_0 \in H_{\theta_0}$  turi *lokaliai mažiausią dispersiją* taške  $\theta = \theta_0$ , jei visiems  $T \in H_{\theta_0}$  teisingos nelygybės

$$M_{\theta_0} (T_0 - \psi(\theta_0))^2 \leq M_{\theta_0} (T - \psi(\theta_0))^2.$$

Jei  $H$  yra klasė visų nepaslinktųjų  $\psi(\theta)$  įverčių  $T = T(X)$ , visiems  $\theta \in \Theta$  turinčių dispersiją  $D_\theta T$ , tai sakome, kad  $\psi(\theta)$  įvertis  $T_0 \in H$  turi *tolygiai mažiausią dispersiją*, kai visiems  $\theta \in \Theta$  ir visiems  $T \in H$  teisingos nelygybės

$$M_\theta(T_0 - \psi(\theta))^2 \leq M_\theta(T - \psi(\theta))^2.$$

**1 teorema.** *Pažymėkime  $K$  klasę visų realiųjų statistikų  $W$ , turinčių savybes  $M_\theta W = 0$ ,  $M_\theta W^2 < \infty$ . Tarkime, kad įverčių klasė  $H$  nėra tuščia.  $\psi(\theta)$  įvertis  $T_0 \in H$  turi tolygiai mažiausią dispersiją tada ir tik tada, kai kiekvienai statistikai  $W \in K$  ir visiems  $\theta \in \Theta$*

$$M_\theta W T_0 = 0.$$

Atkreipsime dėmesį, jog iš Koši nelygybės išplaukia, kad  $M_\theta W T_0$  egzistuoja.

**I r o d y m a s. B ū t i n u m a s.** Tarkime, kad  $T_0$  turi tolygiai mažiausią dispersiją ir kuriam nors  $\theta_0 \in \Theta$  bei kuriai nors  $W_0 \in K$  teisinga nelygybė  $M_{\theta_0} W_0 T_0 \neq 0$ . Kiekvienam realiajam  $\lambda$  įvertis  $T_0 + \lambda W_0 \in H$ . Vidurkis  $M_{\theta_0} W_0^2$  negali būti lygus 0, nes tada ir  $M_{\theta_0} W_0 T_0$  būtų lygus 0. Imkime  $\lambda_0 = -M_{\theta_0} W_0 T_0 / M_{\theta_0} W_0^2$ . Tada gautume

$$\begin{aligned} D_{\theta_0}(T_0 + \lambda_0 W_0) &= D_{\theta_0} T_0 + 2\lambda_0 M_{\theta_0} W_0 T_0 + \lambda_0^2 M_{\theta_0} W_0^2 = \\ &= D_{\theta_0} T_0 - \frac{M_{\theta_0}^2 W_0 T_0}{M_{\theta_0} W_0^2} < D_{\theta_0} T_0, \end{aligned}$$

bet tai prieštarautų prielaidai, kad  $T_0$  turi tolygiai mažiausią dispersiją.

**P a k a n k a m u m a s.** Tarkime, kad kuriam nors įverčiui  $T_0 \in H$  ir visiems  $\theta \in \Theta$  bei visoms statistikoms  $W \in K$  teisinga lygybė

$$M_\theta W T_0 = 0.$$

Kiekvienam įverčiui  $T \in H$  turime  $T_0 - T \in K$ . Vadinasi, visiems  $\theta \in \Theta$

$$M_\theta(T_0 - T)T_0 = 0,$$

t. y.

$$M_\theta T_0^2 = M_\theta T_0 T.$$

Iš Koši nelygybės išplaukia

$$M_\theta T_0^2 \leq (M_\theta T_0^2 \cdot M_\theta T^2)^{1/2}.$$

Jei  $M_\theta T_0^2 = 0$ , tai nieko nereikia įrodinėti. Jei  $M_\theta T_0^2 > 0$ , tai

$$M_\theta T_0^2 \leq M_\theta T^2.$$

Tai ir reikėjo įrodyti, nes  $M_\theta T_0 = M_\theta T = \psi(\theta)$ .  $\square$

Įverčiams su lokaliai mažiausia dispersija teisinga analogiška teorema.

**2 teorema.** *Pažymėkime  $K_{\theta_0}$  klasę visų realiųjų statistikų  $W$ , turinčių savybes  $M_{\theta_0}W = 0$ ,  $M_{\theta_0}W^2 < \infty$ . Tarkime, kad įverčių klasė  $H_{\theta_0}$  nėra tuščia.  $\psi(\theta)$  įvertis  $T_0 \in H_{\theta_0}$  turi lokaliai mažiausią dispersiją taške  $\theta = \theta_0$  tada ir tik tada, kai kiekvienai statistikai  $W \in K_{\theta_0}$*

$$M_{\theta_0}WT_0 = 0.$$

Į r o d y m a s analogiškas 1 teoremos įrodymui.

1 ir 2 teoremos nurodo būdą, kaip patikrinti, ar įvertis turi mažiausią dispersiją. Konstruojant tokius įverčius, praverčia dvi toliau įrodomos teoremos.

**3 (Rao<sup>1</sup>–Blekvelo<sup>2</sup>) teorema.** *Tarkime, kad pasiskirstymų sistema  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  turi pakankamąją statistiką  $T$  ir įverčių klasė  $H$  nėra tuščia. Tada sąlyginio vidurkio variantas  $M_\theta(V|T)$ ,  $V \in H$ , pagal pakankamosios statistikos apibrėžimą nepriklausantis nuo  $\theta$ , yra  $\psi(\theta)$  nepaslinktasis įvertis. Be to, visiems  $\theta \in \Theta$*

$$(1) \quad M_\theta(M_\theta(V|T) - \psi(\theta))^2 \leq M_\theta(V - \psi(\theta))^2.$$

Ši formulė virsta lygybe visiems  $\theta \in \Theta$  tada ir tik tada, kai  $V = M_\theta(V|T)$  beveik visur matų  $\mathcal{P}_\theta$  atžvilgiu.

Į r o d y m a s. Pagal II.10.4 teoremą

$$M_\theta(M_\theta(V|T)) = M_\theta V.$$

Todėl  $M(V|T)$  yra nepaslinktasis  $\psi(\theta)$  įvertis. Vadinasi, pakanka visiems  $\theta \in \Theta$  įrodyti nelybę

$$M_\theta(M_\theta(V|T))^2 \leq M_\theta V^2.$$

Kadangi  $M_\theta V^2 = M_\theta(M_\theta(V^2|T))$ , tai pakanka įrodyti, kad beveik visur mato  $\mathcal{P}_\theta$  atžvilgiu

$$(2) \quad (M_\theta(V|T))^2 \leq M_\theta(V^2|T).$$

Nesunku suvokti, kad atsitiktiniam vidurkiui  $M_\theta(V|T)$  beveik visur mato  $\mathcal{P}_\theta$  atžvilgiu galima taikyti Koši nelybę. Gausime, kad beveik visur mato  $\mathcal{P}_\theta$  atžvilgiu

<sup>1</sup> Callyampudi Radhakrishna Rao (g. 1920 m.) – indų matematikas.

<sup>2</sup> David Blackwell (g. 1919 m.) – amerikiečių matematikas.

$$M_\theta^2(V|T) \leq M_\theta(V^2|T) \cdot M_\theta(1|T),$$

o tai ir yra (2) nelygybė.

Jei (1) formulėje kuriam nors  $\theta$  turime lygybės ženklą, tai teisinga lygybė

$$(3) \quad M_\theta(M_\theta(V|T))^2 = M_\theta V^2.$$

Tačiau pagal II.10.8 teoremą

$$\begin{aligned} M_\theta(VM_\theta(V|T)) &= M_\theta(M_\theta(VM_\theta(V|T)T)) = \\ &= M_\theta(M_\theta(V|T)M_\theta(V|T)). \end{aligned}$$

Iš šios ir (3) formulės

$$\begin{aligned} M_\theta(V - M_\theta(V|T))^2 &= M_\theta V^2 - 2M_\theta(VM_\theta(V|T)) + \\ &+ M_\theta(M_\theta(V|T))^2 = M_\theta V^2 - M_\theta(M_\theta(V|T))^2 = 0. \end{aligned}$$

Iš čia išplaukia, kad  $V = M_\theta(V|T)$  beveik visur mato  $\mathcal{P}_\theta$  atžvilgiu.  $\square$

Kita teorema pagrįsta pilnosios statistikos sąvoka.

Sakoma, kad pasiskirstymų sistema  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ , nusakyta erdvėje  $\{R^k, \mathcal{B}^k\}$ , yra *pilna*, jei kiekviena Borelio funkcija  $\varphi : R^k \rightarrow R$  su sąlyga

$$\int_{R^k} \varphi(x) \mathcal{P}_\theta(dx) = 0, \quad \theta \in \Theta,$$

yra beveik visur lygi 0 visų matų  $\mathcal{P}_\theta, \theta \in \Theta$ , prasme.

7 p a v y z d y s. Nagrinėkime binominių pasiskirstymų sistemą  $\{P_\theta, 0 < \theta < 1\}$ , nusakytą erdvėje  $\{R, \mathcal{B}\}$  lygybėmis

$$P_\theta(y) = \begin{cases} \binom{s}{y} \theta^y (1-\theta)^{s-y}, & \text{kai } y = 0, 1, \dots, s, \\ 0 & \text{visiems kitiems } y. \end{cases}$$

Parodysime, kad ši sistema yra pilna. Tarkime, kad kokiai nors Borelio funkcijai  $\varphi$

$$(4) \quad \int_R \varphi(x) P_\theta(dx) = \sum_{k=0}^s \varphi(k) \binom{s}{k} \theta^k (1-\theta)^{s-k} = 0, \quad 0 < \theta < 1.$$

Pažymėkime  $z = \theta/(1-\theta)$ . Tada (4) lygybė virsta šitokia:

$$\sum_{k=0}^s \varphi(k) \binom{s}{k} z^k = 0, \quad 0 < z < \infty.$$

Kadangi  $s$ -ojo laipsnio polinomas turi ne daugiau kaip  $s$  skirtingų šaknų, o šis polinomas virsta nuliu visiems teigiamiesiems  $z$ , tai visi jo koeficientai turi būti lygūs 0. Vadinasi,  $\varphi(k) = 0$  ( $k = 0, 1, \dots, s$ ).

Statistika  $T$  yra vadinama *pilnąja* pasiskirstymų sistemos  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  *statistika*, jei jos indukuotų pasiskirstymų sistema  $\{\mathcal{P}_\theta^T, \theta \in \Theta\}$  yra pilna.

8 p a v y z d y s. Sakykime, atliekame  $n$  Bernulio eksperimentų, kuriuose stebime kokią nors įvykį. To įvykio tikimybė  $p \in (0, 1)$  yra nežinoma, bet ta pati visuose eksperimentuose. Imkime statistiką  $T(X) = X_1 + \dots + X_n$  (įvykių skaičių, atlikus  $n$  eksperimentų). Jos generuota pasiskirstymų sistema nusakyta 7 pavyzdyje. Vadinasi, statistika  $T$  yra pilna šiai pasiskirstymų sistemai.

Dažnai statistikos pilnumą padeda nustatyti tolesnė teorema.

**4 teorema.** *Tarkime, kad pasiskirstymų sistema  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ ,  $\Theta \subset R$ , nusakyta erdvėje  $\{R, \mathcal{B}\}$ , yra dominuojama kokio nors  $\sigma$  baigtinio mato su tankio funkcija*

$$p_\theta(y) = h(y) \exp\{\theta \cdot U(y) + V(\theta)\};$$

čia  $h, U$  yra Borelio funkcijos. Tarkime, kad aibėje  $\Theta$  telpa neišsigimęs intervalas. Tada

$$T(X) = \sum_{k=1}^n U(X_k)$$

yra pilna ir pakankama pasiskirstymų sistemos  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  statistika.

Šios teoremos įrodymą galima rasti, pavyzdžiui, [39], p. 98.

**5 (Lemano<sup>1</sup>–Šefė<sup>2</sup>) teorema.** *Tarkime, kad pasiskirstymų sistema  $\{\mathcal{P}_\theta, \theta \in \Theta\}$  turi pilną pakankamąją statistiką  $T$  ir įverčių klasė  $H$  nėra tuščia. Tada kiekvienam  $V \in H$  sąlyginis vidurkis  $M_\theta(V|T)$  yra nepaslinktasis  $\psi(\theta)$  įvertis su tolygiai mažiausia dispersija.*

Į r o d y m a s. Pirmiausia įrodysime, kad bet kuriems  $V_1 \in H, V_2 \in H$  beveik visur matų  $\mathcal{P}_\theta$  atžvilgiu

$$(5) \quad M_\theta(V_1|T) = M_\theta(V_2|T).$$

Pažymėkime  $\mathcal{P}_\theta^T$  matą, indukuotą statistikos  $T$ . Sakykime,  $Q = T(R^n)$ . Kadangi  $M_\theta(V_1|T)$  ir  $M_\theta(V_2|T)$  yra nepaslinktieji  $\psi(\theta)$  įverčiai, tai

$$\int_Q (M_\theta(V_1|T) - M_\theta(V_2|T)) d\mathcal{P}_\theta^T$$

visiems  $\theta \in \Theta$ . Iš matų  $\mathcal{P}_\theta^T$  sistemos pilnumo išplaukia, kad (5) teisinga beveik visur matų  $\mathcal{P}_\theta^T$  atžvilgiu. Taigi visi  $M_\theta(V|T)$ ,  $V \in H$ , sutampa vienas su kitu beveik visur matų  $\mathcal{P}_\theta$  atžvilgiu. Pagal 1 teoremą įvertis  $M_\theta(V|T)$  turi tolygiai mažiausią dispersiją. □

<sup>1</sup> Erich Leo Lehmann (g. 1917 m.) – amerikiečių matematikas.

<sup>2</sup> Henry Scheffé (g. 1907 m.) – amerikiečių matematikas.

## 6. ĮVERČIŲ SUDARYMO METODAI

Įverčius galime sudaryti įvairiais būdais. Tačiau ne visi bet kaip sudaryti įverčiai bus tinkami. Todėl naudinga žinoti bendrus metodus, kuriuos taikant, galima gauti gerus įverčius. Tokių metodų yra nemažai. Nagrinėsime tik du iš jų.

Istoriškai pirmasis iš tokių metodų yra vadinamasis *momentų metodas*, pasiūlytas K. Pirsono. Tarkime, kad pasiskirstymų klasė  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ ,  $\Theta \subset \mathbb{R}^s$ , priklauso nuo vektorinio parametro  $\theta = (\theta_1, \dots, \theta_s)$  ir tie pasiskirstymai turi  $s$  pirmųjų momentų  $\alpha_r(\theta_1, \dots, \theta_s)$  ( $r = 1, \dots, s$ ). Imame pirmuosius  $s$  empirinių momentų  $A_r$  ( $r = 1, \dots, s$ ) ir prilyginame juos atitinkamiems teoriniams momentams. Gauname  $s$  lygčių su  $s$  nežinomųjų sistema

$$A_r = \alpha_r(\theta_1, \dots, \theta_s) \quad (r = 1, \dots, s).$$

Spręsimę ją  $\theta_1, \dots, \theta_s$  atžvilgiu. Jei sprendiniai

$$\theta_r^* = \theta_r^*(X_1, \dots, X_n) \quad (r = 1, \dots, s)$$

egzistuoja, tai juos ir laikysime parametru  $\theta_1, \dots, \theta_s$  įverčiais.

Žinoma, užuot ėmę iš eilės pirmuosius  $s$  pradinių momentų, galime imti  $s$  kitų momentų, nebūtinai pirmųjų ir nebūtinai pradinių, jei tik tie momentai egzistuoja. Tačiau iš pirmųjų momentų gauname paprastesnius ir tikslesnius įverčius.

Paaiškinsime šį metodą pavyzdžiu.

1 p a v y z d y s. Tarkime, kad stebimasis atsitiktinis dydis yra pasiskirstęs pagal normalųjį dėsnį  $N(a, \sigma^2)$  su nežinomais parametrais  $a \in \mathbb{R}$  ir  $\sigma > 0$ . Imkime pirmąjį pradinį ir antrąjį centrinį momentus, lygindami teorinius ir empirinius momentus

$$\begin{cases} \bar{X} = a, \\ S^2 = \sigma^2. \end{cases}$$

Iš karto gauname  $a$  ir  $\sigma^2$  įverčius  $\bar{X}$  ir  $S^2$ .

Momentų metodas yra labai paprastas, bet jį taikant, ne visada galima gauti gerus rezultatus. Geresni įverčiai gaunami *didžiausio tikėtimumo metodu*, pasiūlytu R. Fišerio 1912 m.

Tirsime pasiskirstymus  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ ,  $\Theta \subset \mathbb{R}^s$ , priklausančius nuo kelių realių parametru  $\theta = (\theta_1, \dots, \theta_s)$  ir dominuojamus mato  $\mu$  su tankio funkcija

$$\mathbf{p}_\theta(x) = p_\theta(x_1) \dots p_\theta(x_n)$$

(žr. 4 skyrelį). Parametro  $\theta \in \Theta$  reikšmėms ir taškams  $x = (x_1, \dots, x_n) \in \mathbb{R}^n$  su sąlyga  $\mathbf{p}_\theta(x) > 0$  apibrėžkime funkcijas

$$h(\theta, x) = p_\theta(x_1) \dots p_\theta(x_n)$$

ir

$$l(\theta, x) = \ln h(\theta, x) = \ln p_\theta(x_1) + \dots + \ln p_\theta(x_n).$$

Funkcija

$$H(\theta) = H(\theta, X) = p_\theta(X_1) \dots p_\theta(X_n)$$

vadinama *tikėtinumo funkcija*. Nagrinėjamas ir jos logaritmas

$$L(\theta) = L(\theta, X) = \ln p_\theta(X_1) + \dots + \ln p_\theta(X_n).$$

$h(\theta, x)$  ir  $l(\theta, x)$  yra jų realizacijos. Jei egzistuoja statistika  $\theta^* = \theta^*(X_1, \dots, X_n)$ , tenkinanti sąlygą

$$l(\theta^*) = \sup_{\theta \in \Theta} l(\theta),$$

tai ji vadinama parametro  $\theta$  *didžiausio tikėtinumo įverčiu*.

Jei  $\Theta$  yra  $s$ -matis intervalas,  $l(\theta)$  turi maksimumą jo viduje ir yra diferencijuojama  $\theta_1, \dots, \theta_s$  atžvilgiu, tai jos maksimumo taške

$$\frac{\partial H(\theta)}{\partial \theta_r} = 0 \quad (r = 1, \dots, s)$$

arba

$$\frac{\partial L(\theta)}{\partial \theta_r} = 0 \quad (r = 1, \dots, s).$$

Vadinasi, didžiausio tikėtinumo įvertis yra šių, vadinamųjų didžiausio tikėtinumo, lygčių sprendinys. Dažnai tos lygtys turi tik vieną sprendinį.

2 p a v y z d y s. Tirkime Puasono pasiskirstymą su nežinomu parametru  $\lambda > 0$ . Pagal 4.3 pavyzdį tikėtinumo funkcija

$$H(\lambda) = \frac{\lambda^{X_1 + \dots + X_n}}{X_1! \dots X_n!} e^{-\lambda n}.$$

Iš čia

$$L(\lambda) = -\lambda n + \sum_{k=1}^n (X_k \ln \lambda - \ln X_k!).$$

Diferencijuodami pagal  $\lambda$ , gauname didžiausio tikėtinumo lygtį

$$\frac{\partial L}{\partial \lambda} = -n + \frac{1}{\lambda} \sum_{k=1}^n X_k = 0.$$

Iš jos randame didžiausio tikėtinumo įvertį

$$\lambda^* = \bar{X}.$$

3 p a v y z d y s. Panagrinėkime normalųjį dėsnį  $N(a, \sigma^2)$  su žinomu  $\sigma^2$ , bet nežinomu  $a \in R$ . Pagal 4.1 pavyzdį tikėtinumo funkcija

**284 Matematinės statistikos pradmenys**

$$H(a) = \frac{1}{(\sigma\sqrt{2\pi})^n} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{k=1}^n (X_k - a)^2 \right\}$$

ir jos logaritmas

$$L(a) = -n \ln(\sigma\sqrt{2\pi}) - \frac{1}{2\sigma^2} \sum_{k=1}^n (X_k - a)^2.$$

Didžiausio tikėtinumo lygtis yra

$$\frac{\partial L}{\partial a} = \frac{1}{\sigma^2} \sum_{k=1}^n (X_k - a) = 0.$$

Iš jos gauname didžiausio tikėtinumo įvertį

$$a^* = \bar{X}.$$

4 p a v y z d y s. Jei turime normalųjį dėsnį  $N(a, \sigma^2)$  su ž i n o m u  $a$ , bet n e ž i n o m a dispersija  $\sigma^2 > 0$ , tai, diferencijuodami tikėtinumo funkcijos logaritmą

$$L(\sigma^2) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^n (X_k - a)^2$$

pagal  $\sigma^2$ , gauname didžiausio tikėtinumo lygtį

$$\frac{\partial L}{\partial(\sigma^2)} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=1}^n (X_k - a)^2.$$

Iš jos gauname didžiausio tikėtinumo įvertį

$$(\sigma^2)^* = S_0^2.$$

5 p a v y z d y s. Jei turime normalųjį pasiskirstymą su abiem nežinomais parametrais  $a \in R$  ir  $\sigma^2 > 0$ , tai, kaip ir 3 bei 4 pavyzdžiuose, išdiferencijavę tikėtinumo funkcijos logaritmą pagal  $a$  ir  $\sigma^2$ , gauname lygčių sistemą

$$\begin{aligned} \frac{\partial L}{\partial a} &= \frac{1}{\sigma^2} \sum_{k=1}^n (X_k - a) = 0, \\ \frac{\partial L}{\partial(\sigma^2)} &= -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=1}^n (X_k - a)^2 = 0. \end{aligned}$$

Iš pirmosios lygties

$$a^* = \bar{X}.$$

Irašę šį sprendinį į antrąją lygtį, gauname

$$-\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=1}^n (X_k - \bar{X})^2 = 0.$$

Iš jos

$$(\sigma^2)^* = S^2.$$

Vadinasi,  $a^* = \bar{X}$  ir  $(\sigma^2)^* = S^2$  yra parametrų  $a$  ir  $\sigma^2$  didžiausio tikėtimumo įverčiai.

Paminėsime be įrodymo (žr. [6], 33.3 skyrelį): jei yra išpildytos gana bendros sąlygos, tai didžiausio tikėtimumo įverčiai yra suderinti ir asimptotiškai nepaslinski.

## 7. EFEKTYVIEJI ĮVERČIAI

Jei pasiskirstymų klasė ir įverčiai tenkina gana bendras sąlygas, tai galima rasti tokių įverčių dispersijų apatinį rėžį.

**(Rao–Kramero) teorema.** *Tarkime, kad pasiskirstymų klasė  $\{\mathcal{P}_\theta, \theta \in \Theta\}$ , dominuojama mato  $\mu$  su tankio funkcija  $\mathbf{p}_\theta(x)$ , priklauso nuo vieno realaus parametro  $\theta$ ,  $\Theta$  yra visa realiųjų skaičių tiesė arba intervalas, o  $T(X)$  – integruojama statistika. Pareikalaukime, kad aibė  $A = \{x : \mathbf{p}_\theta(x) > 0\}$  nepriklausytų nuo  $\theta$  ir visiems  $\theta \in \Theta$  būtų*

$$\begin{aligned} \frac{\partial}{\partial \theta} \int_A \mathbf{p}_\theta(x) \mu(dx) &= \int_A \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \mu(dx), \\ \frac{\partial}{\partial \theta} \int_A T(x) \mathbf{p}_\theta(x) \mu(dx) &= \int_A T(x) \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \mu(dx), \\ I(\theta) &= \int_A \left( \frac{\partial \ln \mathbf{p}_\theta(x)}{\partial \theta} \right)^2 \mathbf{p}_\theta(x) \mu(dx) > 0; \end{aligned}$$

sakykime, kad čia nurodyti integralai ir išvestinės egzistuoja. Jei  $M_\theta T(X) = \theta + b(\theta)$  ir funkcija  $b(\theta)$  yra diferencijuojama, tai

$$M_\theta (T(X) - \theta)^2 \geq \frac{(1 + b'(\theta))^2}{I(\theta)};$$

atskiru atveju, kai  $T(X)$  yra nepaslinktasis  $\theta$  įvertis,

$$(1) \quad D_\theta T(X) \geq \frac{I}{I(\theta)}.$$

Teoremos sąlygose minimų integralų integravimo sritis yra aibė  $A$ . Tačiau galima integruoti ir visoje erdvėje  $R^n$ , jei susitarsime laikyti pointegrines funkcijas lygias 0 tuose taškuose, kuriuose jos nėra apibrėžtos (juk ten  $\mathbf{p}_\theta(x) = 0$ ).

Į r o d y m a s. Imkime lygybes

$$\mathcal{P}_\theta(R^n) = \int_A \mathbf{p}_\theta(x) \mu(dx),$$

$$M_\theta T(X) = \int_A T(x) \mathbf{p}_\theta(x) \mu(dx),$$

arba

$$\int_A \mathbf{p}_\theta(x) \mu(dx) = 1,$$

$$\int_A T(x) \mathbf{p}_\theta(x) \mu(dx) = \theta + b(\theta).$$

Diferencijuokime jas pagal  $\theta$ . Teoremos sąlygos leidžia sukeisti diferencijavimo ir integravimo tvarką. Gausime

$$(2) \quad \int_A \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \mu(dx) = 0,$$

$$\int_A T(x) \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \mu(dx) = 1 + b'(\theta).$$

Atėmę iš antrosios lygybės pirmąją, padauginą iš  $\theta$ , turime

$$\int_A (T(x) - \theta) \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \mu(dx) = 1 + b'(\theta),$$

arba

$$\int_A (T(x) - \theta) \frac{\partial \ln \mathbf{p}_\theta(x)}{\partial \theta} \mathcal{P}_\theta(dx) = 1 + b'(\theta).$$

Taikome Koši nelygybę (V.9.13 teorema) ir gauname

$$(3) \quad (1 + b'(\theta))^2 \leq \int_A (T(x) - \theta)^2 \mathcal{P}_\theta(dx) \int_A \left( \frac{\partial \ln \mathbf{p}_\theta(x)}{\partial \theta} \right)^2 \mathcal{P}_\theta(dx).$$

Kadangi

$$\int_A (T(x) - \theta)^2 \mathcal{P}_\theta(dx) = M_\theta (T(X) - \theta)^2,$$

tai (3) nelygybė ir yra ieškomoji.  $\square$

(1) nelygybė yra vadinama *Rao-Kramero nelygybe*.

Nepaslinktuosius įverčius  $T(X)$ , tenkinančius teoremos sąlygas, galima būtų vadinti reguliariaisiais. Iš Rao-Kramero nelygybės gaunamas tokių įverčių dispersijų įvertis iš apačios. Reguliariusius įverčius  $T(X)$ , kuriems teisinga lygybė

$$D_{\theta}T(X) = \frac{1}{I(\theta)},$$

vadinsime *efektyviais*.

Panagrinėsime, kada Rao-Kramero nelygybė virsta lygybe. Kaip matyti iš teoremos įrodymo, tai įvyksta tada ir tik tada, kai (3) nelygybė virsta lygybe, o (3), kaip žinome iš V.9.13 teoremos, virsta lygybe tada ir tik tada, kai egzistuoja konstantos  $c_1$  ir  $c_2$ , iš kurių bent viena nelygi 0, tenkinančios sąlyga

$$c_1 \frac{\partial \ln \mathbf{p}_{\theta}(x)}{\partial \theta} + c_2(T(x) - \theta) = 0$$

beveik visur mato  $\mathcal{P}_{\theta}$  atžvilgiu.

Jei  $c_1 = 0$ , tai tada beveik visur  $T(x) = \theta$ . Tačiau šis atvejis netinka, nes įvertis  $T(X)$  turi nepriklausyti nuo  $\theta$ . Jei  $c_2 = 0$ , tai beveik visur mato  $\mathcal{P}_{\theta}$  atžvilgiu

$$\frac{\partial \ln \mathbf{p}_{\theta}(x)}{\partial \theta} = 0;$$

tada būtų  $I(\theta) = 0$ , bet tai prieštarautų teoremos sąlygoms.

Todėl lieka atvejis, kai  $c_1 \neq 0$ ,  $c_2 \neq 0$ . Tada beveik visur

$$(4) \quad \frac{\partial \ln \mathbf{p}_{\theta}(x)}{\partial \theta} = \kappa(T(x) - \theta);$$

čia  $\kappa = \kappa(\theta)$  gali priklausyti nuo  $\theta$ , bet ne nuo  $x$ . Jei  $\theta^* = T(X)$  yra efektyvusis  $\theta$  įvertis, tai iš (4) išplaukia, kad jį galima gauti didžiausio tikėtinumo metodu, nes tokie įverčiai yra lygties

$$\frac{\partial \ln \mathbf{p}_{\theta}(x)}{\partial \theta} = 0$$

sprendiniai. Didžiausio tikėtinumo lygties sprendiniai  $\theta^* = \text{const}$  paprastai atmetami, nes jie atitinka atvejį  $\kappa(\theta) = 0$ .

Iš (4) išplaukia: jei  $T(X)$  yra efektyvusis įvertis, tai jis yra pasiskirstymų klasės  $\{\mathcal{P}_{\theta}, \theta \in \Theta\}$  pakankamoji statistika. Iš tikrųjų, suintegravę (4), gausime

$$\mathbf{p}_{\theta}(x) = h(x) \exp\{u(\theta)T(x) + v(\theta)\};$$

čia  $h(x)$  priklauso tik nuo  $x$ , o  $u(\theta)$  ir  $v(\theta)$  tik nuo  $\theta$ , be to,  $u'(\theta) \neq 0$ .

Išnagrinėsime keletą pavyzdžių. Skaičiavimams pravartu šiek tiek pertvarkyti reiškinį  $I(\theta)$ . Pastebėsime, kad

$$I(\theta) = M_{\theta} \left( \frac{\partial \ln \mathbf{p}_{\theta}(X)}{\partial \theta} \right)^2.$$

Iš (2) išplaukia, kad

$$M_\theta \frac{\partial \ln \mathbf{p}_\theta(X)}{\partial \theta} = \int_A \frac{\partial \ln \mathbf{p}_\theta(x)}{\partial \theta} \mathbf{p}_\theta(x) \mu(dx) = \int_A \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \mu(dx) = 0.$$

Todėl

$$I(\theta) = D_\theta \frac{\partial \ln \mathbf{p}_\theta(X)}{\partial \theta}.$$

Kadangi  $\mathbf{p}_\theta(X) = p_\theta(X_1) \dots p_\theta(X_n)$ , tai

$$I(\theta) = n D_\theta \frac{\partial \ln p_\theta(X_1)}{\partial \theta}.$$

Reiškinį  $I(\theta)$  galima užrašyti ir kitaip, jei be teoremos sąlygų dar teisinga ir sąlyga

$$\int \left| \frac{\partial^2 \ln \mathbf{p}_\theta(x)}{\partial \theta^2} \right| \mathbf{p}_\theta(x) \mu(dx) < \infty.$$

Tada egzistuoja vidurkis

$$\begin{aligned} M_\theta \frac{\partial^2 \ln \mathbf{p}_\theta(X)}{\partial \theta^2} &= \int \frac{\frac{\partial^2 \mathbf{p}_\theta(x)}{\partial \theta^2} \mathbf{p}_\theta(x) - \left( \frac{\partial \mathbf{p}_\theta(x)}{\partial \theta} \right)^2}{\mathbf{p}_\theta^2(x)} \mathbf{p}_\theta(x) \mu(dx) = \\ &= \int \frac{\partial^2 \mathbf{p}_\theta(x)}{\partial \theta^2} \mu(dx) - \int \left( \frac{\partial \ln \mathbf{p}_\theta(x)}{\partial \theta} \right)^2 \mathbf{p}_\theta(x) \mu(dx). \end{aligned}$$

Kadangi antrasis dešinės pusės narys yra  $I(\theta)$  ir

$$\int \frac{\partial^2 \mathbf{p}_\theta(x)}{\partial \theta^2} \mu(dx) = \frac{\partial^2}{\partial \theta^2} \int \mathbf{p}_\theta(x) \mu(dx) = 0,$$

tai

$$I(\theta) = -M_\theta \frac{\partial^2 \ln \mathbf{p}_\theta(X)}{\partial \theta^2} = -n M_\theta \frac{\partial^2 \ln p_\theta(X_1)}{\partial \theta^2}.$$

1 p a v y z d y s. Nagrinėsime atsitiktinį dydį, pasiskirsčiusį pagal binominį dėsnį. Tarkime, kad jis įgyja reikšmes  $0, 1, \dots, N$ , reikšmę  $x_1$  įgyja su tikimybe

$$\binom{N}{x_1} \alpha^{x_1} (1 - \alpha)^{N - x_1};$$

čia  $\alpha \in (0, 1)$  yra nežinomas parametras. Nesunku patikrinti, kad šiuo atveju pasiskirstymų klasė tenkina Rao–Kramero teoremos sąlygas, be to,

$$I(\alpha) = n D_\alpha \left( \frac{X_1}{\alpha(1 - \alpha)} - \frac{N}{1 - \alpha} \right) = \frac{Nn}{\alpha(1 - \alpha)}.$$

Įvertis  $\bar{X}/N$  taip pat tenkina teoremos sąlygas. Kadangi

$$M(\bar{X}/N) = \frac{1}{nN} \sum_{k=1}^n M_\alpha X_k = \alpha,$$

$$D_\alpha(\bar{X}/N) = \frac{1}{n^2 N^2} \sum_{k=1}^n D_\alpha X_k = \frac{\alpha(1-\alpha)}{Nn},$$

tai  $\bar{X}/N$  yra efektyvusis  $\alpha$  įvertis.

2 p a v y z d y s. Tirsime atsitiktinį dydį, pasiskirsčiusį pagal Puasono dėsnį su nežinomu parametru  $\lambda > 0$ . Šiuo atveju (žr. 4.6 ir 6.2 pavyzdžius) sveikiesiems neneigiamiesiems  $x_1$

$$p_\lambda(x_1) = \frac{\lambda^{x_1}}{x_1!} e^{-\lambda},$$

$$\frac{\partial^2}{\partial \lambda^2} \ln p_\lambda(x_1) = -\frac{x_1}{\lambda^2},$$

$$I(\lambda) = -n M_\lambda \left( -\frac{X_1}{\lambda^2} \right) = \frac{n}{\lambda^2} M_\lambda X_1 = \frac{n}{\lambda}.$$

Kadangi

$$M\bar{X} = \lambda, \quad D_\lambda \bar{X} = \lambda/n,$$

tai  $\bar{X}$  yra efektyvusis  $\lambda$  įvertis.

5 skyrelyje matėme, kad ir  $V = q_1 X_1 + \dots + q_n X_n$  su konstantomis  $q_1, \dots, q_n$ , tenkinančiomis sąlyga  $q_1 + \dots + q_n = 1$ , yra nepaslinktasis vidurkio įvertis. Jo dispersija nagrinėjamu atveju

$$D_\lambda V = \sum_{k=1}^n D_\lambda (q_k X_k) = \lambda \sum_{k=1}^n q_k^2 = \lambda \sum_{k=1}^n \left( q_k - \frac{1}{n} \right)^2 + \frac{\lambda}{n}.$$

Matome, kad  $V$  yra efektyvusis  $\lambda$  įvertis tada ir tik tada, kai  $q_k = 1/n$ .

3 p a v y z d y s. Nagrinėsime atsitiktinį dydį, pasiskirsčiusį pagal normalųjį dėsnį  $N(a, \sigma^2)$  su ž i n o m u  $\sigma^2$ , bet n e ž i n o m u  $a \in R$ . Parodysime, kad ir čia  $\bar{X}$  yra efektyvusis  $a$  įvertis. Visiems realiesiems  $x_1$  (žr. 6.3 pavyzdį)

$$p_a(x_1) = \frac{1}{\sigma\sqrt{2\pi}} \exp \left( -\frac{(x_1 - a)^2}{2\sigma^2} \right),$$

$$\frac{\partial^2}{\partial a^2} \ln p_a(x_1) = -\frac{1}{\sigma^2}.$$

Po paprastų skaičiavimų

$$I(a) = \frac{n}{\sigma^2}, \quad D_a \bar{X} = \frac{\sigma^2}{n}.$$

## 290 Matematinės statistikos pradmenys

4 p a v y z d y s. Vėl tirsime atsitiktinį dydį, pasiskirsčiusį pagal normalųjį dėsnį, bet dabar laikysime  $a$  ž i n o m u, o  $\sigma^2 > 0$  – n e ž i n o m u. Parodysime, kad  $S_0^2$  yra efektyvusis  $\sigma^2$  įvertis. Visiems realiesiems  $x_1$

$$\frac{\partial}{\partial(\sigma^2)} \ln p_{\sigma^2}(x_1) = \frac{(x_1 - a)^2}{2\sigma^4} - \frac{1}{2\sigma^2}.$$

Apskaičiuosime  $I(\sigma^2)$  ir  $D_{\sigma^2} S_0^2$ :

$$I(\sigma^2) = \frac{n}{4\sigma^8} D_{\sigma^2}(X_1 - a)^2,$$

$$D_{\sigma^2} S_0^2 = \frac{1}{n} D_{\sigma^2}(X_1 - a)^2.$$

Abiejuose reiškinuose turime to paties atsitiktinio dydžio dispersiją. Apskaičiuosime ją. Iš lygybės

$$D_{\sigma^2}(X_1 - a)^2 = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} (u - a)^4 \exp\left(-\frac{(u - a)^2}{2\sigma^2}\right) du -$$

$$- \left( \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} (u - a)^2 \exp\left(-\frac{(u - a)^2}{2\sigma^2}\right) du \right)^2$$

po pakeitimo  $u - a = \sigma y$  gauname

$$D_{\sigma^2}(X_1 - a)^2 = \frac{\sigma^4}{\sqrt{2\pi}} \int_{-\infty}^{\infty} y^4 e^{-y^2/2} dy - \left( \frac{\sigma^2}{\sqrt{2\pi}} \int_{-\infty}^{\infty} y^2 e^{-y^2/2} dy \right)^2.$$

Pirmąjį integralą integruojame dalimis

$$\int_{-\infty}^{\infty} y^4 e^{-y^2/2} dy = \int_{-\infty}^{\infty} (-y^3) de^{-y^2/2} = 3 \int_{-\infty}^{\infty} y^2 e^{-y^2/2} dy.$$

Visai taip pat

$$\int_{-\infty}^{\infty} y^2 e^{-y^2/2} dy = \int_{-\infty}^{\infty} (-y) de^{-y^2/2} = \int_{-\infty}^{\infty} e^{-y^2/2} dy = \sqrt{2\pi}.$$

Čia galėjome naudotis ir II.9.1 pavyzdžio rezultatais. Todėl

$$D_{\sigma^2}(X_1 - a)^2 = 2\sigma^4$$

ir

$$I(\sigma^2) = \frac{n}{2\sigma^4}, \quad D_{\sigma^2} S_0^2 = \frac{2\sigma^4}{n}.$$

Matome, kad  $S_0^2$  yra efektyvusis  $\sigma^2$  įvertis.

Jei vietoj  $S_0^2$  imtume  $S_1^2$ , kuris, kaip matėme 5.6 pavyzdyje, yra nepaslinktasis  $\sigma^2$  įvertis, tai gautume (apskaičiuokite!)

$$D_{\sigma^2} S_1^2 = \frac{2\sigma^4}{n-1}.$$

Vadinasi,  $S_1^2$  nėra efektyvusis  $\sigma^2$  įvertis. Tačiau

$$\frac{1/I(\sigma^2)}{D_{\sigma^2} S_1^2} = 1 - \frac{1}{n}$$

konverguoja į 1, kai  $n \rightarrow \infty$ . Tokį įvertį galima būtų pavadinti *asimptotiškai efektyviu*.

Pastebėsime (žr. [6], 33.3 skyrelį), kad didžiausio tikėtimumo įverčiai, kai patenkintos gana bendros sąlygos, yra asimptotiškai efektyvūs.

Jei  $\theta^*$  yra bet kuris nepaslinktasis parametro  $\theta$  įvertis, turintis dispersiją, tai

$$\frac{1}{I(\theta)D_{\theta}\theta^*}$$

paprastai vadinamas įverčio  $\theta^*$  *efektyvumu*.

Tenka pastebėti, kad ne visada egzistuoja efektyvūs įverčiai čia nurodyta prasme. Kaip matėme, kai pasiskirstymas yra normalusis  $N(a, \sigma^2)$  su nežinomais  $a, \sigma^2$ , nepaslinktasis parametro  $\sigma^2$  įvertis  $S_1^2$  turi dispersiją  $2\sigma^4/(n-1)$ . Galima būtų įrodyti, kad ji yra mažiausia galima. Tuo tarpu  $1/I(\sigma^2) = 2\sigma^4/n$ . Vadinasi, minimali pasiekiamą reguliariųjų įverčių dispersija gali būti didesnė už Rao–Kramero nelygybėje nurodytą apatinį rėžį.

Šią teoriją galima apibendrinti ir tuo atveju, kai pasiskirstymų klasė priklauso nuo kelių realiųjų parametrų.

## 8. PASIKLIAUTINIEJI INTERVALAI

Jei nežinomam parametrui  $\theta$  turime "gerą" įvertį  $\theta^*(X)$  ir  $x = (x_1, \dots, x_n)$  yra imties realizacija, tai galime laikyti  $\theta \approx \theta^*(x_1, \dots, x_n)$ . Tačiau toks parametro įvertinimo būdas turi didelių trūkumų – juk  $\theta^*(X_1, \dots, X_n)$  yra atsitiktinis dydis. Kad ir koks "geras" būtų įvertis  $\theta^*$ , jo reikšmės yra išsibarsčiusios apie  $\theta$ . Jei tas dydis yra tolydus, tai tikimybė jam įgyti konkrečią reikšmę lygi 0. Todėl, remdamiesi įverčiais, galime rasti ne pačią nežinomo parametro reikšmę, o tik sritį, kuriai su tam tikra tikimybe priklauso vertinamasis parametras. Jei ta tikimybė artima 1, tai praktiškai galime laikyti, jog parametras yra toje srityje.

Sakykime, reikia įvertinti nežinomą parametą  $\theta$ . Imkime dvi statistikas  $\theta_1^*(X_1, \dots, X_n) < \theta_2^*(X_1, \dots, X_n)$ . Pažymėkime

$$\alpha = \mathcal{P}_{\theta}\{\theta_1^*(X_1, \dots, X_n) < \theta < \theta_2^*(X_1, \dots, X_n)\}.$$

Jei  $\alpha$  mažai skiriasi nuo 1, tai galime laikyti, kad praktiškai

$$\theta_1^* < \theta < \theta_2^*.$$

Intervalas  $(\theta_1^*, \theta_2^*)$  yra vadinamas parametro  $\theta$  *pasikliautinuoju intervalu*, o  $\alpha$  – *pasikliovimo tikimybė*, arba *pasikliovimo lygmeniu*.  $1 - \alpha$  yra klaidos tikimybė. Pasikliovimo tikimybė paprastai imama 0,9; 0,95; 0,99 ir pan. Šias sąvokas pasiūlė Dž. Neimanas<sup>1</sup>.

Statistikas  $\theta_1^*$  ir  $\theta_2^*$  galima parinkti įvairiausiais būdais. Reikia stengtis, kad tai pačiai pasikliovimo tikimybei pasikliautinis intervalas būtų kuo trumpesnis.

Sudarysime normaliojo pasiskirstymo  $N(a, \sigma^2)$  parametų pasikliautinius intervalus. Teks skirti atvejus, kai vienas iš parametų  $a, \sigma^2$  yra žinomas, o kitas – nežinomas, ir kai abu parametrai nežinomi.

1. Tarkime, kad ž i n o m a s  $\sigma^2$ , o n e ž i n o m a s  $a \in R$ . Tiesa, toks atvejis turi tik teorinę reikšmę: paprastai nežinome abiejų parametų arba žinome  $a$ , bet nežinome  $\sigma^2$ . Matėme, kad  $\bar{X}$  yra efektyvusis  $a$  įvertis. Juo ir remsimės, sudarydami pasikliautinius intervalus. Imkime intervalą  $(\bar{X} - \delta, \bar{X} + \delta)$ ; čia  $\delta$  – teigiamas skaičius, kurį vėliau parinksime. Apskaičiuosime pasikliovimo tikimybę

$$\alpha = \mathcal{P}_a(\bar{X} - \delta < a < \bar{X} + \delta) = \mathcal{P}_a\left(-\frac{\delta\sqrt{n}}{\sigma} < \frac{1}{\sigma\sqrt{n}} \sum_{k=1}^n (X_k - a) < \frac{\delta\sqrt{n}}{\sigma}\right).$$

Kadangi  $X_k$  yra nepriklausomi ir kiekvienas iš jų pasiskirstęs pagal  $N(a, \sigma^2)$ , tai suma

$$\frac{1}{\sigma\sqrt{n}} \sum_{k=1}^n (X_k - a) = (\bar{X} - a) \frac{\sqrt{n}}{\sigma}$$

yra pasiskirsčiusi pagal dėsnį  $N(0, 1)$ . Parinę  $\delta = \sigma u / \sqrt{n}$ , gauname

$$(1) \quad \alpha = \Phi(u) - \Phi(-u) = 2\Phi(u) - 1 = \sqrt{\frac{2}{\pi}} \int_0^u e^{-y^2/2} dy.$$

Pasikliovimo tikimybę  $\alpha$  parenkame, vadovaudamiesi praktiniais sumetimais. Dažnai tai bus ekonominiai samprotavimai. Turėdami  $\alpha$ , iš (1) galime rasti  $u = u(\alpha)$ . Paprastai tam praverčia normaliojo pasiskirstymo lentelės. Žinodami  $u$ , randame pasikliautinąjį intervalą

$$\left(\bar{X} - \frac{\sigma u}{\sqrt{n}}, \bar{X} + \frac{\sigma u}{\sqrt{n}}\right).$$

Kuo didesnis  $\alpha$ , tuo didesnis ir  $u(\alpha)$ , ir atvirkščiai. Sakysime (žr., pvz., [17], 1 lentelę),

<sup>1</sup> Jerzy Neyman (1895–1981) – amerikiečių matematikas.

$$u(0, 9) \approx 1, 64; u(0, 95) \approx 1, 96; u(0, 99) \approx 2, 58; u(0, 999) \approx 3, 29.$$

Paėmę didesnę  $\alpha$ , turėsime mažesnę klaidos tikimybę  $1 - \alpha$ , tačiau tada ir  $u(\alpha)$  bus didesnis bei platesnis pasikliautinis intervalas, vadinasi,  $a$  įvertinsime ne taip tiksliai. Pasikliautinąjį intervalą galime susiaurinti, padidindami  $n$  (jei tai leidžia eksperimento sąlygos). Jei iš anksto parenkame  $\alpha$  ir  $u$ , tai galime rasti  $n$ .

2. Tarkime, kad  $a$  yra žinomas, o  $\sigma^2 > 0$  – nežinomas. 7.4 pavyzdyje parodėme, kad  $S_0$  yra efektyvusis  $\sigma^2$  įvertis. Nagrinėkime intervalą  $(v_1 S_0^2, v_2 S_0^2)$ , kai  $0 < v_1 < v_2$ . Jį atitinka pasiklovimo tikimybė

$$\alpha = P_{\sigma^2}(v_1 S_0^2 < \sigma^2 < v_2 S_0^2) = P_{\sigma^2}\left(\frac{n}{v_2} < \sum_{k=1}^n \left(\frac{X_k - a}{\sigma}\right)^2 < \frac{n}{v_1}\right).$$

Iš III.9.3 pavyzdžio žinome, kad suma

$$\sum_{k=1}^n \left(\frac{X_k - a}{\sigma}\right)^2$$

yra pasiskirsčiusi pagal  $\chi^2$  su  $n$  laisvės laipsnių dėsnį. Todėl, parinkę  $v_1 = n/u_2$ ,  $v_2 = n/u_1$ , kai  $0 < u_1 < u_2$ , turime

$$\alpha = P(u_1 < \chi_n^2 < u_2) = \int_{u_1}^{u_2} p_{\chi_n^2}(y) dy.$$

Jei pasiklovimo tikimybė  $\alpha$  yra duota, tai  $u_1$  ir  $u_2$  reikia taip parinkti, kad jie tenkintų tą lygybę. Aišku, tai galime padaryti be galo daug būdų. Paprastai imama

$$(2) \quad \begin{aligned} \int_0^{u_1} p_{\chi_n^2}(y) dy &= \frac{1 - \alpha}{2}, \\ \int_{u_2}^{\infty} p_{\chi_n^2}(y) dy &= \frac{1 - \alpha}{2}. \end{aligned}$$

Radę  $u_1 = u_1(\alpha)$ ,  $u_2 = u_2(\alpha)$ , gauname  $\sigma^2$  pasikliautinąjį intervalą

$$(nu_2^{-1}(\alpha)S_0^2, nu_1^{-1}(\alpha)S_0^2).$$

Spręsdami (2) lygtis, naudojames  $\chi_n^2$  pasiskirstymo lentelėmis. Dideliems  $n$  tokių lentelių nėra. Jų ir neverta sudarinėti, nes atitinkamai normuotas  $\chi_n^2$  pasiskirstymas konverguoja į normalųjį pasiskirstymą, kai  $n$  neapbrėžtai didėja. Įrodysime šį faktą. Kadangi  $\chi_n^2$  yra  $n$  normaliųjų dydžių, pasiskirsčiusių pagal  $N(0, 1)$ , kvadratų suma, tai jo vidurkis yra  $n$ , o dispersija  $2n$  (įrodykite!). Iš centrinės ribinės teoremos (III.11.2 teoremos 2 išvados) išplaukia, kad

$$\frac{\chi_n^2 - n}{\sqrt{2n}}$$

yra asimptotiškai pasiskirstęs pagal  $N(0, 1)$ . Pasirodo, kad jau gana nedideliams  $n$  liekamasis narys yra mažas. Yra sudarytos  $\chi_n^2$  kvantilių ir jų aproksimacijų skirtumų lentelės (žr. [17], III<sup>b</sup> lentelę).

3. Tirsime atvejį, kai abu parametrai  $a \in R$  ir  $\sigma^2 > 0$  yra nežinomi. Sudarydami pasikliautinuosius intervalus, jau negalime naudoti statistikų

$$\frac{\sqrt{n}(\bar{X} - a)}{\sigma}, S_0^2,$$

nes  $a$  ir  $\sigma^2$  yra nežinomi. Imsime statistikas

$$\frac{\sqrt{n}(\bar{X} - a)}{S_1}, (n-1) \left( \frac{S_1}{\sigma} \right)^2 = n \left( \frac{S}{\sigma} \right)^2.$$

Laikysime, kad  $n > 1$ . Rasime jų pasiskirstymus. Mums reikės daugiamačių normaliųjų atsitiktinių dydžių savybių.

**Lema.** *Jei stebimasis atsitiktinis dydis yra pasiskirstęs pagal normalųjį dėsnį  $N(a, \sigma^2)$ , tai statistikos  $\bar{X}$  ir  $S^2$  yra nepriklausomos, be to, statistika*

$$(\bar{X} - a) \frac{\sqrt{n}}{\sigma} = \frac{1}{\sigma \sqrt{n}} \sum_{k=1}^n (X_k - a)$$

yra pasiskirsčiusi pagal  $N(0, 1)$ , statistika

$$(n-1) \left( \frac{S_1}{\sigma} \right)^2 = \sum_{k=1}^n \left( \frac{X_k - \bar{X}}{\sigma} \right)^2$$

– pagal  $\chi^2$  su  $n-1$  laisvės laipsnių, o statistika

$$\frac{(\bar{X} - a)\sqrt{n}}{S_1}$$

– pagal Stjudento dėsnį su  $n-1$  laisvės laipsnių.

**I r o d y m a s.** Atsitiktinio vektoriaus  $X = (X_1, \dots, X_n)$  charakteristinė funkcija pagal III.12 skyrelį

$$f_X(t) = \exp\{i(a, \dots, a)t' - \frac{1}{2}\sigma^2 tt'\};$$

čia  $t = (t_1, \dots, t_n)$ , o brūkšnelis reiškia transponavimą. Imkime ortogonalią matricą

$$C = \begin{vmatrix} c_{11} & \dots & c_{1n} \\ \dots & \dots & \dots \\ c_{n1} & \dots & c_{nn} \end{vmatrix},$$

kurioje  $c_{11} = \dots = c_{nn} = n^{-1/2}$ . Kadangi matrica yra ortogonalai, tai

$$\sum_{k=1}^n c_{kj}c_{kl} = \begin{cases} 1, & \text{kai } j = l, \\ 0, & \text{kai } j \neq l. \end{cases}$$

Iš čia

$$\sum_{k=1}^n c_{kj} = 0 \quad (j = 2, \dots, n).$$

Nagrinėsime vektorių  $Y = (Y_1, \dots, Y_n) = XC$ . Aišku,

$$(3) \quad X_1^2 + \dots + X_n^2 = Y_1^2 + \dots + Y_n^2.$$

Parodysime, kad atsitiktiniai dydžiai  $Y_1, \dots, Y_n$  yra nepriklausomi. Vektoriaus  $Y$  charakteristinė funkcija

$$\begin{aligned} f_Y(t) &= f_X(tC') = \exp \left\{ i(a, \dots, a)Ct' - \frac{1}{2}\sigma^2 tC' Ct \right\} = \\ &= \exp \left\{ iat_1 \sqrt{n} - \frac{1}{2}\sigma^2 tt' \right\}. \end{aligned}$$

Matome, kad atsitiktiniai dydžiai  $Y_1, \dots, Y_n$  yra normalieji ir kas du nekoreliuoti. Pagal III.13 skyrelio teoremą jie yra nepriklausomi. Be to,

$$\begin{aligned} Y_1 &= (X_1 + \dots + X_n)n^{-1/2} = \bar{X}\sqrt{n}, \\ MY_1 &= a\sqrt{n}, \quad MY_k = 0 \quad (k = 2, \dots, n), \\ DY_k &= \sigma^2 \quad (k = 1, \dots, n). \end{aligned}$$

Iš (3) išplaukia, kad dydžiai

$$\sum_{k=1}^n (X_k - \bar{X})^2 = \sum_{k=1}^n X_k^2 - n\bar{X}^2 = \sum_{k=2}^n Y_k^2$$

ir  $Y_1$  yra nepriklausomi. Lieka remtis III.9.3 pavyzdžiu.

Iš III.9.4 pavyzdžio išplaukia, kad statistika

$$\frac{(\bar{X} - a)\sqrt{n}}{S_1}$$

yra pasiskirsčiusi pagal Stjudento dėsnį su  $n - 1$  laisvės laipsnių.  $\square$

Dabar jau galime sudaryti pasikliautinuosius intervalus nežinomiems parametrams  $a$  ir  $\sigma^2$ . Juos imame pavidalo

$$\left( \bar{X} - \frac{u_1 S_1}{\sqrt{n}}, \bar{X} - \frac{u_2 S_1}{\sqrt{n}} \right), \quad u_1 > u_2, \\ \left( \frac{n S_1^2}{v_1}, \frac{n S_1^2}{v_2} \right), \quad v_1 > v_2 > 0.$$

Atitinkamos pasiklovimo tikimybės lygios

$$\alpha' = \mathcal{P}_{(a,\sigma)} \left( u_2 < \frac{(\bar{X} - a)\sqrt{n}}{S_1} < u_1 \right) = \int_{u_2}^{u_1} p_{St_{n-1}}(y) dy, \\ \alpha'' = \mathcal{P}_{(a,\sigma)} \left( v_2 < n \left( \frac{S_1}{\sigma} \right)^2 < v_1 \right) = \int_{v_2}^{v_1} p_{\chi_{n-1}^2}(y) dy;$$

čia  $p_{St_{n-1}}(y)$  yra Stjudento pasiskirstymo su  $n - 1$  laisvės laipsnių tankis. Pasirinkę  $\alpha'$  ir  $\alpha''$ , skaičius  $u_1, u_2, v_1, v_2$  paprastai randame iš lygčių

$$u_2 = -u_1, \quad \frac{1 - \alpha'}{2} = \int_{u_1}^{\infty} p_{St_{n-1}}(y) dy, \\ \frac{1 - \alpha''}{2} = \int_0^{v_2} p_{\chi_{n-1}^2}(y) dy, \\ \frac{1 - \alpha''}{2} = \int_{v_1}^{\infty} p_{\chi_{n-1}^2}(y) dy.$$

Palyginę antrąjį pasikliautinąjį intervalą dispersijai įvertinti, kai vidurkis  $a$  yra nežinomas, su pasikliautiniu intervalu, kai  $a$  yra žinomas (2 atvejais), matome, kad abiem atvejais vartojamas  $\chi^2$  pasiskirstymas, tik antruoju atveju su  $n$  laisvės laipsnių, o pirmuoju – su  $n - 1$  laisvės laipsnių.

Ieškant pasikliautinųjų intervalų, tenka naudotis  $\chi^2$  ir Stjudento pasiskirstymų lentelėmis (žr. [17], III, IV, V lentelės), kurios yra sudarytos tik nedideliems  $n$ . Jau matėme, kad  $\chi^2$  pasiskirstymą dideliems  $n$  galima aproksimuoti normaliuoju pasiskirstymu. Taip yra ir su Stjudento pasiskirstymu. Šio dėsnio su  $n$  laisvės laipsnių tankio funkcija (žr. III.9.4 pavyzdį) yra

$$p_{St_n}(y) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{\frac{n}{2}}\Gamma\left(\frac{n}{2}\right)} \cdot \frac{1}{\sqrt{2\pi}} \left(1 + \frac{y^2}{n}\right)^{-(n+1)/2}.$$

Pagal Stirlingo formulę pirmasis dauginamasis konverguoja į 1, kai  $n \rightarrow \infty$ . Bet kuriam fiksuotam  $y$

$$-\frac{n+1}{2} \ln\left(1 + \frac{y^2}{n}\right) \rightarrow -\frac{y^2}{2},$$

vadinas,

$$p_{St_n}(y) \rightarrow \frac{1}{\sqrt{2\pi}} e^{-y^2/2}.$$

Toliau

$$(1 + y^2/n)^{(n+1)/2} \geq (1 + y^2/n)^{[(n+1)/2]} \geq 1 + [(n+1)/2]y^2/n \geq 1 + y^2/2.$$

Todėl funkcija  $p_{St_n}(y)$  yra mažoruoji funkcija

$$C(1 + y^2/2)^{-1}.$$

Pasirėmę V.9.16 teorema, gauname

$$\int_{-\infty}^u p_{St_n}(y) dy \rightarrow \frac{1}{\sqrt{2\pi}} \int_{-\infty}^u e^{-y^2/2} dy = \Phi(u),$$

kai  $n \rightarrow \infty$ .

Ši teiginį galima ir kitaip įrodyti. III.9.4 pavyzdyje atsitiktinis dydis, pasiskirstęs pagal Stjudento dėsnį, buvo nusakytas kaip dviejų nepriklausomų atsitiktinių dydžių santykis. Skaitiklyje buvo atsitiktinis dydis, pasiskirstęs pagal  $N(0, 1)$ , o vardiklyje – kvadratinė šaknis iš vienodai pasiskirsčiusių nepriklausomų atsitiktinių dydžių aritmetinio vidurkio. Iš Činčino teoremos išplaukia, kad vardiklyje esančio atsitiktinio dydžio pasiskirstymas konverguoja į vienetinį pasiskirstymą  $\varepsilon(y)$ . Iš čia išplaukia, kad minėtųjų atsitiktinių dydžių santykis yra pasiskirstęs pagal  $N(0, 1)$  (įrodykite!).

4. Iki šiol nagrinėjome normaliojo pasiskirstymo parametrų įvertinimą. Analogiškas teorijas galima sukurti ir kai kuriems kitiems pasiskirstymams. Tačiau, kai eksperimento sąlygos leidžia turėti daug stebėjimo duomenų, dažnai jų pasiskirstymas mažai skiriasi nuo normaliojo.

Tarkime, kad stebimasis atsitiktinis dydis turi nežinomą vidurkį  $a \in R$  ir žinomą dispersiją  $\sigma^2$ . Iš centrinės ribinės teoremos (III.11.2 teoremos 2 išvada) išplaukia, kad normuotos sumos

$$(\bar{X} - a)\sqrt{n}/\sigma$$

pasiskirstymas konverguoja į standartinį normalųjį pasiskirstymą. Vadinas,

$$\alpha = \mathcal{P}_a(-u < (\bar{X} - a)\sqrt{n}/\sigma < u) \approx \sqrt{\frac{2}{\pi}} \int_0^u e^{-y^2/2} dy,$$

kai  $n$  yra pakankamai didelis. Pasirinkę pasiklovimo tikimybę  $\alpha$ , iš tos apytikslės lygybės apskaičiuojame apytikslę  $u = u(\alpha)$  reikšmę ir gauname nežinomo vidurkio pasikliautinąjį intervalą

$$\left(\bar{X} - \frac{\sigma u}{\sqrt{n}}, \bar{X} + \frac{\sigma u}{\sqrt{n}}\right).$$

Jei dispersija  $\sigma^2 > 0$  yra nežinoma, tai šiuose įvertinimuose  $\sigma^2$  reikia pakeisti  $S_1^2$  arba  $S^2$ . Galima įrodyti, kad dideliems  $n$  statistika  $(\bar{X} - a)\sqrt{n}/S_1$  yra apytiksliai pasiskirsčiusi pagal  $N(0, 1)$  (priminsime, kad ir Stjudento pasiskirstymas, kai laisvės laipsnių skaičius yra didelis, mažai skiriasi nuo  $N(0, 1)$ ). Pasirinkę  $\alpha$ , randame  $u = u(\alpha)$  iš apytikslės lygybės

$$\alpha = \mathcal{P}_{(a, \sigma)}(-u < (\bar{X} - a)\sqrt{n}/S_1 < u) \approx \sqrt{\frac{2}{\pi}} \int_0^u e^{-y^2/2} dy$$

ir sudarome nežinomo vidurkio pasikliautinąjį intervalą

$$\left(\bar{X} - \frac{S_1 u}{\sqrt{n}}, \bar{X} + \frac{S_1 u}{\sqrt{n}}\right).$$

5. Baigdami paminėsime dar vieną praktiškai svarbų pasikliautiniųjų intervalų sudarymo metodą. Tarkime, kad nežinomam parametrui  $\theta$  įvertinti naudojamos statistika  $T(X)$ , gauta didžiausio tikėtimumo metodu. Kai tenkinamos gana bendros sąlygos, atsitiktinis dydis  $(T(X) - \theta)/D_\theta^{1/2}T(X)$  yra asimptotiškai pasiskirstęs pagal normalųjį dėsnį  $N(0, 1)$ . Paėmę  $\alpha$ , iš apytikslės lygties

$$\alpha = \mathcal{P}_\theta(-u < \frac{T(X) - \theta}{\sqrt{D_\theta T(X)}} < u) \approx \sqrt{\frac{2}{n}} \int_0^u e^{-y^2/2} dy$$

randame  $u = u(\alpha)$  ir sudarome parametro  $\theta$  pasikliautinąjį intervalą

$$(T(X) - u(\alpha)\sqrt{D_\theta T(X)}, T(X) + u(\alpha)\sqrt{D_\theta T(X)}).$$

P a v y z d y s. Fabriko cechą gamina kokias nors detales. Iš jo vienos dienos produkcijos atsitiktinai parenkame detalę, ją pasveriamo ir gražiname atgal. Po 24 svėrimų gavome šitokius rezultatus (sakysime, gramais):

2,1 2,3 1,9 2,0 2,1 2,2 1,8 1,7 2,1 2,2 1,9 2,0  
1,9 2,1 1,8 2,0 1,9 2,2 2,1 2,3 1,9 2,1 2,2 2,0

Laikydami, kad detalių svoris pasiskirstęs pagal normalųjį dėsnį, įvertinsime jo vidurkį ir dispersiją.

Turime

$$\bar{x} \approx 2,0333, s^2 \approx 0,0247, s_1^2 \approx 0,0258.$$

Paėmę  $\alpha' = \alpha'' = 0,98$ , iš Stjudento pasiskirstymo lentelių (su 23 laisvės laipsniais) randame

$$u_1 = -u_2 \approx 2,4999,$$

o iš  $\chi^2$  lentelių (su 23 laisvės laipsniais)

$$v_1 \approx 41,638, \quad v_2 \approx 10,196.$$

Vidurkio pasikliautinojo intervalo galai yra

$$\bar{x} - \frac{u_1 s_1}{\sqrt{23}} \approx 1,9496, \quad \bar{x} + \frac{u_1 s_1}{\sqrt{23}} \approx 2,1170,$$

o dispersijos

$$\frac{24s^2}{v_1} \approx 0,0142, \quad \frac{24s^2}{v_2} \approx 0,0581.$$

## 9. STATISTINIŲ HIPOTEZIŲ TIKRINIMAS

Ši uždavinį jau formulavome 1 skyrelyje. Priminsime, kad statistinėmis vadiname hipotezes apie stebimojo atsitiktinio dydžio arba kelių dydžių pasiskirstymą. Statistinės bus, pavyzdžiui, hipotezės: stebimasis atsitiktinis dydis yra pasiskirstęs pagal normalųjį dėsnį, dviejų atsitiktinių dydžių vidurkiai yra lygūs, vieno atsitiktinio dydžio dispersija yra didesnė negu kito.

Su tokiais uždaviniais dažnai susiduriame praktikoje. Sakysime, kokiai nors ligai gydyti yra vartojami žinomi vaistai. Rasti nauji vaistai. Ar jie bus efektyvesni už senesius? Fabrikas gamina elektros lemputes. Siūloma pakeisti technologinį procesą. Ar nauju būdu pagamintos lemputės degs ilgiau?

Sakykime, turime pasiskirstymų klasę  $\{P_\theta, \theta \in \Theta\}$  ir  $\Theta_0$  yra aibės  $\Theta$  poaibis. Statistinė hipotezė bus teiginys, kad stebimojo atsitiktinio dydžio pasiskirstymas  $P_\theta$  priklauso klasei  $\{P_\theta, \theta \in \Theta_0\}$ , kitaip tariant  $\theta \in \Theta_0$ . Tikrinamoji hipotezė paprastai vadinama *pagrindine*, arba *nuline*, ir žymima  $H_0$ . Kartu nagrinėjama ir priešinga jai hipotezė  $H_1$ . Ji vadinama *konkuruojančia*, arba *alternatyviaja*, hipoteze, arba tiesiog *alternatyva*. Tai bus teiginys, kad  $\theta \in \Theta_1 = \Theta \setminus \Theta_0$ . Jei aibė  $\Theta_0$  yra sudaryta iš vieno taško, tai hipotezė vadinama *paprastąja*. Priešingu atveju ji vadinama *sudėtingąja*.

Jei, pavyzdžiui, turime klasę normaliųjų pasiskirstymų su žinomomis dispersijomis, bet nežinomais vidurkiais  $a \in \mathcal{R}$ , tai teiginys, kad stebimojo dydžio vidurkis  $a = 5$ , yra paprastoji hipotezė, o jos alternatyva yra teiginys  $a \neq 5$ . Teiginys  $a > 5$  yra sudėtingoji hipotezė.

Matematinė statistika nagrinėja kriterijus arba testus, kurie leistų spręsti, ar stebėjimo duomenys suderinami su nuline hipoteze.

Kriterijų sudarymo idėja šitokia. Erdvę  $R^n$  suskaidome į dvi sritis – Borelio aibes:  $R_0$  ir  $R_1 = R^n \setminus R_0$ . Sritį  $R_1$  parenkame taip, kad tikimybės imčiai  $X = (X_1, \dots, X_n)$  patekti į tą sritį, kai hipotezė  $H_0$  yra teisinga,

$$\mathcal{P}_\theta(X \in R_1), \quad \theta \in \Theta_0,$$

būtų mažos. Susitariame, kad hipotezė  $H_0$  nesuderinama su stebėjimo duomenimis ir todėl yra atmestina, kai  $x \in R_1$ . Ši sritis paprastai vadinama *kritine*.

Jei  $x \in R_0$ , tai laikome hipotezę  $H_0$  suderinama su stebėjimo duomenimis ir todėl priimtina.

Ši procedūra negarantuoja, kad padarytoji išvada bus visada teisinga. Mes galime tik teigti, kad ji bus teisinga su tam tikra tikimybe. Jei tikimybės  $\mathcal{P}_\theta(X \in R_1)$ ,  $\theta \in \Theta_0$ , yra mažos, tai praktiškai labai retai atmesime hipotezę  $H_0$ , kai ji teisinga. Sakysime, jei tos tikimybės ne didesnės kaip 0,01, tai vidutiniškai ne daugiau kaip vieną kartą iš 100 atmesime teisingą hipotezę.

Naudodamiesi statistiniu kriterijumi, galime padaryti dviejų rūšių klaidas: atmesti, kaip jau minėjome, hipotezę  $H_0$ , kai ji yra teisinga (*pirmosios rūšies klaida*), arba priimti  $H_0$ , nors ji klaidinga (*antrosios rūšies klaida*). Galimi atvejai nurodyti lentelėje.

	Išvada	
	Priimta $H_0$	Atmesta $H_0$
$H_0$ teisinga	Teisingai	I rūšies klaida
$H_0$ klaidinga	II rūšies klaida	Teisingai

Geriausia būtų kriterijus sudaryti taip, kad abiejų rūšių klaidų tikimybės būtų minimalios. Deja, kai stebėjimų skaičius yra ribotas, to padaryti negalima. Praplėtus kritinę sritį, antrosios rūšies klaidos tikimybė sumažės, bet padidės pirmosios rūšies klaidos tikimybė, ir atvirkščiai. Todėl paprastai parenkamas rėžis, kurio neturėtų viršyti pirmosios rūšies klaidos tikimybė, ir stengiamasi minimizuoti antrosios rūšies klaidos tikimybę. Kitaip tariant, parenkamas nedidelis skaičius  $\alpha \in (0, 1)$ , vadinamas *reikšmingumo lygmeniu*, ir reikalaujama, kad pirmosios rūšies klaidos tikimybė būtų ne didesnė už tą skaičių

$$\sup_{\theta \in \Theta_0} \mathcal{P}_\theta(X \in R_1) \leq \alpha,$$

o antrosios rūšies klaidos tikimybė

$$\mathcal{P}_\theta(X \in R_0), \theta \in \Theta_1,$$

būtų kiek galima mažesnė, t. y. tikimybė

$$\beta(\theta) = \mathcal{P}_\theta(X \in R_1) = 1 - \mathcal{P}_\theta(X \in R_0), \theta \in \Theta_1,$$

vadinama *kriterijaus galia*, kiek galima didesnė. Ši tikimybė, traktuojama kaip  $\theta$  funkcija visiems  $\theta \in \Theta$ , yra vadinama *kriterijaus galios funkcija*.  $\beta(\theta)$  reiškia tikimybę atmesti hipotezę  $H_0$ , kai tikroji parametro reikšmė yra  $\theta$ .

Tarkime, kad turime du kriterijus su kritinėmis sritimis  $R_1$  ir  $R'_1$ , turinčius tą patį reikšmingumo lygmenį. Kriterijus su kritine sritimi  $R_1$  vadinamas *tolygiai galingesniu* už kriterijų su kritine sritimi  $R'_1$ , jei

$$\mathcal{P}_\theta(X \in R_1) \leq \mathcal{P}_\theta(X \in R'_1), \quad \theta \in \Theta_0,$$

$$\mathcal{P}_\theta(X \in R_1) \geq \mathcal{P}_\theta(X \in R'_1), \quad \theta \in \Theta_1.$$

Kriterijų su kritine sritimi  $R_1$  ir reikšmingumo lygmeniu  $\alpha$  vadiname *tolygiai galingiausiu*, jei

$$\sup_{R'_1} \mathcal{P}_\theta(X \in R'_1) = \mathcal{P}_\theta(X \in R_1), \quad \theta \in \Theta_1;$$

čia supremumas imamas pagal visas kritines sritis  $R'_1$  su reikšmingumo lygmeniu  $\alpha$ . Kai alternatyva yra paprastoji ( $\Theta_1$  turi tik vieną elementą), tolygiai galingiausią kriterijų vadiname tiesiog galingiausiu.

## 10. FUNDAMENTALIOJI NEIMANO–PIRSONO

### LEMA

Praeitame skyrelyje nagrinėtus statistinius kriterijus galime aprašyti šitokiu būdu. Kiekvienam  $x \in R^n$  apibrėžiame funkciją  $\psi(x)$ , įgyjančią dvi reikšmes: 0 ir 1, ir susitariame tikrinamąją hipotezę atmesti, kai imčiai  $x$  ta funkcija įgyja reikšmę 1, arba priimti, kai ji įgyja reikšmę 0. Jei  $\psi(x)$  yra Borelio funkcija, tai ji nusako erdvėje  $R^n$  dvi sritis: kritinę sritį  $R_1 = \{x : \psi(x) = 1\}$  ir jos papildomąją sritį  $R_0 = \{x : \psi(x) = 0\}$ .

Praplėsime funkcijų  $\psi$  klasę, nagrinėdami Borelio funkcijas, apibrėžtas erdvėje  $R^n$  ir galinčias įgyti reikšmes iš intervalo  $[0, 1]$ . Paėmę tokią funkciją, sudarysime naujo tipo kriterijų. Kai imčiai  $x$  turime  $\psi(x) = 1$  arba  $\psi(x) = 0$ , tai, kaip ir anksčiau, hipotezę  $H_0$  atmetame arba priimame. Jei  $0 < \psi(x) < 1$ , tai hipotezę  $H_0$  su tikimybe  $\psi(x)$  atmetame ir su tikimybe  $1 - \psi(x)$  priimame. Tą procedūrą galima interpretuoti šitaip: kiekvienai imčiai  $x$  atliekame atsitiktinį eksperimentą su dviem galimais rezultatais, kurių tikimybės yra  $\psi(x)$  ir  $1 - \psi(x)$ . Gavę pirmąjį rezultatą, hipotezę atmetame, gavę antrąjį – priimame.

Tokius kriterijus vadiname *randomizuotais* (nuo anglų kalbos žodžio *random* – atsitiktinis). 9 skyrelyje nagrinėti kriterijai vadinami *nerandomizuotais* arba *determinuotais*.

Funkciją

$$\beta(\theta) = \beta(\theta, \psi) = M_\theta \psi(X), \quad \theta \in \Theta,$$

vadinsime randomizuoto kriterijaus *galios funkcija*. Uždavinys yra rasti tokias funkcijas  $\psi$ , kad galia būtų didžiausia visiems  $\theta \in \Theta_1$ , kai  $M_\theta \psi(X) \leq \alpha$  visiems  $\theta \in \Theta_0$ .

Toliau nagrinėsime tik atvejį, kai hipotezė ir jos alternatyva yra paprastosios, t. y.  $\Theta_0 = \{\theta_0\}$ ,  $\Theta_1 = \{\theta_1\}$ . Pažymėkime  $K_\alpha$  klasę funkcijų  $\psi$ , kurioms pirmosios rūšies klaidos tikimybė yra ne didesnė už  $\alpha$ :

### 302 Matematinės statistikos pradmenys

$$K_\alpha = \{\psi : M_{\theta_0}\psi(X) \leq \alpha\}.$$

Kriterijų su funkcija  $\psi^* \in K_\alpha$  vadinsime *galingiausiu*, jei

$$\beta(\theta_1, \psi^*) = \sup_{\psi \in K_\alpha} \beta(\theta_1, \psi),$$

kitaip tariant, jei antrosios rūšies klaidos tikimybė tenkina sąlygą

$$M_{\theta_1}(1 - \psi^*(X)) = \inf_{\psi \in K_\alpha} M_{\theta_1}(1 - \psi(X)).$$

Laikysime, kad pasiskirstymus  $\mathcal{P}_{\theta_k}$  ( $k = 0, 1$ ) dominuoja matas  $\mu$  su tankio funkcijomis  $\mathbf{p}_{\theta_k}(x) = p_{\theta_k}(x_1) \dots p_{\theta_k}(x_n)$  ( $k = 0, 1$ ).

Parodysime, kad galingiausias kriterijus egzistuoja ir rasime jo pavidalą.

**Teorema (fundamentalioji Neimano–Pirsono lema).** *Kiekvienam  $\alpha \in (0, 1)$  galima rasti tokias konstantas  $c = c_\alpha$  ir  $h = h_\alpha$ , kad funkcijai*

$$\psi^*(x) = \begin{cases} 1, & \text{kai } \mathbf{p}_{\theta_1}(x) > h\mathbf{p}_{\theta_0}(x), \\ c, & \text{kai } \mathbf{p}_{\theta_1}(x) = h\mathbf{p}_{\theta_0}(x), \\ 0, & \text{kai } \mathbf{p}_{\theta_1}(x) < h\mathbf{p}_{\theta_0}(x), \end{cases}$$

būtų teisinga lygybė

$$M_{\theta_0}\psi^*(X) = \alpha$$

ir ja pagrįstas kriterijus būtų galingiausias tarp klasės  $K_\alpha$  funkcijas atitinkančių kriterijų.

I r o d y m a s. 1. Nagrinėkime funkciją

$$w(h) = \mathcal{P}_{\theta_0}(\mathbf{p}_{\theta_1}(X) > h\mathbf{p}_{\theta_0}(X)) = \int_{\{x: \mathbf{p}_{\theta_1}(x) > h\mathbf{p}_{\theta_0}(x)\}} \mathbf{p}_{\theta_0}(x)\mu(dx).$$

Ši funkcija yra nedidėjanti, tolydi iš dešinės,  $w(h) = 1$ , kai  $h < 0$ , ir  $w(h) \rightarrow 0$ , kai  $h \rightarrow \infty$ .

Kai  $\alpha \in (0, 1)$ , pažymėkime  $h_\alpha$  mažiausią  $h$ , kuriam

$$w(h) \leq \alpha \leq w(h - 0).$$

Jei  $w(h_\alpha - 0) - w(h_\alpha) > 0$ , imkime

$$c_\alpha = \frac{\alpha - w(h_\alpha)}{w(h_\alpha - 0) - w(h_\alpha)}.$$

Jei  $w(h_\alpha - 0) - w(h_\alpha) = 0$ , tai imkime  $c_\alpha = 1$ . Apskaičiuosime

$$M_{\theta_0}\psi^*(X) = \int_{R^n} \psi^*(x)\mathbf{p}_{\theta_0}(x)\mu(dx).$$

Integravimo sritį galime suskaidyti į tris viena kitos nedengiančias sritis  $\{x : \mathbf{p}_{\theta_1}(x) > h_\alpha \mathbf{p}_{\theta_0}(x)\}$ ,  $\{x : \mathbf{p}_{\theta_1}(x) = h_\alpha \mathbf{p}_{\theta_0}(x)\}$ ,  $\{x : \mathbf{p}_{\theta_1}(x) < h_\alpha \mathbf{p}_{\theta_0}(x)\}$ . Pirmojoje srityje integralas lygus  $w(h_\alpha)$ , antrojoje  $c_\alpha(w(h_\alpha - 0) - w(h_\alpha))$ , trečiojoje 0. Taigi

$$(1) \quad M_{\theta_0} \psi^*(X) = w(h_\alpha) + c_\alpha(w(h_\alpha - 0) - w(h_\alpha)) = \alpha.$$

2. Tarkime, kad  $\psi$  yra bet kuri klasės  $K_\alpha$  funkcija. Parodysime, kad

$$M_{\theta_1} \psi^*(X) - M_{\theta_1} \psi(X) = \int_{R^n} (\psi^*(x) - \psi(x)) \mathbf{p}_{\theta_1}(x) \mu(dx) \geq 0.$$

Imame integralą

$$\begin{aligned} & \int_{R^n} (\psi^*(x) - \psi(x)) (\mathbf{p}_{\theta_1}(x) - h_\alpha \mathbf{p}_{\theta_0}(x)) \mu(dx) = \\ & = \int_{\{x: \psi^*(x) > \psi(x)\}} + \int_{\{x: \psi^*(x) < \psi(x)\}}. \end{aligned}$$

Pirmajame integrale funkcija  $\psi^*(x) > 0$ , todėl pagal jos apibrėžimą  $\mathbf{p}_{\theta_1}(x) - h_\alpha \mathbf{p}_{\theta_0}(x) \geq 0$ . Iš čia išplaukia, kad tas integralas yra neneigiamas. Visai taip pat antrajame integrale funkcija  $\mathbf{p}_{\theta_1}(x) - h_\alpha \mathbf{p}_{\theta_0}(x) \leq 0$ ; todėl ir tas integralas yra neneigiamas. Iš čia

$$\begin{aligned} & \int_{R^n} (\psi^*(x) - \psi(x)) \mathbf{p}_{\theta_1}(x) \mu(dx) \geq \\ & \geq h_\alpha \int_{R^n} (\psi^*(x) - \psi(x)) \mathbf{p}_{\theta_0}(x) \mu(dx) = \\ & = h_\alpha (M_{\theta_0} \psi^*(X) - M_{\theta_0} \psi(X)). \end{aligned}$$

Remiantis klasės  $K_\alpha$  apibrėžimu ir (1) lygybe, šis reiškinys yra neneigiamas.  $\square$

Įrodinėdami kriterijaus su funkcija  $\psi^*$  galingumą klasėje  $K_\alpha$ , rėmėmės savybe, kad to kriterijaus pirmosios rūšies klaidos tikimybė yra  $\alpha$ . Tarp randomizuotų kriterijų toks kriterijus visada egzistuoja. Jei apsiribotume nerandomizuotais kriterijais, tai ne kiekvienam  $\alpha$  būtų galima rasti tokį  $h$ , kad funkciją

$$(2) \quad \hat{\psi}(x) = \begin{cases} 1, & \text{kai } \mathbf{p}_{\theta_1}(x) \geq h \mathbf{p}_{\theta_0}(x), \\ 0, & \text{kai } \mathbf{p}_{\theta_1}(x) < h \mathbf{p}_{\theta_0}(x), \end{cases}$$

atitinkančio kriterijaus pirmosios rūšies klaidos tikimybė būtų lygi  $\alpha$ . Jei kuriam nors  $\alpha$  tokį  $h$  galima rasti, tai kriterijus su funkcija  $\hat{\psi}$  bus galiausias klasėje  $K_\alpha$ .

Jei funkcija  $w(h)$  yra tolydi, tai galingiausias kriterijus bus nerandomizuotas visiems  $\alpha \in (0, 1)$ ; jį atitinkanti funkcija bus (2) pavidalo.

Jei kuriam nors  $\alpha$  funkcija  $w(h)$  taške  $h_\alpha$  yra tolydi:  $w(h_\alpha - 0) = w(h_\alpha)$ , tai galingiausias kriterijus bus taip pat nerandomizuotas. Vadinasi, jei duotas kuris nors reikšmingumo lygmuo  $\alpha$ , tai, pakeitę jį siek tiek mažesniu (sakysime, skaičiumi  $w(h_\alpha) - \varepsilon$ ), gausime nerandomizuotą kriterijų. Toks pakeitimas sumažina pirmosios rūšies klaidos tikimybę, bet padidina antrosios rūšies klaidos tikimybę. Tačiau taip keisti apsimoka, nes nerandomizuoti kriterijai yra paprastesni už randomizuotus.

Pastebėsime, kad galingiausias kriterijus yra pagrįstas funkcija

$$\frac{\mathbf{p}_{\theta_1}(x)}{\mathbf{p}_{\theta_0}(x)} = \frac{p_{\theta_1}(x_1) \dots p_{\theta_1}(x_n)}{p_{\theta_0}(x_1) \dots p_{\theta_0}(x_n)},$$

t. y. tikėtinumo funkcijų realizacijų santykiu. Dažnai patogiu imti jos logaritmą

$$z = z(x) = \sum_{k=1}^n \ln \frac{p_{\theta_1}(x_k)}{p_{\theta_0}(x_k)}$$

ir funkciją  $\psi^*$  užrašyti šitaip:

$$\psi^*(x) = \begin{cases} 1, & \text{kai } z(x) > d_\alpha, \\ c_\alpha, & \text{kai } z(x) = d_\alpha, \\ 0, & \text{kai } z(x) < d_\alpha. \end{cases}$$

## 11. HIPOTEZIŲ APIE PASISKIRSTYMO PARAMETRUS TIKRINIMAS

Keliais pavyzdžiais parodysime, kaip sudaromi kriterijai statistinėms hipotezėms apie pasiskirstymo parametrus tikrinti. Remsimės 10 skyrelyje išdėstyta teorija.

1. Sakykime, turime normalųjį pasiskirstymą su nežinomu viidurkiu  $a \in R$ , bet žinoma dispersija  $\sigma^2$ , ir reikia patikrinti hipotezę  $H_0$ , kad  $a = a_0$ , kai alternatyva yra  $a = a_1 > a_0$  (nepainioti  $a_1$  su empiriniu vidurkiu!). Tikėtinumo funkcijų realizacijų santykio logaritmo pagrindinis narys yra lygus

$$\begin{aligned} & -\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - a_1)^2 + \frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - a_0)^2 = \\ & = n(a_1 - a_0)\bar{x}/\sigma^2 + \frac{1}{2}n(a_1^2 - a_0^2)/\sigma^2. \end{aligned}$$

Šiuo atveju funkcija  $w(h)$  yra tolydi. Todėl galėsime sudaryti galingiausią nerandomizuotą kriterijų. Kritinė sritis bus pavidalo

$$(\bar{x} - a_0)\sqrt{n}/\sigma \geq u.$$

Jei hipotezė  $H_0$  yra teisinga, tai statistika  $(\bar{X} - a_0)\sqrt{n}/\sigma$ , kaip žinome iš 8 skyrelio, yra pasiskirsčiusi pagal  $N(0, 1)$ . Pirmosios rūšies klaidos tikimybė

$$(1) \quad \alpha = \mathcal{P}_{a_0}((\bar{X} - a_0)\sqrt{n}/\sigma \geq u) = \frac{1}{\sqrt{2\pi}} \int_u^\infty e^{-v^2/2} dv = 1 - \Phi(u).$$

Iš šios lygybės randame  $u = u_\alpha$ ; jis yra standartinio normaliojo pasiskirstymo  $(1 - \alpha)$ -kvantilis. Kriterijaus galia

$$\begin{aligned} \beta(a_1) &= \mathcal{P}_{a_1}((\bar{X} - a_0)\sqrt{n}/\sigma \geq u_\alpha) = \mathcal{P}_{a_1}((\bar{X} - a_1)\sqrt{n}/\sigma \geq \\ &\geq u_\alpha + (a_0 - a_1)\sqrt{n}/\sigma) = 1 - \Phi(u_\alpha + (a_0 - a_1)\sqrt{n}/\sigma). \end{aligned}$$

Matome, kad tikimybė atmesti  $H_0$  yra lygi kriterijaus reikšmingumo lygmeniui, kai  $a = a_0$ , ir monotoniškai artėja prie 1, kai  $a_1 \rightarrow \infty$ . Iš čia taip pat matome, kad, paėmę pakankamai didelį  $n$ , kriterijaus galią galime padaryti kiek norima artimą 1. Galios funkcijos grafikas pavaizduotas 34 paveiksle.

Kritinės srities pavidalas nepriklauso nuo alternatyvos  $a = a_1$ . Todėl gautasis kriterijus yra tolygiai galingiausias, kai alternatyva yra sudėtinga:  $\Theta_1 = \{a : a > a_0\}$ .

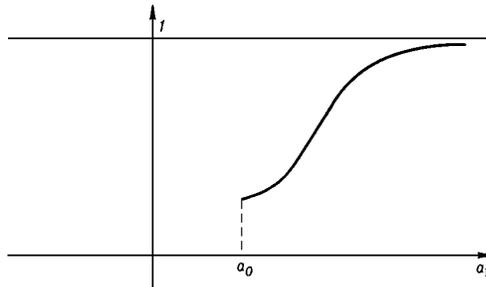
Jei alternatyva yra  $a = a_1 < a_0$ , tai hipotezę atmetame, kai konkreti imtis tenkina nelygybę

$$(\bar{x} - a_0)\sqrt{n}/\sigma \leq u.$$

Skaičių  $u = u_\alpha$  randame iš lygties

$$(2) \quad \alpha = \Phi(u);$$

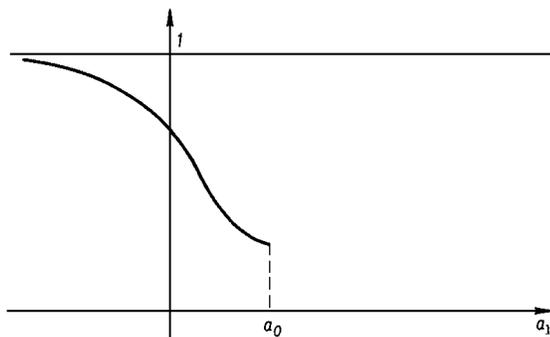
jis yra  $\alpha$ -kvantilis. Kriterijaus galia



34 pav.

$$\begin{aligned}\beta(a_1) &= \mathcal{P}_{a_1}((\bar{X} - a_0)\sqrt{n}/\sigma \leq u) = \mathcal{P}_{a_1}((\bar{X} - a_1)\sqrt{n}/\sigma \leq \\ &\leq u_\alpha + (a_0 - a_1)\sqrt{n}/\sigma) = \Phi(u_\alpha + (a_0 - a_1)\sqrt{n}/\sigma).\end{aligned}$$

Galios funkcijos grafikas pavaizduotas 35 paveiksle.



35 pav.

Ir šis kriterijus yra tolygiai galingiausias, kai turime sudėtingą alternatyvą  $\Theta_1 = \{a : a < a_0\}$ .

Panagrinėkime alternatyvą  $a = a_1 \neq a_0$ . Hipotezę atmetame, kai konkreti imtis tenkina nelygybę

$$|\bar{x} - a_0|\sqrt{n}/\sigma \geq u.$$

Skaičių  $u = u_\alpha$  rasime iš lygties

$$(3) \quad \begin{aligned} \alpha &= \mathcal{P}_{a_0}(|\bar{X} - a_0|\sqrt{n}/\sigma \geq u) = \\ &= \frac{1}{\sqrt{2\pi}} \int_{|y| \geq u} e^{-v^2/2} dv = \Phi(-u) + 1 - \Phi(u) = 2(1 - \Phi(u)); \end{aligned}$$

jis yra  $(1 - \alpha/2)$ -kvantilis. Galios funkcija

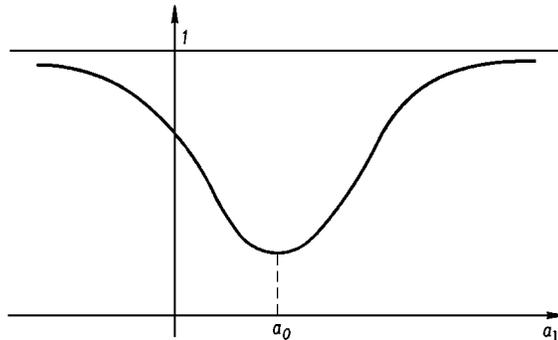
$$\beta(a_1) = \Phi(-u_\alpha + (a_0 - a_1)\sqrt{n}/\sigma) + 1 - \Phi(u_\alpha + (a_0 - a_1)\sqrt{n}/\sigma).$$

Jos grafikas pavaizduotas 36 paveiksle.

Šis kriterijus nėra tolygiai galingiausias sudėtingai alternatyvai  $\Theta_1 = \{a : a \neq a_0\}$ . Iš tikrųjų galingiausio paprastajai alternatyvai  $a = a_1 \neq a_0$  kriterijaus kritinė sritis priklauso nuo  $a_1$  (ji yra vienokia, kai  $a_1 < a_0$ , ir kitokia, kai  $a_1 > a_0$ ).

Paskutinįjį iš nagrinėtų kriterijų galima būtų pavadinti dvipusiu, o pirmuosius du – vienpusiais: dešiniapusiu ir kairiapusiu.

Jei pasiskirstymas nėra normalusis, bet turi žinomą dispersiją  $\sigma^2$ , tai galime pasinaudoti statistikos  $(\bar{X} - a)\sqrt{n}/\sigma$  asimptotiniu normalumu. Hipotezei  $a = a_0$  su atitinkamomis alternatyvomis kriterijų kritinės sritys gali būti sudarytos taip pat, kaip ir turint normalųjį pasiskirstymą, tik (1), (2), (3) lygtis skaičiams  $u_\alpha$  rasti reikėtų pakeisti apytikslėmis lygtimis, tuo tikslėnėmis, kuo didesnis  $n$ .



36 pav.

2. Tarkime, kad stebimasis atsitiktinis dydis įgyja dvi reikšmes: 1 ir 0 su tikimybėmis atitinkamai  $p$  ir  $1 - p$ . Tikimybė  $p \in (0, 1)$  yra n e ž i n o m a. Reikia patikrinti hipotezę  $p = p_0$ , kai alternatyva yra  $p = p_1 < p_0$ . Tikėtinumo funkcijų realizacijų santykis yra

$$\prod_{k=1}^n \left(\frac{p_1}{p_0}\right)^{x_k} \left(\frac{1-p_1}{1-p_0}\right)^{1-x_k},$$

o jo logaritmas

$$\kappa_n \ln \frac{1/p_0 - 1}{1/p_1 - 1} + n \ln \frac{1 - p_1}{1 - p_0};$$

čia  $\kappa_n = x_1 + \dots + x_n$  yra sveikasis neneigiamas skaičius, o jo koeficientas – neigiamas. Todėl funkcija  $\psi^*$  yra šitokio pavidalo:

$$\psi^*(x) = \begin{cases} 1, & \text{kai } \kappa_n < m, \\ c, & \text{kai } \kappa_n = m, \\ 0, & \text{kai } \kappa_n > m. \end{cases}$$

Tarkime, kad reikšmingumo lygmuo yra  $\alpha$ . Pirmosios rūšies klaidos tikimybė turi būti

$$\alpha = c\mathcal{P}_{p_0}(X_1 + \dots + X_n = m) + \sum_{k < m} \mathcal{P}_{p_0}(X_1 + \dots + X_n = k).$$

Iš čia reikia rasti  $c = c_\alpha$  ir  $m = m_\alpha$ . Kadangi statistika  $X_1 + \dots + X_n$ , kai teisinga nulinė hipotezė, yra pasiskirsčiusi pagal binominį dėsnį su  $p = p_0$ , tai

$$\mathcal{P}_{p_0}(X_1 + \dots + X_n = k) = \binom{n}{k} p_0^k (1 - p_0)^{n-k}.$$

Jei egzistuoja toks sveikasis  $m$ , kad

$$\sum_{k=0}^m \binom{n}{k} p_0^k (1 - p_0)^{n-k} = \alpha,$$

tai jį ir laikome  $m_\alpha$ ; tada  $c_\alpha$  imame lygų 1. Gauname galingiausią nerandomizuotą kriterijų. Jei tokio sveikojo  $m$  nėra, tai parenkame sveiką  $m_\alpha$  su sąlyga

$$\sum_{k=0}^{m_\alpha-1} \binom{n}{k} p_0 (1 - p_0)^{n-k} < \alpha < \sum_{k=0}^{m_\alpha} \binom{n}{k} p_0 (1 - p_0)^{n-k}.$$

Tada

$$c_\alpha = \frac{\alpha - \sum_{k=0}^{m_\alpha-1} \binom{n}{k} p_0^k (1 - p_0)^{n-k}}{\binom{n}{m_\alpha} p_0^{m_\alpha} (1 - p_0)^{n-m_\alpha}}.$$

Vėl gauname galingiausią, tačiau randomizuotą kriterijų.

Kritiškosios srities pavidalas nepriklauso nuo alternatyvos  $p = p_1$ . Todėl gautasis kriterijus yra tolygiai galingiausias, kai alternatyva yra sudėtinga:  $\Theta_1 = \{p : p < p_0\}$ .

Praktiškai abiem atvejais, kaip buvo rašyta 10 skyrelyje, vartojamas nerandomizuotas kriterijus su funkcija

$$\hat{\psi}(x) = \begin{cases} 1, & \text{kai } \kappa_n \leq m, \\ 0, & \text{kai } \kappa_n > m. \end{cases}$$

Paliekame skaitytojui užrašyti galios funkciją bei išnagrinėti atvejus, kai alternatyva yra  $p = p_1 > p_0$  arba  $p = p_1 \neq p_0$ .

1 p a v y z d y s. Laboratorijoje tiriami nauji vaistai kuriai nors ligai gydyti. Vaistų atradėjai teigia, kad jie efektyvūs 80% atvejų. Laboratorijoje vaistus tikrino 7 kartus, ir 4 kartus jie buvo efektyvūs. Patikrinsime, ar šie duomenys atitinka atradėjų teiginį, kai reikšmingumo lygmuo  $\alpha = 0,1$ .

Tikrinsime hipotezę  $H_0 : p = 0,8$ , kai alternatyva yra  $H_1 : p = p_1 < 0,8$ .

Nesunku suskaičiuoti, kad

$$\sum_{k=0}^3 \binom{7}{k} 0,8^k \cdot 0,2^{7-k} \approx 0,033$$

ir

$$\binom{7}{4} 0,8^4 \cdot 0,2^3 \approx 0,115, \quad \sum_{k=0}^4 \binom{7}{k} 0,8^k \cdot 0,2^{7-k} \approx 0,148.$$

Todėl  $m_{0,1} = 4$  ir  $c_{0,1} \approx 0,58$ . Turime galingiausią randomizuotą kriterijų su funkcija

$$\psi^*(x) = \begin{cases} 1, & \text{kai } \kappa_7 < 4, \\ c_{0,1}, & \text{kai } \kappa_7 = 4, \\ 0, & \text{kai } \kappa_7 > 4, \end{cases}$$

ir nerandomizuotą kriterijų su funkcija

$$\hat{\psi}(x) = \begin{cases} 1, & \text{kai } \kappa_7 \leq 4, \\ 0, & \text{kai } \kappa_7 > 4. \end{cases}$$

Jei pasirinksime nerandomizuotą kriterijų, tai hipotezę teks atmesti. Jei imsime randomizuotą kriterijų, tai hipotezę atmesime su tikimybe  $c_{0,1} \approx 0,58$ , o su tikimybe  $1 - c_{0,1} \approx 0,42$  laikysime ją priimtina.

Skaičiavimai palengvės, pasinaudojus lygybe

$$\sum_{k=0}^m \binom{n}{k} p^k (1-p)^{n-k} = 1 - I_p(m+1, n-m);$$

čia

$$I_p(m, n) = \frac{1}{B(m, n)} \int_0^p y^{m-1} (1-y)^{n-1} dy,$$

$$B(m, n) = \int_0^1 y^{m-1} (1-y)^{n-1} dy.$$

Yra sudarytos lentelės (žr. [17], XII lentelę; [2], 5.1, 5.2 lenteles). Vartojamos taip pat įvairios apytikslės formulės (Muavro–Laplaso, Puasono teoremos ir t. t.).

3. Stebime atsitiktinį dydį, pasiskirsčiusį pagal Puasono dėsnį su  $n$  e-ž i n o m u p a r a m e t r u  $\lambda > 0$ . Reikia patikrinti hipotezę  $\lambda = \lambda_0$ , kai alternatyva yra  $\lambda = \lambda_1 > \lambda_0$ . Tikėtinumo funkcijų realizacijų santykio logaritmas yra

$$(x_1 + \dots + x_n) \ln \frac{\lambda_1}{\lambda_0} - n(\lambda_1 - \lambda_0);$$

čia  $x_1 + \dots + x_n$  yra sveikasis neneigiamas skaičius, jo koeficientas yra teigiamas. Imame funkciją

$$\psi^*(x) = \begin{cases} 1, & \text{kai } x_1 + \dots + x_n > m, \\ c, & \text{kai } x_1 + \dots + x_n = m, \\ 0, & \text{kai } x_1 + \dots + x_n < m. \end{cases}$$

Skaičius  $c = c_\alpha$  ir  $m = m_\alpha$  reikia rasti iš lygties

$$\alpha = c \mathcal{P}_{\lambda_0}(X_1 + \dots + X_n = m) + \sum_{k>m} \mathcal{P}_{\lambda_0}(X_1 + \dots + X_n = k).$$

Statistika  $X_1 + \dots + X_n$ , kai teisinga nulinė hipotezė, yra pasiskirsčiusi pagal Puasono dėsnį su parametru  $\lambda_0 n$ . Todėl

$$\mathcal{P}_{\lambda_0}(X_1 + \dots + X_n = k) = \frac{(\lambda_0 n)^k}{k!} e^{-\lambda_0 n}.$$

Jei egzistuoja sveikasis skaičius  $m$ , tenkinantis sąlygą

$$\sum_{k=m}^{\infty} \frac{(\lambda_0 n)^k}{k!} e^{-\lambda_0 n} = \alpha,$$

tai jį ir laikome  $m_\alpha$ ; tada  $c_\alpha = 1$ . Gauname galingiausią nerandomizuotą kriterijų. Jei tokio sveikąjo  $m$  nėra, tai galime rasti sveikąjį  $m_\alpha$  su sąlyga

$$\sum_{k=m_\alpha+1}^{\infty} \frac{(\lambda_0 n)^k}{k!} e^{-\lambda_0 n} < \alpha < \sum_{k=m_\alpha}^{\infty} \frac{(\lambda_0 n)^k}{k!} e^{-\lambda_0 n}.$$

Tada  $c_\alpha$  imame lygų

$$c_\alpha = \frac{\alpha - \sum_{k=m_\alpha+1}^{\infty} \frac{(\lambda_0 n)^k}{k!} e^{-\lambda_0 n}}{\frac{(\lambda_0 n)^{m_\alpha}}{m_\alpha!} e^{-\lambda_0 n}}.$$

Gauname randomizuotą galingiausią kriterijų.

Iš čia kritinės srities pavidalas nepriklauso nuo alternatyvos  $\lambda = \lambda_1 > \lambda_0$ . Kriterijus yra tolygiai galingiausias, kai alternatyva yra sudėtinga:  $\Theta_1 = \{\lambda : \lambda > \lambda_0\}$ .

Praktiškai abiem atvejais vartojamas nerandomizuotas kriterijus su funkcija

$$\hat{\psi}(x) = \begin{cases} 1, & \text{kai } x_1 + \dots + x_n \geq m, \\ 0, & \text{kai } x_1 + \dots + x_n < m. \end{cases}$$

Siūlome skaitytojui išnagrinėti galios funkciją bei sudaryti kriterijus, kai alternatyvos yra  $\lambda = \lambda_1 < \lambda_0$  arba  $\lambda = \lambda_1 \neq \lambda_0$ .

Praktiniuose skaičiavimuose galima naudotis lygybe

$$\sum_{k=0}^m \frac{\lambda^k}{k!} e^{-\lambda} = P(\chi_{2m+2}^2 > 2\lambda),$$

atitinkamomis lentelėmis (žr. [17], III lentelę; [2], 5.3 lentelę) bei įvairiomis apytikslėmis formulėmis.

4. Nagrinėsime normalųjį pasiskirstymą, kai **a b u p a r a m e t r a i**  $a \in R$  ir  $\sigma^2 > 0$  yra **n e ž i n o m i**. Tikrinsime hipotezę  $H_0$ , kad  $a = a_0$ . Statistika  $(\bar{X} - a_0)\sqrt{n}/S_1$ , kai teisinga  $H_0$ , yra pasiskirsčiusi pagal Stjudento dėsnį su  $n - 1$  laisvės laipsnių (žr. 8 skyrelio lema).

Kai alternatyva yra  $a = a_1 > a_0$ , hipotezė atmetama, jei

$$(\bar{x} - a_0)\sqrt{n}/s_1 \geq u.$$

Tada

$$\alpha = \mathcal{P}_{a_0}((\bar{X} - a_0)\sqrt{n}/S_1 \geq u) = \int_u^\infty p_{S_{t_{n-1}}}(v)dv;$$

$u = u_\alpha$  yra Stjudento pasiskirstymo su  $n - 1$  laisvės laipsnių  $(1 - \alpha)$ -kvantilis.

Jei alternatyva yra  $a = a_1 < a_0$ , tai hipotezę atmetame, kai

$$(\bar{x} - a_0)\sqrt{n}/s_1 \leq u;$$

$u = u_\alpha$  randame iš lygybės

$$\alpha = \int_{-\infty}^u p_{S_{t_{n-1}}}(v)dv;$$

$u_\alpha$  yra atitinkamo Stjudento pasiskirstymo  $\alpha$ -kvantilis.

Pagaliau, kai alternatyva yra  $a = a_1 \neq a_0$ , hipotezė atmetama, jei

$$|\bar{x} - a_0|\sqrt{n}/s_1 \geq u,$$

ir  $u = u_\alpha$  randamas iš lygties

$$\alpha = \int_{|v| \geq u} p_{S_{t_{n-1}}}(v)dv.$$

Jei pasiskirstymas yra bet koks, tačiau turi dispersiją  $\sigma^2$ , tai galima būtų parodyti, kad statistika  $(\bar{X} - a_0)\sqrt{n}/S_1$  yra asimptotiškai pasiskirsčiusi pagal  $N(0, 1)$ , kai hipotezė  $H_0 : a = a_0$  yra teisinga. Tam pakanka pastebėti, kad statistika  $(\bar{X} - a_0)\sqrt{n}/\sigma$ , kai teisinga nulinė hipotezė, yra asimptotiškai pasiskirsčiusi pagal  $N(0, 1)$ , o  $S_1$  konverguoja pagal tikimybę į  $\sigma$ . Kritines sritis galime konstruoti kaip ir 1 uždavinyje. Skaičiai  $u$  randami iš apytikslių lygybių, analogiškų (1), (2), (3).

2 p a v y z d y s. Knygos pradžioje (I.2 skyrelyje) pasakojome, kad Biufonas metė monetą 4040 kartų, ir 2048 kartus atvirto herbas. Ar šie duomenys atitinka hipotezę, kad moneta yra simetriška, kai reikšmingumo lygmuo lygus 0,05?

Reikia patikrinti hipotezę, kad herbo atvartimo tikimybė  $p = 0,5$ , kai alternatyva yra  $p = p_1 \neq 0,5$ . Statistika  $(\bar{X} - 0,5)\sqrt{2n}$ , kai teisinga nulinė hipotezė, yra asimptotiškai pasiskirsčiusi pagal  $N(0, 1)$ . Kritinė sritis yra  $|\bar{x} - 0,5|\sqrt{2n} \geq u$ . Skaičių  $u = u_{0,05}$  randame iš apytikslės lygties

$$0,05 \approx 2(1 - \Phi(u)).$$

Iš čia  $\Phi(u) \approx 0,975$  ir  $u_{0,05} \approx 1,960$ . Vadinasi, kritinę sritį galime imti  $|\bar{x} - 0,5| \geq 1,96(2n)^{-1/2} \approx 0,0218$ . Iš Biufono duomenų  $\bar{x} - 0,5 \approx 0,007$ . Hipotezė priimtina.

5. Panagrinėkime hipotezių apie normaliojo pasiskirstymo dispersiją tikrinimą. Tarkime, kad v i d u r k i s  $a$  yra ž i n o m a s, o d i s p e r s i j a  $\sigma^2 > 0$  n e ž i n o m a

, ir reikia patikrinti hipotezę  $\sigma^2 = \sigma_0^2$ , kai alternatyva yra  $\sigma^2 = \sigma_1^2 > \sigma_0^2$ . Remsimės Neimano–Pirsono fundamentaliąja lema. Tikėtinumo funkcijų realizacijų santykio logaritmo pagrindinis narys yra

$$-\frac{1}{2} \left( \frac{1}{\sigma_0^2} - \frac{1}{\sigma_1^2} \right) \sum_{k=1}^n (x_k - a)^2.$$

Todėl hipotezė atmetama, kai

$$ns_0^2/\sigma_0^2 \leq u.$$

Statistika  $nS_0^2/\sigma_0^2$ , kai teisinga nulinė hipotezė, yra pasiskirsčiusi pagal  $\chi^2$  su  $n$  laisvės laipsnių. Skaičių  $u = u_\alpha$  randame iš lygties

$$\alpha = \int_0^u p_{\chi_n^2}(v) dv.$$

Jis yra to pasiskirstymo  $\alpha$ -kvantilis.

Jei alternatyva yra  $\sigma^2 = \sigma_1^2 < \sigma_0^2$ , tai hipotezė atmetama, kai

$$ns_0^2/\sigma_0^2 \geq u$$

su  $u = u_\alpha$ , lygiu  $(1 - \alpha)$ -kvantiliui.

Alternatyvai  $\sigma^2 = \sigma_1^2 \neq \sigma_0^2$  nulinė hipotezė atmetama, kai

$$ns_0^2/\sigma_0^2 \leq u' \text{ arba } ns_0^2/\sigma_0^2 \geq u'';$$

čia  $u' = u'_\alpha$  yra  $\alpha/2$ -kvantilis, o  $u'' = u''_\alpha$  yra  $(1 - \alpha/2)$ -kvantilis.

Šių kriterijų galios atitinkamai lygios

$$1 - F_{\chi_n^2}(u_\alpha \sigma_0^2/\sigma_1^2), \quad F_{\chi_n^2}(u_\alpha \sigma_0^2/\sigma_1^2), \\ F_{\chi_n^2}(u'_\alpha \sigma_0^2/\sigma_1^2) + 1 - F_{\chi_n^2}(u''_\alpha \sigma_0^2/\sigma_1^2).$$

Visi trys yra galingiausi, kai atitinkamos alternatyvos paprastosios. Pirmieji du yra tolygiai galingiausi, kai alternatyvos sudėtingos.

Jei vidurkis  $a \in R$  yra nežinomas, tai vietoj statistikos  $nS_0^2/\sigma_0^2$  imame statistiką  $(n-1)S_1^2/\sigma_0^2$ . Kai teisinga nulinė hipotezė, ši statistika yra pasiskirsčiusi pagal  $\chi^2$  su  $n-1$  laisvės laipsnių. Kritinės sritys sudaromos analogiškai.

6. Dažnai tenka lyginti dviejų atsitiktinių dydžių nežinomus vidurkius. Tarkime, kad du stebimieji atsitiktiniai dydžiai yra pasiskirstę pagal  $N(a_1, \sigma_1^2)$  ir  $N(a_2, \sigma_2^2)$  su nežinomais vidurkiais  $a_1 \in R, a_2 \in R$ , bet žinomomis dispersijomis  $\sigma_1^2$  ir  $\sigma_2^2$ . Stebime  $n$  kartų pirmąjį dydį ir  $m$  kartų – antrąjį. Gauname imtis  $X = (X_1, \dots, X_n)$  ir  $Y = (Y_1, \dots, Y_m)$ . Imkime statistiką

$$\frac{\bar{X} - \bar{Y} - b_0}{\sqrt{\sigma_1^2/n + \sigma_2^2/m}}.$$

Jei teisinga hipotezė  $a_1 - a_2 = b_0$ , tai ta statistika pasiskirsčiusi pagal  $N(0, 1)$ .

Tikriname hipotezę  $a_1 - a_2 = b_0$  su alternatyva  $a_1 - a_2 = b_1 > b_0$ . Remdamiesi Neimano–Pirsono lema, gauname, kad hipotezę reikia atmesti, kai

$$\frac{\bar{x} - \bar{y} - b_0}{\sqrt{\sigma_1^2/n + \sigma_2^2/m}} \geq u.$$

Jei alternatyva yra  $a_1 - a_2 < b_0$ , tai hipotezę atmetame, kai

$$\frac{\bar{x} - \bar{y} - b_0}{\sqrt{\sigma_1^2/n + \sigma_2^2/m}} \leq u.$$

Pagaliam, jei alternatyva yra  $a_1 - a_2 \neq b_0$ , tai hipotezę atmetame, kai

$$\frac{|\bar{x} - \bar{y} - b_0|}{\sqrt{\sigma_1^2/n + \sigma_2^2/m}} \geq u.$$

Lygtis skaičiams  $u = u_\alpha$  rasti paliekame parašyti skaitytojui. Galima būtų įrodyti, kad pirmieji du kriterijai yra tolygiai galingiausi sudėtingoms dešiniapusei ir kairiapusei alternatyvoms.

Jei dispersijos  $\sigma_1^2$  ir  $\sigma_2^2$  nėra žinomos, bet žinomas jų santykis  $\sigma_1^2/\sigma_2^2 = \lambda$ , tai, sudarydami kritines sritis, galime naudotis statistika

$$\frac{\bar{X} - \bar{Y} - b_0}{\sqrt{(n-1)S_{11}^2 + \lambda(m-1)S_{12}^2}} \sqrt{\frac{\lambda nm(n+m-2)}{n+\lambda m}};$$

čia

$$(4) \quad S_{11}^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2, \quad S_{12}^2 = \frac{1}{m-1} \sum_{k=1}^m (Y_k - \bar{Y})^2.$$

Jei teisinga hipotezė  $a_1 - a_2 = b_0$ , tai analogiškai 8 skyrelio lemai galima parodyti, kad ši statistika pasiskirsčiusi pagal Stjudento dėsnį su  $n+m-2$  laisvės laipsnių.

Jei ir dispersijų santykis yra nežinomas, tai galima imti statistiką

$$\frac{\bar{X} - \bar{Y} - b_0}{\sqrt{(n-1)S_{11}^2 + (m-1)S_{12}^2}} \sqrt{\frac{nm(n+m-2)}{n+m}}.$$

Kai teisinga nulinė hipotezė, ta statistika yra apytiksliai pasiskirsčiusi pagal Stjudento dėsnį su  $n+m-2$  laisvės laipsnių. Kritines sritis galima sudaryti kaip ir anksčiau. Tačiau šiuo atveju statistika gali patekti į kritinę sritį ir dėl dispersijų skirtumo, nors nulinė hipotezė apie vidurkius ir teisinga. Esama būdų, leidžiančių sumažinti  $\sigma_1^2/\sigma_2^2$  įtaką.

7. Tenka lyginti ir dviejų dydžių dispersijas. Sakykime, turime du normaliuosius atsitiktinius dydžius su nežinomomis dispersijomis  $\sigma_1^2$  ir  $\sigma_2^2$ . Reikia patikrinti hipotezę  $\sigma_1^2 = \lambda_0 \sigma_2^2$ . Jei vidurkiai  $a_1$  ir  $a_2$  yra žinomi, tai imame statistiką  $S_{01}^2/(\lambda_0 S_{02}^2)$ ; čia

$$S_{01}^2 = \frac{1}{n} \sum_{k=1}^n (X_k - a_1)^2, \quad S_{02}^2 = \frac{1}{m} \sum_{k=1}^m (Y_k - a_2)^2.$$

Jei hipotezė teisinga, tai ta statistika pagal III.9.5 pavyzdį turi Fišerio pasiskirstymą su  $n$  ir  $m$  laisvės laipsnių.

Jei alternatyva yra  $\sigma_1^2 > \lambda_0 \sigma_2^2$ , tai hipotezę atmetame, kai

$$s_{01}^2/(\lambda_0 s_{02}^2) \geq u;$$

čia  $u = u_\alpha$  yra Fišerio pasiskirstymo su  $n$  ir  $m$  laisvės laipsnių  $(1-\alpha)$ -kvantilis. Jei alternatyva yra  $\sigma_1^2 < \lambda_0 \sigma_2^2$ , tai hipotezė atmetama, kai

$$s_{01}^2/(\lambda_0 s_{02}^2) \leq u;$$

čia  $u = u_\alpha$  yra  $\alpha$ -kvantilis (žr. [17], VII lentelę).

Pagaliau, jei alternatyva yra  $\sigma_1^2 \neq \lambda_0 \sigma_2^2$ , tai nulinę hipotezę atmetame, kai

$$s_{01}^2/(\lambda_0 s_{02}^2) \leq u' \quad \text{arba} \quad s_{01}^2/(\lambda_0 s_{02}^2) \geq u'';$$

skaičius  $u' = u'_\alpha$  yra Fišerio pasiskirstymo su  $m$  ir  $n$  laisvės laipsnių  $\alpha/2$ -kvantilis, o  $u'' = u''_\alpha$  – to pasiskirstymo  $(1 - \alpha/2)$ -kvantilis.

Jei v i d u r k i a i  $a_1$  ir  $a_2$  yra n e ž i n o m i, tai nagrinėjame statistiką  $S_{11}^2/(\lambda_0 S_{12}^2)$ ; dydžiai  $S_{11}^2$  ir  $S_{12}^2$  apibrėžti (4) formule. Ši statistika, kai teisinga nulinė hipotezė, pagal 8 skyrelio lemą ir III.9.5 pavyzdį turi Fišerio pasiskirstymą su  $n - 1$  ir  $m - 1$  laisvės laipsnių. Kritinės sritys sudaromos analogiškai.

Paliekame skaitytojui parašyti tų kriterijų galios funkcijas.

3 p a v y z d y s. Detalėms gaminti buvo pasiūlyti du būdai. Kadangi jos gaminamos iš reto metalo, tai buvo tiriama, kuriuo būdu gaminant detalę, reikia mažiau metalo. Pirmuoju būdu buvo pagamintos 6 detalės; joms prireikė 3,1; 3,8; 3,6; 4,0; 3,4; 3,7 gramų metalo. Antruoju būdu pagamino 5 detales; joms prireikė 4,1; 4,3; 4,7; 4,8; 4,6 gramų metalo.

Laikysime, kad abiem atvejais turime normalųjį pasiskirstymą. Pirmiausia patikrinsime hipotezę, ar su reikšmingumo lygmeniu 0,1 galime laikyti, kad abiem atvejais dispersijos yra tos pačios. Turime:

$$\begin{aligned} \bar{x} &= 3,6, & \bar{y} &= 4,5, \\ 5s_{11}^2 &= 0,5, & 4s_{12}^2 &= 0,34. \end{aligned}$$

Kai teisinga ši hipotezė, statistika  $S_{11}^2/S_{12}^2$  yra pasiskirsčiusi pagal Fišerio dėsnį su 5 ir 4 laisvės laipsniais. Randame jo 0,05 ir 0,95-kvantilius. Jie apytiksliai lygūs 0,19 ir 6,26, o  $s_{11}^2/s_{12}^2 \approx 1,18$ . Hipotezė priimtina.

Laikydami, kad abi dispersijos yra lygios, patikrinsime, ar ir vidurkiai yra lygūs. Reikšmingumo lygmenį imsime 0,05. Rasime Stjudento pasiskirstymo su 9 laisvės laipsniais 0,975-kvantilį. Jis lygus 2,26. Hipotezę reikia atmesti, kai

$$\frac{|\bar{x} - \bar{y}|}{\sqrt{5s_{11}^2 + 4s_{12}^2}} \sqrt{\frac{6 \cdot 5 \cdot 9}{11}} \geq 2,26.$$

Kairioji šios lygybės pusė mūsų atveju yra apytiksliai lygi 4,87. Hipotezė atmetina.

## 12. $\chi^2$ KRITERIJUS

Tarp daugybės kriterijų statistinėms hipotezėms tikrinti svarbią vietą užima vadinamasis  $\chi^2$  kriterijus, pasiūlytas K. Pirsono. Jis yra gana paprastas ir plačiai taikomas.

Tarkime, kad atliekame  $n$  nepriklausomų eksperimentų. Atlikus bet kurį eksperimentą, įvyksta vienas iš nesutaikomų įvykių  $A_1, \dots, A_r, A_1 \cup \dots \cup A_r = \Omega$ , su pastoviomis tikimybėmis  $p_1, \dots, p_r; p_1 + \dots + p_r = 1$ . Pažymėkime

įvykio  $A_k$  įvykimų skaičių, atlikus  $n$  eksperimentų, raide  $\kappa_k$ . Taigi  $\kappa_1 + \dots + \kappa_r = n$ . Statistiniai dažniai  $\kappa_1/n, \dots, \kappa_r/n$  yra tikimybių  $p_k$  įverčiai.

Ivesime dažnių  $\kappa_1/n, \dots, \kappa_r/n$  ir tikimybių  $p_1, \dots, p_r$  nukrypimo matą

$$\sum_{k=1}^r c_k \left( \frac{\kappa_k}{n} - p_k \right)^2;$$

čia  $c_k$  yra bet kokios teigiamos konstantos. Tinkamai jas parinkus, tas reiškinys turi paprastas asimptotines savybes. Taip, pavyzdžiui, yra, kai  $c_k = n/p_k$ . Pažymėkime

$$\Delta_n = \sum_{k=1}^r \frac{(\kappa_k - np_k)^2}{np_k} = \sum_{k=1}^r \frac{\kappa_k^2}{np_k} - n.$$

**Lema.** Jei kompleksinis skaičius  $z$  tenkina nelygybę  $|z| \leq 1/2$ , tai

$$\left| \ln(1+z) - z + \frac{z^2}{2} \right| \leq \frac{2}{3}|z|^3.$$

Į r o d y m a s analogiškas III.10 skyrelio lemos įrodymui. Turime

$$\left| \ln(1+z) - z + \frac{z^2}{2} \right| \leq \sum_{k=3}^{\infty} \frac{|z|^k}{k} \leq \frac{1}{3} \sum_{k=3}^{\infty} |z|^k = \frac{|z|^3}{3(1-|z|)} \leq \frac{2}{3}|z|^3. \quad \square$$

**1 (Pirsono) teorema.**  $\Delta_n$  yra asimptotiškai pasiskirstęs pagal  $\chi^2$  su  $r-1$  laisvės laipsnių.

Į r o d y m a s. Tikimybė, kad  $\kappa_1 = m_1, \dots, \kappa_r = m_r$ , yra lygi

$$\frac{n!}{m_1! \dots m_r!} p_1^{m_1} \dots p_r^{m_r}.$$

Todėl vektoriaus  $(\kappa_1, \dots, \kappa_r)$  charakteristinė funkcija

$$\begin{aligned} f_{(\kappa_1, \dots, \kappa_r)}(t_1, \dots, t_r) &= \\ &= \sum_{\substack{m_1 \geq 0, \dots, m_r \geq 0 \\ m_1 + \dots + m_r = n}} e^{i(t_1 m_1 + \dots + t_r m_r)} \frac{n!}{m_1! \dots m_r!} p_1^{m_1} \dots p_r^{m_r} = \\ &= (p_1 e^{it_1} + \dots + p_r e^{it_r})^n. \end{aligned}$$

Pažymėkime

$$Z_k = \frac{\kappa_k - np_k}{\sqrt{np_k}} \quad (k = 1, \dots, r).$$

Tada

$$\Delta_n = \sum_{k=1}^r Z_k^2, \quad \sum_{k=1}^r Z_k \sqrt{p_k} = 0.$$

Vektoriaus  $Z = (Z_1, \dots, Z_r)$  charakteristinė funkcija

$$\begin{aligned} f_Z(t_1, \dots, t_r) &= \exp\left(-i\sqrt{n} \sum_{k=1}^r t_k \sqrt{p_k}\right) f\left(\frac{t_1}{\sqrt{np_1}}, \dots, \frac{t_r}{\sqrt{np_r}}\right) = \\ &= \left(\sum_{k=1}^r p_k e^{it_k/\sqrt{np_k}}\right)^n \exp\left(-i\sqrt{n} \sum_{k=1}^r t_k \sqrt{p_k}\right). \end{aligned}$$

Pasinaudoję nelygybe (žr. III.8 skyrelio lemą)

$$\left|e^{iv} - 1 - iv + \frac{v^2}{2}\right| \leq \frac{|v|^3}{6},$$

teisinga visiems realiesiems  $v$ , ir laikydami  $n$  pakankamai dideliu, gauname

$$\begin{aligned} \ln f_Z(t_1, \dots, t_r) &= n \ln \sum_{k=1}^r p_k e^{it_k/\sqrt{np_k}} - i\sqrt{n} \sum_{k=1}^r t_k \sqrt{p_k} = \\ &= n \ln \sum_{k=1}^r p_k \left(1 + \frac{it_k}{\sqrt{np_k}} - \frac{t_k^2}{2np_k} + \frac{B|t_k|^3}{(np_k)^{3/2}}\right) - i\sqrt{n} \sum_{k=1}^r t_k \sqrt{p_k} = \\ &= n \ln \left(1 + \frac{i}{\sqrt{n}} \sum_{k=1}^r t_k \sqrt{p_k} - \frac{1}{2n} \sum_{k=1}^r t_k^2 + \frac{B}{n^{3/2}}\right) - i\sqrt{n} \sum_{k=1}^r t_k \sqrt{p_k}. \end{aligned}$$

Čia ir toliau  $B$  reiškia skaičių, ne visada tą patį, bet aprėžtą konstantos, nepriklausančios nuo  $n$ . Remsimės šio skyrelio lema. Pakankamai dideliems  $n$

$$\begin{aligned} \ln f_Z(t_1, \dots, t_r) &= n \left( \frac{i}{\sqrt{n}} \sum_{k=1}^r t_k \sqrt{p_k} - \frac{1}{2n} \sum_{k=1}^r t_k^2 + \frac{B}{n^{3/2}} \right) - \\ &- \frac{n}{2} \left( \frac{i}{\sqrt{n}} \sum_{k=1}^r t_k \sqrt{p_k} + \frac{B}{n} \right)^2 + \frac{B}{\sqrt{n}} - i\sqrt{n} \sum_{k=1}^r t_k \sqrt{p_k} = \\ &= -\frac{1}{2} \sum_{k=1}^r t_k^2 + \frac{1}{2} \left( \sum_{k=1}^r t_k \sqrt{p_k} \right)^2 + \frac{B}{\sqrt{n}}. \end{aligned}$$

Todėl, kai  $n \rightarrow \infty$ ,

$$f_Z(t_1, \dots, t_r) \rightarrow \exp \left\{ -\frac{1}{2} Q(t_1, \dots, t_r) \right\};$$

čia

$$Q(t_1, \dots, t_r) = \sum_{k=1}^r t_k^2 - \left( \sum_{k=1}^r t_k \sqrt{p_k} \right)^2$$

yra neneigiamai apibrėžta kvadratinė forma (įrodykite!).

Tarkime, kad  $Y = (Y_1, \dots, Y_r)$  yra normalusis vektorius su charakteristine funkcija  $\exp \left\{ -\frac{1}{2} Q(t_1, \dots, t_r) \right\}$ . Kvadratinę formą  $Q$ , panaudoję ortogonalią transformaciją  $(t_1, \dots, t_r) = (u_1, \dots, u_r)C$  su sąlyga  $u_r = t_1 p_1^{1/2} + \dots + t_r p_r^{1/2}$ , galime užrašyti pavidalu  $Q(t_1, \dots, t_r) = u_1^2 + \dots + u_{r-1}^2$ . Tai bus vektoriaus  $Y(C^{-1})' = (V_1, \dots, V_{r-1}, 0)$  (žr. III.13 skyrelį) charakteristinė funkcija. Atsitiktiniai dydžiai  $V_1, \dots, V_{r-1}$  yra nepriklausomi ir pasiskirstę pagal  $N(0, 1)$ .

Pasinaudoję teorema apie tolydžią atitiktį tarp pasiskirstymo funkcijų ir charakteristinių funkcijų (žr. III.13 skyrelį), gauname

$$\begin{aligned} f_{\Delta_n}(t) &= \int \dots \int_{R^r} e^{it(v_1^2 + \dots + v_r^2)} dF_Z(v_1, \dots, v_r) \rightarrow \\ &\rightarrow \int \dots \int_{R^r} e^{it(v_1^2 + \dots + v_r^2)} dF_Y(v_1, \dots, v_r) = f_{Y_1^2 + \dots + Y_r^2}(t). \end{aligned}$$

Kadangi matrica  $(C^{-1})'$  yra ortogonalė, tai  $Y_1^2 + \dots + Y_r^2 = V_1^2 + \dots + V_{r-1}^2$ . Todėl

$$f_{\Delta_n}(t) \rightarrow f_{V_1^2 + \dots + V_{r-1}^2}(t),$$

kai  $n \rightarrow \infty$ . Vadinas,  $\Delta_n$  yra asimptotiškai pasiskirstęs pagal  $\chi^2$  su  $r - 1$  laisvės laipsnių.  $\square$

Remdamiesi šia teorema, galime sudaryti kriterijų hipotezei  $H_0 : p_1 = \dots = p_1^0, \dots, p_r = p_r^0$  tikrinti. Jei įvykių  $A_1, \dots, A_r$  tikimybės žymiai skiriasi nuo  $p_1^0, \dots, p_r^0$ , tai skirtumai  $\kappa_k/n - p_k^0$  dažniau įgis didesnes reikšmes, negu jas įgytų tuo atveju, kai hipotezė teisinga.

Paėmę reikšmingumo lygmenį  $\alpha$ , kritinę kriterijaus sritį apibrėšime nelygybe  $\Delta_n \geq u$ ; skaičių  $u = u_\alpha$  randame iš lygties

$$\mathcal{P}(\Delta_n \geq u) = \alpha.$$

Statistikos  $\Delta_n$  pasiskirstymo nežinome, bet žinome, kad ji asimptotiškai pasiskirsčiusi pagal  $\chi^2$  su  $r - 1$  laisvės laipsnių. Todėl tą lygtį, kai  $n$  yra pakankamai didelis, pakeičiame apytiksle lygtimi

$$\int_u^\infty p_{\chi_{r-1}^2}(v) dv \approx \alpha.$$

Taigi  $u_\alpha$  laikome apytiksliai lygiu pasiskirstymo  $\chi^2$  su  $r - 1$  laisvės laipsnių  $(1 - \alpha)$ -kvantiliu.

1 p a v y z d y s. Genetikos pradininkas G. Mendelis<sup>1</sup> darė bandymus su žirniais. Tarp jo užaugintų žirnių buvo 315 lygūs ir geltoni, 108 – lygūs ir žali, 101 – raukšlėti ir geltoni bei 32 – raukšlėti ir žali. Pagal paveldimumo teoriją tokių žirnių skaičių santykis turėtų būti 9:3:3:1. Ar Mendelio duomenys patvirtina jo teoriją su reikšmingumo lygmeniu  $\alpha = 0,05$ ?

Šiuo atveju  $p_1 = 9/16$ ;  $p_2 = p_3 = 3/16$ ;  $p_4 = 1/16$ ;  $n = 315 + 108 + 101 + 32 = 556$ . Pasiskirstymo  $\chi^2$  su 3 laisvės laipsniais 0,95-kvantilis yra  $\approx 7,815$ . Statistikos  $\Delta_n$  reikšmė

$$\frac{315^2}{556 \cdot 9/16} + \frac{108^2}{556 \cdot 3/16} + \frac{101^2}{556 \cdot 3/16} + \frac{32^2}{556 \cdot 1/16} - 556 \approx 0,470.$$

Hipotezė atitinka stebėjimo duomenis.

Iš Pirsono teoremos irodymo išplaukia, kad  $\Delta_n$  pasiskirstymo konvergavimas į ribinį yra tuo lėtesnis, kuo mažesnės  $p_k$ . Rekomenduojama ši kriterijų taikyti tada, kai  $np_k \geq 5$ .

Remdamiesi Pirsono teorema, galime sudaryti kriterijų tikrinti hipotezėi  $H_0$ , kad stebimasis atsitiktinis dydis turi kokią nors konkrečią pasiskirstymo funkciją  $F(y)$ . Ta funkcija turi būti visiškai apibrėžta ir neturi priklausyti nuo jokių nežinomų parametrų.

Padalykime atsitiktinio dydžio visų galimų reikšmių aibę  $W$  į poaibius  $W_1, \dots, W_r$ , kurie kas du neturi bendrų elementų ir kurių sąjunga lygi aibei  $W$ . Pažymėkime  $A_k$  įvykių, kai atsitiktinis dydis įgyja reikšmę iš srities  $W_k$ . Jei hipotezė  $H_0$  yra teisinga, tai galime apskaičiuoti įvykių  $A_k$  tikimybes  $p_k^0$ . Užuoat tikrinę hipotezę  $H_0$ , tikriname hipotezę  $H'_0$ , kad tikimybės stebimajam atsitiktiniam dydžiui įgyti reikšmes iš aibių  $W_k$  yra  $p_k^0$  ( $k = 1, \dots, r$ ).

Dažnai tenka tikrinti hipotezes, kai pasiskirstymas yra, pavyzdžiui, normalusis, Puasono ar pan. Tokie pasiskirstymai priklauso nuo parametrų, kurie paprastai yra nežinomi. Sakykime, reikia patikrinti hipotezę, kad stebimojo dydžio pasiskirstymas yra  $P_{(\theta_1, \dots, \theta_s)}$  su kokiomis nors parametrų  $\theta_1, \dots, \theta_s$  reikšmėmis. Kaip ir anksčiau, suskaidę to dydžio galimų reikšmių aibę  $W$  į sritis  $W_1, \dots, W_r$  ( $r > s$ ), imame tikimybes  $p_k(\theta_1, \dots, \theta_s)$  ( $k = 1, \dots, r$ ), kad stebimasis dydis įgis reikšmes iš poaibių  $W_k$ , ir sudarome atstumo matą

$$(1) \quad \Delta_n(\theta_1, \dots, \theta_s) = \sum_{k=1}^r \frac{(\kappa_k - np_k(\theta_1, \dots, \theta_s))^2}{np_k(\theta_1, \dots, \theta_s)}.$$

Jei parametrų  $\theta_1, \dots, \theta_s$  reikšmės būtų žinomos, tai turėtume jau išnagrinėtą atvejį. Tačiau jos nežinomos. Peršasi paprasta išeitis: reikia parametrus pakeisti jų įverčiais. Imkime kuriuos nors parametrų įverčius  $\theta_1^*, \dots, \theta_s^*$  ir pakeiskime jais (1) formulėje pačius parametrus  $\theta_1, \dots, \theta_s$ . Deja, vėl iškils nauji sunkumai:  $p_k(\theta_1^*, \dots, \theta_s^*)$  bus ne konstantos, bet atsitiktiniai dydžiai. Todėl 1 teorema nebus pritaikoma.

<sup>1</sup> Gregor-Johann Mendel (1822–1884) – austrų botanikas.

### 320 Matematinės statistikos pradmenys

Įverčius  $\theta_1^*, \dots, \theta_s^*$  galime parinkti daugybe būdų. Suprantama, statistikos  $\Delta_n$  pasiskirstymas priklausys nuo tų įverčių parinkimo. Juos galima parinkti ir taip, kad po nedidelių pakeitimų tiktų anksčiau išdėstyta teorija. Natūralu stengtis įverčius  $\theta_1^*, \dots, \theta_s^*$  parinkti taip, kad statistika  $\Delta_n$  būtų kuo mažesnė. Tai – vadinamasis  $\chi^2$  *minimumo metodas*. Tam reikalui (1) diferencijuojame parametrų  $\theta_1, \dots, \theta_s$  atžvilgiu (jei toks diferencijavimas yra galimas) ir gautas dalines išvestines prilyginame 0. Gauname lygčių sistemą

$$(2) \quad -\frac{1}{2} \frac{\partial \Delta_n}{\partial \theta_j} = \sum_{k=1}^r \left( \frac{\kappa_k - np_k}{p_k} + \frac{(\kappa_k - np_k)^2}{2np_k^2} \right) \frac{\partial p_k}{\partial \theta_j} = 0 \quad (j = 1, \dots, s).$$

Iš jų randame įverčius  $\tilde{\theta}_j$  ir jais pakeičiame  $\theta_j$  (1) formulėje. Kai patenkintos gana bendros sąlygos,  $\Delta_n(\tilde{\theta}_1, \dots, \tilde{\theta}_s)$  yra asimptotiškai pasiskirsčiusi pagal  $\chi^2$  su  $r - s - 1$  laisvės laipsnių.

(2) lygtis net paprasčiausiais atvejais sunku išspręsti. Galima būtų parodyti, kad antruosius narius tose lygtyse, kai  $n$  yra didelis, galima atmesti; nuo to nesikeičia statistikos  $\Delta_n$  asimptotinis pasiskirstymas. Turime paprastesnę lygčių sistemą

$$(3) \quad \sum_{k=1}^r \frac{\kappa_k - np_k}{p_k} \frac{\partial p_k}{\partial \theta_j} = 0 \quad (j = 1, \dots, s).$$

Ši sistema gaunama, prilyginus nuliui  $\Delta_n(\theta_1, \dots, \theta_s)$  išvestines pagal parametrus  $\theta_1, \dots, \theta_s$ , bet, skaičiuojant išvestines, laikoma, kad (1) formulės vardikliai yra pastovūs. Kadangi

$$\sum_{k=1}^r p_k(\theta_1, \dots, \theta_s) = 1,$$

tai (3) sistemą galima dar supaprastinti:

$$(4) \quad \sum_{k=1}^r \frac{\kappa_k}{p_k} \frac{\partial p_k}{\partial \theta_j} = 0 \quad (j = 1, \dots, s).$$

Šis metodas yra vadinamas *modifikuotu  $\chi^2$  minimumo metodu*.

**2 teorema.** *Tarkime, kad funkcijos  $p_k(\theta_1, \dots, \theta_s)$  ( $k = 1, \dots, r$ ) kuriame nors neišsigimusiam erdvės  $R^s$  intervale  $\Theta$  tenkina sąlygas:*

$$p_k(\theta_1, \dots, \theta_s) \geq c > 0 \quad (k = 1, \dots, r),$$

$$\sum_{k=1}^r p_k(\theta_1, \dots, \theta_s) = 1,$$

*egzistuoja tolydzios išvestinės*

$$\frac{\partial p_k}{\partial \theta_j}, \quad \frac{\partial^2 p_k}{\partial \theta_j \partial \theta_l} \quad (k = 1, \dots, r; j = 1, \dots, s; l = 1, \dots, s)$$

ir matricos

$$\left\| \frac{\partial p_k}{\partial \theta_j} \right\| \quad (k = 1, \dots, r; j = 1, \dots, s)$$

rangas yra lygus  $s$ . Sakykime, atliekame šio skyrelio pradžioje aprašytus  $n$  nepriklausomų eksperimentų ir tikimybė, kad įvykis  $A_k$  įvyks, atlikus kurį nors iš tų eksperimentų, yra  $p_k^0 = p_k(\theta_1^0, \dots, \theta_s^0)$ ; čia  $(\theta_1^0, \dots, \theta_s^0)$  – vidinis intervalo  $\Theta$  taškas. Tada (3) lygtys turi vienintelį sprendinį  $(\hat{\theta}_1, \dots, \hat{\theta}_s)$ , konverguojantį pagal tikimybę į  $(\theta_1^0, \dots, \theta_s^0)$ . Statistika

$$(5) \quad \Delta_n(\hat{\theta}_1, \dots, \hat{\theta}_s) = \sum_{k=1}^r \frac{(\kappa_k - np_k(\hat{\theta}_1, \dots, \hat{\theta}_s))^2}{np_k(\hat{\theta}_1, \dots, \hat{\theta}_s)}$$

yra asimptotiškai pasiskirsčiusi pagal  $\chi^2$  su  $r - s - 1$  laisvės laipsnių.

Šios teoremos įrodymas yra gana ilgas ir sudėtingas. Jį galima rasti, pavyzdžiui, [6], 30.3 skyrelyje.

Ta teorema grindžiamas kriterijus konstruojamas jau mums žinomais būdais.

Sakykime, reikia patikrinti hipotezę  $H_0$ , jog stebimojo atsitiktinio dydžio pasiskirstymas priklauso klasei  $\{P_\theta, \theta \in \Theta\}$ ,  $\Theta_0 \subset R^s$ . Suskirstykime to dydžio galimų reikšmių aibę į  $r$  aibių  $W_k$  ( $k = 1, \dots, r$ ). Pažymėkime  $p_k$  tikimybę įvykio  $A_k$ , kad atsitiktinis dydis pateks į  $W_k$ . Ši tikimybė priklauso nuo parametru  $\theta = (\theta_1, \dots, \theta_s)$ . Jei teisingos 2 teoremos sąlygos, hipotezę  $H_0$  pakeičiame hipoteze  $H'_0$ , kad įvykių  $A_k$  tikimybės būtų  $p_k$ , sprendžiame (4) lygčių sistemą ir sudarome statistiką  $\Delta_n(\hat{\theta}_1, \dots, \hat{\theta}_s)$ .

Pailiustruosime šią procedūrą dviem pavyzdžiais.

Sakykime, reikia patikrinti hipotezę  $H_0$ , kad stebimasis atsitiktinis dydis yra pasiskirstęs pagal Puasono dėsnį su nežinomu parametru  $\lambda > 0$ . Šis dydis įgyja sveikąsias neneigiamas reikšmes. Suskaidykime sveikųjų neneigiamų skaičių aibę į poaibius  $W_1 = \{0, 1, \dots, l\}$ ,  $W_k = \{l + k - 1\}$  ( $k = 2, \dots, r - 1$ ),  $W_r = \{l + r - 1, l + r, \dots\}$ . Tada

$$p_1 = p_1(\lambda) = \sum_{m=0}^l \frac{\lambda^m}{m!} e^{-\lambda},$$

$$p_k = p_k(\lambda) = \frac{\lambda^{l+k-1}}{(l+k-1)!} e^{-\lambda} \quad (k = 2, \dots, r-1),$$

$$p_r = p_r(\lambda) = \sum_{m=l+r-1}^{\infty} \frac{\lambda^m}{m!} e^{-\lambda}.$$

Tikimybės  $p_k$  tenkina 2 teoremos sąlygas. (4) sistema yra sudaryta iš vienos lygties

$$\begin{aligned} & \kappa_1 \frac{\sum_{m=0}^l \left(\frac{m}{\lambda} - 1\right) \frac{\lambda^m}{m!}}{\sum_{m=0}^l \frac{\lambda^m}{m!}} + \sum_{k=2}^{r-1} \left(\frac{l+k-1}{\lambda} - 1\right) \kappa_k + \\ & + \kappa_r \frac{\sum_{m=l+r-1}^{\infty} \left(\frac{m}{\lambda} - 1\right) \frac{\lambda^m}{m!}}{\sum_{m=l+r-1}^{\infty} \frac{\lambda^m}{m!}} = 0. \end{aligned}$$

Iš čia

$$\lambda = \frac{1}{n} \left( \kappa_1 \frac{\sum_{m=0}^l m \frac{\lambda^m}{m!}}{\sum_{m=0}^l \frac{\lambda^m}{m!}} + \sum_{k=2}^{r-1} (l+k-1) \kappa_k + \kappa_r \frac{\sum_{m=l+r-1}^{\infty} m \frac{\lambda^m}{m!}}{\sum_{m=l+r-1}^{\infty} \frac{\lambda^m}{m!}} \right).$$

Vidurinė suma lygi

$$\sum_{l < x_k < l+r-1} X_k;$$

pirmoji ir trečioji sumos paprastai nedaug skiriasi nuo sumų

$$\sum_{x_k \leq l} X_k, \quad \sum_{x_k \geq l+r-1} X_k.$$

Todėl sprendinys yra  $\tilde{\lambda} \approx \bar{X}$ . Patariama poaibius  $W_k$  parinkti taip, kad būtų  $np_k \geq 5$ .

2 p a v y z d y s. Buvo stebimos radioaktyviosios dalelės ir registruojama, kiek signalų gaunama kas valandą. Štai rezultatai: 0 signalų užregistruota 1924 kartus, 1 signalas – 541 kartą, 2 signalai – 103 kartus, 3 signalai – 17 kartų, 4 signalai – 1 kartą, 5 signalai – 1 kartą, 6 ir daugiau signalų – nė vieno karto. Su reikšmingumo lygmeniu 0,05 patikrinsime hipotezę, kad signalų skaičius pasiskirstęs pagal Puasono dėsnį.

Čia  $n = 1924 + 541 + 103 + 17 + 1 + 1 = 2587$ , empirinis vidurkis  $\bar{x} = (0 \cdot 1924 + 1 \cdot 541 + 2 \cdot 103 + 3 \cdot 17 + 4 \cdot 1 + 5 \cdot 1 + 6 \cdot 0) / n \approx 0,3119443$ .

Sudarome poaibius  $W_k = \{k-1\}$  ( $k = 1, 2, 3$ ),  $W_4 = \{3, 4, \dots\}$ .

Skaičiavimai surašyti lentelėje.

k	$\kappa_k$	$p_k$	$np_k$	$(\kappa_k - np_k)^2 / (np_k)$
1	1924	0,7320223	1893,74	0,48
2	541	0,2283502	590,74	4,19
3	103	0,0356163	92,14	1,28
4	19	0,0040112	10,38	7,17
Iš viso	2587	1,0000000	2587	13,12

$\chi^2$  pasiskirstymo su 2 laisvės laipsniais 0,95-kvantilis yra apytiksliai lygus 5,991. Todėl hipotezė atmetina.

Remdamiesi nagrinėjamoju kriterijumi, tikrinsime hipotezę, kad stebimasis atsitiktinis dydis yra pasiskirstęs pagal normalųjį dėsnį su nežinomais parametrais  $a \in R$  ir  $\sigma > 0$ . Suskaidykime realiųjų skaičių tiesę į sritis  $W_1 = (-\infty, \tau - h/2)$ ,  $W_k = [\tau_k - h/2, \tau_k + h/2)$  ( $k = 2, \dots, r - 1$ ),  $W_r = [\tau_{r-1} + h/2, \infty)$ ; čia  $\tau_k = \tau + (k - 1)h$ . Jei hipotezė teisinga, tai

$$p_k = p_k(a, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \int_{W_k} \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du \quad (k = 1, \dots, r).$$

Iš čia

$$\begin{aligned} \frac{\partial p_k}{\partial a} &= \frac{1}{\sigma^3\sqrt{2\pi}} \int_{W_k} (u-a) \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du, \\ \frac{\partial p_k}{\partial \sigma^2} &= \frac{1}{\sigma^4\sqrt{2\pi}} \int_{W_k} (u-a)^2 \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du - \\ &\quad - \frac{1}{\sigma^2\sqrt{2\pi}} \int_{W_k} \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du. \end{aligned}$$

(4) lygčių sistemą galima užrašyti šitaip:

$$\begin{aligned} a &= \frac{1}{n} \sum_{k=1}^r \kappa_k \frac{\int_{W_k} u \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du}{\int_{W_k} \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du}, \\ \sigma^2 &= \frac{1}{n} \sum_{k=1}^r \kappa_k \frac{\int_{W_k} (u-a)^2 \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du}{\int_{W_k} \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du}. \end{aligned}$$

Mažiems  $h$  teisingos apytikslės lygybės

### 324 Matematinės statistikos pradmenys

$$\int_{W_k} u \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du \approx \tau_k \int_{W_k} \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du,$$

$$\int_{W_k} (u-a)^2 \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du \approx (\tau_k - a)^2 \int_{W_k} \exp\left(-\frac{(u-a)^2}{2\sigma^2}\right) du,$$

kai  $k = 2, \dots, r-1$ . Jei  $\kappa_1 = \kappa_r = 0$ , tai gauname apytikslus (4) sistemos sprendinius

$$\hat{a} = \frac{1}{n} \sum_k \kappa_k \tau_k, \quad \hat{\sigma}^2 = \frac{1}{n} \sum_k \kappa_k (\tau_k - \hat{a})^2.$$

Išskleidę pointegralinius reiškinius Teiloro eilutėmis taškų  $\tau_k$  aplinkose, gautume tikslesnius sprendinius:

$$\hat{a} = \frac{1}{n} \sum_k \kappa_k \tau_k + O(h^4),$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_k \kappa_k (\tau_k - \hat{a})^2 - \frac{h^2}{12} + O(h^4).$$

Atmetę narius  $O(h^4)$ , galime gauti apytikslus (4) sistemos sprendinius:  $a$  įvertis yra sugrupuotų stebėjimo duomenų vidurkis, o  $\sigma^2$  įvertis – sugrupuotų duomenų dispersija su Šepardo pataisa.

Sprendiniai

$$(6) \quad \hat{a} = \frac{1}{n} \sum_{k=1}^r \kappa_k \tau_k,$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^r \kappa_k (\tau_k - \hat{a})^2 - \frac{h^2}{12}$$

paprastai naudojami ir tada, kai  $h$  nėra labai mažas, o  $\kappa_1$  ir  $\kappa_r$  nėra lygūs nuliui, nes dažnai jie gerai aproksimuoja (4) sistemos sprendinius. Rekomenduojama sekti, kad būtų  $np_k \geq 5$ . Kai į  $W_1$  ir  $W_r$  patenka nedaug reikšmių  $\kappa_k$ , jas galima sujungti.

3 p a v y z d y s. Buvo stebimas atsitiktinis dydis. Stebėjimo duomenys sugrupuoti, paėmus  $h = 2$ . Į intervalus [4, 6), ..., [20, 22) pateko atitinkamai 15, 20, 25, 30, 30, 27, 24, 16, 13 stebimojo dydžio reikšmių. Patikrinsime hipotezę, kad su reikšmingumu lygmeniu 0,05 atsitiktinis dydis pasiskirstęs pagal normalųjį dėsnį. Skaičiavimo rezultatai surašyti lentelėje.

k	$\kappa_k$	$p_k$	$np_k$	$(\kappa_k - np_k)^2 / (np_k)$
1	15	0,0830	16,60	0,15
2	20	0,0901	18,02	0,22
3	25	0,1359	27,18	0,17
4	30	0,2129	42,58	3,72
5	30	0,1290	25,80	0,68
6	27	0,1461	29,22	0,17
7	24	0,1017	20,34	0,66
8	16	0,0583	11,66	1,62
9	13	0,0429	8,58	2,28
Iš viso	200	0,9999	199,98	9,67

Pagal (6) formules

$$\hat{a} = 12,25; \hat{\sigma}^2 \approx 4,512.$$

Sudarome sritis  $W_1 = (-\infty, 6), W_2 = [6, 8), W_3 = [8, 10), \dots, W_8 = [18, 20), W_9 = [20, \infty)$ . Tikimybes  $p_k$  randame iš formulių

$$\begin{aligned} p_1 &= \Phi\left(\frac{6 - \hat{a}}{\hat{\sigma}}\right), \\ p_2 &= \Phi\left(\frac{8 - \hat{a}}{\hat{\sigma}}\right) - \Phi\left(\frac{10 - \hat{a}}{\hat{\sigma}}\right), \\ &\dots\dots\dots \\ p_8 &= \Phi\left(\frac{20 - \hat{a}}{\hat{\sigma}}\right) - \Phi\left(\frac{18 - \hat{a}}{\hat{\sigma}}\right), \\ p_9 &= 1 - \Phi\left(\frac{20 - \hat{a}}{\hat{\sigma}}\right). \end{aligned}$$

Lentelėje visų  $p_k$  suma dėl apvalinimo paklaidų nėra lygi 1. Pasiskirstymo  $\chi^2$  su  $9 - 2 - 1 = 6$  laisvės laipsniais 0,95-kvantilis yra apytiksliai lygus 12,592. Hipotezė priimtina.

$\chi^2$  kriterijus labai plačiai taikomas. Paminėsime dar porą atvejų. Pirmasis yra *požymių nepriklausomumo tikrinimas*. Tarkime, kad generalinės aibės elementai turi du požymius  $A$  ir  $B$ . Pirmasis požymis turi  $r$  kategorijų  $A_1, \dots, A_r$ , o antrasis –  $s$  kategorijų  $B_1, \dots, B_s$ . Vadinasi, visus generalinės aibės elementus galime suskirstyti į  $rs$  klasių, priskirdami vienai klasei elementus, turinčius požymius  $A_j$  ir  $B_k (j = 1, \dots, r; k = 1, \dots, s)$ . Pažymėkime  $p_j$  – tikimybę, kad atsitiktinai parinktas generalinės aibės elementas turi požymį  $A_j$ , raide  $p_{\cdot k}$  – tikimybę, kad jis turi požymį  $B_k$ , ir raide  $p_{jk}$  – tikimybę, kad jis turi požymius  $A_j$  ir  $B_k$ . Reikia patikrinti hipotezę, kad tie požymiai yra nepriklausomi, t. y.  $p_{jk} = p_j \cdot p_{\cdot k}$  visiems  $j = 1, \dots, r; k = 1, \dots, s$ . Aišku,

$$\sum_{j=1}^r p_{j\cdot} = 1,$$

$$\sum_{k=1}^s p_{\cdot k} = 1.$$

Kai hipotezė teisinga, tikimybės  $p_{jk}$  yra  $r + s - 2$  nežinomų parametrų  $p_{1\cdot}, \dots, p_{r-1\cdot}; p_{\cdot 1}, \dots, p_{\cdot s-1}$  funkcijos.

Pažymėkime raide  $\kappa_{jk}$  skaičių imties elementų, turinčių požymius  $A_j$  ir  $B_k$ . (4) sistema bus pavidalo

$$\sum_{j=1}^r \left( \frac{\kappa_{jk}}{p_{\cdot k}} - \frac{\kappa_{js}}{p_{\cdot s}} \right) = 0 \quad (k = 1, \dots, s-1),$$

$$\sum_{k=1}^s \left( \frac{\kappa_{jk}}{p_{j\cdot}} - \frac{\kappa_{rk}}{p_{r\cdot}} \right) = 0 \quad (j = 1, \dots, r-1).$$

Gauname įverčius

$$\hat{p}_{j\cdot} = \frac{\kappa_{j\cdot}}{n} \quad (j = 1, \dots, r),$$

$$\hat{p}_{\cdot k} = \frac{\kappa_{\cdot k}}{n} \quad (k = 1, \dots, s);$$

čia

$$\kappa_{j\cdot} = \sum_{k=1}^s \kappa_{jk} \quad (j = 1, \dots, r),$$

$$\kappa_{\cdot k} = \sum_{j=1}^r \kappa_{jk} \quad (k = 1, \dots, s).$$

(5) statistika yra pavidalo

$$(7) \quad n \sum_{j=1}^r \sum_{k=1}^s \frac{\left( \kappa_{jk} - \frac{\kappa_{j\cdot} \kappa_{\cdot k}}{n} \right)^2}{\kappa_{j\cdot} \kappa_{\cdot k}} = n \left( \sum_{j=1}^r \sum_{k=1}^s \frac{\kappa_{jk}^2}{\kappa_{j\cdot} \kappa_{\cdot k}} - 1 \right).$$

Ji yra asimptotiškai pasiskirsčiusi pagal  $\chi^2$  su  $rs - (r + s - 2) - 1 = (r - 1)(s - 1)$  laisvės laipsnių.

4 p a v y z d y s. Dvi grupės ligonių  $A$  ir  $B$ , po 100 asmenų kiekviena, serga kokia nors liga. Grupės  $A$  ligoniai buvo gydomi serumu, o grupės  $B$  ligoniai to serumo negavo ( $B$  buvo kontrolinė grupė). Šiaip abi grupės buvo gydomos vienodai. Nustatyta, kad pirmojoje grupėje pagijo 75 ligoniai, o antrojoje 65. Su reikšmingumo lygmeniu 0,05 reikia patikrinti hipotezę, kad serumas nebuvo efektyvus.

Bandyimo rezultatus surašome lentelėje.

	Pasveiko	Nepasveiko	Iš viso
Grupė A	75	25	100
Grupė B	65	35	100
Iš viso	140	60	

(7) statistikos reikšmė

$$200 \left( \frac{75^2}{140 \cdot 100} + \frac{65^2}{140 \cdot 100} + \frac{25^2}{60 \cdot 100} + \frac{35^2}{60 \cdot 100} - 1 \right) \approx 2,38.$$

$\chi^2$  pasiskirstymo su 1 laisvės laipsniu 0,95-kvantilis yra apytiksliai lygus 3,841. Todėl hipotezė atitinka stebėjimo duomenis.

Čia aprašytą procedūrą nesunku pritaikyti, remiantis anksčiau nurodytu būdu, dviejų atsitiktinių dydžių nepriklausomumui tikrinti. Paliekame tai padaryti skaitytojui.

Pritaikysime dar  $\chi^2$  kriterijų stebėjimų *homogeniškumui* tikrinti. Sakykime, turime  $s$  serijų bandymų; tose serijose yra atitinkamai  $n_1, \dots, n_s$  pavienių bandymų. Atlikus bet kurį bandymą, gali įvykti vienas iš nesutaikomų įvykių  $A_1, \dots, A_r$ ; visų tų įvykių sąjunga yra būtinas įvykis. Įvykių  $A_j$  skaičių  $k$ -ojoje bandymų serijoje pažymėkime  $\kappa_{kj}$  ( $\kappa_{k1} + \dots + \kappa_{kr} = n_k$ ), o įvykio  $A_j$  pasirodymo tikimybę, atlikus  $k$ -osios serijos bandymą, pažymėkime  $p_{kj}$  ( $p_{k1} + \dots + p_{kr} = 1$ ). Remiantis stebėjimų duomenimis, reikia patikrinti hipotezę, kad kiekvienoje bandymų serijoje įvykio  $A_j$  pasirodymo tikimybė yra ta pati:  $p_{kj} = p_j$  ( $j = 1, \dots, r; k = 1, \dots, s$ ). Jei hipotezė teisinga, tai  $p_1 + \dots + p_r = 1$ .

Sprendžiant šį uždavinį, reikia atsižvelgti į tai, kiek iš tikimybių  $p_j$  yra žinomų.

Jei visos jos žinomos ir  $s = 1$ , tai turime šio skyrelio pradžioje aprašytą atvejį. Atitinkama statistika  $\Delta_n$ , remiantis Pirsono teorema, yra asimptotiškai pasiskirsčiusi pagal  $\chi^2$  dėsnį su  $r - 1$  laisvės laipsnių. Jei  $s > 1$ , tai kiekvienai bandymų serijai sudarome statistiką  $\Delta_{n_k}$  ir visas jas sudedame. Gautoji statistika

$$\sum_{k=1}^s \sum_{j=1}^r \frac{(\kappa_{kj} - n_k p_j)^2}{n_k p_j},$$

analogiškai 1 teoremai, bus asimptotiškai pasiskirsčiusi pagal  $\chi^2$  su  $s(r - 1)$  laisvės laipsnių.

Jei visos tikimybės  $p_1, \dots, p_r$  yra nežinomos, tai  $p_{kj}$  yra nežinomų parametrų  $p_1, \dots, p_{r-1}$  funkcijos. Tų parametrų įverčius randame iš (4) lygčių sistemos; jie lygūs

$$\hat{p}_j = \frac{\kappa_{.j}}{n} \quad (j = 1, \dots, r);$$

čia  $\kappa_{.j} = \kappa_{1j} + \dots + \kappa_{sj}$ . Sudarome statistiką

$$(8) \quad \sum_{k=1}^s \sum_{j=1}^r \frac{(\kappa_{kj} - n_k \hat{p}_j)^2}{n_k \hat{p}_j} = n \left( \sum_{k=1}^s \sum_{j=1}^r \frac{\kappa_{kj}^2}{n_k \kappa_{.j}} - 1 \right).$$

Galima būtų parodyti, kad ji turi asimptotinį pasiskirstymą  $\chi^2$  su  $(r - 1) \times (s - 1)$  laisvės laipsnių, kai tikrinamoji hipotezė yra teisinga.

Jei tikimybės  $p_1, \dots, p_r$  yra parametru  $\theta_1, \dots, \theta_l$  ( $1 \leq l < s$ ) funkcijos, tai parametru  $\theta_m$  įverčius randame iš (4) sistemos ir sudarome statistiką, analogišką (5). Galima būtų parodyti, kad ji turi asimptotinį  $\chi^2$  pasiskirstymą su  $s(r - 1) - l$  laisvės laipsnių.

5 p a v z d y s. Lentelėje pateikti įvairiais 1935 m. mėnesiais Švedijoje gimusių berniukų ir mergaičių skaičiai (pavyzdys paimtas iš [6] knygos).

Mėnuo	Berniukų skaičius	Mergaičių skaičius	Iš viso
1	3743	3537	7280
2	3550	3407	6957
3	4017	3866	7883
4	4173	3711	7884
5	4117	3775	7892
6	3944	3665	7609
7	3964	3621	7585
8	3797	3596	7393
9	3712	3491	7203
10	3512	3991	6903
11	3392	3160	6552
12	3761	3371	7132
Iš viso	45682	42591	88273

Su reikšmingumo lygmeniu 0,05 patikrinsime hipotezę, kad visais mėnesiais berniuko gimimo tikimybė yra ta pati.

Čia turime  $r = 2, s = 12$ . Nežinomas parametras yra berniuko gimimo tikimybė  $p$ . Jos įvertis  $\hat{p} = \kappa_{.1}/n$ .

(8) statistikos

$$\begin{aligned} & \sum_{k=1}^{12} \left( \frac{(\kappa_{k1} - n_k \hat{p})^2}{n_k \hat{p}} + \frac{(\kappa_{k2} - n_k(1 - \hat{p}))^2}{n_k(1 - \hat{p})} \right) = \\ & = \sum_{k=1}^{12} \frac{(\kappa_{k1} - n_k \hat{p})^2}{n_k \hat{p}(1 - \hat{p})} = \frac{1}{1 - \hat{p}} \left( \frac{1}{\hat{p}} \sum_{k=1}^{12} \frac{\kappa_{k1}^2}{n_k} - \kappa_{.1} \right) \end{aligned}$$

reikšmė yra apytiksliai lygi 14,986.  $\chi^2$  su  $(s - 1)(r - 1) = 11$  laisvės laipsnių 0,95-kvantis yra 19,675. Galime laikyti, kad hipotezė neprieštarauja stebėjimo duomenims.

### 13. KRITERIJAI, PAGRĮSTI EMPIRINĖS IR TEORINĖS PASISKIRSTYMO FUNKCIJŲ SKIRTUMU

Nagrinėsime, kaip empirinė pasiskirstymo funkcija aproksimuoja teorinę pasiskirstymo funkciją.

Tarkime, kad stebimojo atsitiktinio dydžio su pasiskirstymo funkcija  $F(y)$  atsitiktinė imtis yra  $(X_1, \dots, X_n)$ . Jo empirinę pasiskirstymo funkciją apibrėžėme 2 skyrelyje. Kiekvienam fiksuotam  $y$  tai yra atsitiktinis dydis

$$\mathcal{F}_n(y) = \frac{1}{n} \sum_{X_k < y} 1.$$

Pažymėkime  $Y_{ky}$  atsitiktinį dydį, įgyjantį reikšmę 1 su tikimybe  $\mathcal{P}(X_k < y) = F(y)$  ir reikšmę 0 su tikimybe  $\mathcal{P}(X_k \geq y) = 1 - F(y)$ . Dydžiai  $Y_{1y}, \dots, Y_{ny}$  yra nepriklausomi. Tada empirinę pasiskirstymo funkciją galime užrašyti šitaip:

$$\mathcal{F}_n(y) = \frac{1}{n} \sum_{k=1}^n Y_{ky}.$$

Pastebėsime, kad dydžio  $Y_{ky}$  vidurkis

$$MY_{ky} = F(y),$$

o dispersija

$$DY_{ky} = F(y)(1 - F(y)).$$

Iš vidurkio ir dispersijos savybių išplaukia, kad

$$M\mathcal{F}_n(y) = F(y), \quad D\mathcal{F}_n(y) = \frac{1}{n}F(y)(1 - F(y)).$$

Iš stipriojo didžiųjų skaičių dėsnio (III.5.2 teoremos 2 išvados) išplaukia, kad kiekvienam  $y \in R$  empirinė pasiskirstymo funkcija konverguoja su tikimybe 1 į teorinę pasiskirstymo funkciją

$$\mathcal{P}\{\mathcal{F}_n(y) \xrightarrow[n \rightarrow \infty]{} F(y)\} = 1.$$

Vadinasi,  $\mathcal{F}_n(y)$  yra nepaslinktasis ir suderintasis  $F(y)$  įvertis.

Dar daugiau: iš centrinės ribinės teoremos (III.11.2 teoremos 2 išvados) išplaukia, kad kiekvienam  $y \in R$  su sąlyga  $0 < F(y) < 1$

$$\mathcal{P} \left\{ \frac{\sum_{k=1}^n (Y_{ky} - MY_{ky})}{\left( \sum_{k=1}^n DY_{ky} \right)^{1/2}} < u \right\} = \mathcal{P} \left\{ \frac{\sqrt{n}(\mathcal{F}_n(y) - F(y))}{\sqrt{F(y)(1 - F(y))}} < u \right\} \xrightarrow{n \rightarrow \infty} \Phi(u).$$

Šie teiginiai rodo, kad kiekvienam fiksuotam  $y \in R$  empirinė pasiskirstymo funkcija  $\mathcal{F}_n(y)$  artėja prie tikrosios pasiskirstymo funkcijos  $F(y)$ . V. Glivenka<sup>1</sup> 1933 m. įrodė, kad  $\mathcal{F}_n(y)$  su tikimybe 1 konverguoja į  $F(y)$  tolygiai visiems  $y \in R$ . Įrodysime tą teoremą.

**1 lema.** *Jei turime baigtinę arba skaičių įvykių sistemą  $\{A_k\}$  ir kiekvieno jų tikimybė  $P(A_k) = 1$ , tai ir tos sistemos sankirtos tikimybė*

$$P\left(\bigcap_k A_k\right) = 1.$$

**Į r o d y m a s.** Kadangi

$$P\left(\bigcup_k A_k^c\right) \leq \sum_k P(A_k^c)$$

ir  $P(A_k^c) = 0$ , tai

$$P\left(\bigcup_k A_k^c\right) = 0.$$

Iš čia

$$P\left(\bigcap_k A_k\right) = 1 - P\left(\left(\bigcap_k A_k\right)^c\right) = 1 - P\left(\bigcup_k A_k^c\right) = 1. \quad \square$$

**1(Glivenkos) teorema.** *Jei  $F(y)$  yra atsitiktinio dydžio pasiskirstymo funkcija, o  $\mathcal{F}_n(y)$  – jo empirinė pasiskirstymo funkcija, tai*

$$\mathcal{P}\left\{ \sup_{-\infty < y < \infty} |\mathcal{F}_n(y) - F(y)| \xrightarrow{n \rightarrow \infty} 0 \right\} = 1.$$

**Į r o d y m a s.** Imkime bet kuri natūralųjį skaičių  $r$ . Pažymėkime  $y_{rk}$  ( $k = 1, \dots, r$ ) mažiausią  $y$ , tenkinantį nelygybes

<sup>1</sup> Valerijus Glivenka (1897–1940) – ukrainiečių kilmės matematikas.

$$F(y) \leq \frac{k}{r} \leq F(y + 0).$$

Tarkime, kad

$$\begin{aligned} E_{rk} &= \left\{ \mathcal{F}_n(y_{rk}) \xrightarrow{n \rightarrow \infty} F(y_{rk}) \right\}, \\ E_r &= E_{r1} \cap \dots \cap E_{rr} = \left\{ \max_{1 \leq k \leq r} |\mathcal{F}_n(y_{rk}) - F(y_{rk})| \xrightarrow{n \rightarrow \infty} 0 \right\}, \\ E &= E_1 \cap E_2 \cap \dots = \left\{ \max_{1 \leq k \leq r} |\mathcal{F}_n(y_{rk}) - F(y_{rk})| \xrightarrow{n \rightarrow \infty} 0; r = 1, 2, \dots \right\}. \end{aligned}$$

Iš stipriojo didžiųjų skaičių dėsnio išplaukia, kad

$$\mathcal{P}(E_{rk}) = 1 \quad (r = 1, 2, \dots; k = 1, \dots, r).$$

Pagal 1 lemą

$$(1) \quad \begin{aligned} \mathcal{P}(E_r) &= 1, \\ \mathcal{P}(E) &= 1. \end{aligned}$$

Pažymėkime

$$C = \left\{ \sup_{-\infty < y < \infty} |\mathcal{F}_n(y) - F(y)| \xrightarrow{n \rightarrow \infty} 0 \right\}.$$

Jei įrodytume, kad  $E \subset C$ , tai iš (1) išplauktų teoremos teiginys.

Kiekvienam  $y \in (y_{rk}, y_{r,k+1}]$  teisingos nelygybės

$$(2) \quad \mathcal{F}_n(y_{rk} + 0) \leq \mathcal{F}_n(y) \leq \mathcal{F}_n(y_{r,k+1})$$

ir

$$(3) \quad F(y_{rk} + 0) \leq F(y) \leq F(y_{r,k+1}),$$

be to,

$$(4) \quad 0 \leq F(y_{r,k+1}) - F(y_{rk} + 0) \leq \frac{1}{r}.$$

Atėmę iš (2) nelygybės (3), gauname

$$\mathcal{F}_n(y_{rk} + 0) - F(y_{r,k+1}) \leq \mathcal{F}_n(y) - F(y) \leq \mathcal{F}_n(y_{r,k+1}) - F(y_{rk} + 0).$$

Iš čia ir iš (4) nelygybės išplaukia

$$|\mathcal{F}_n(y) - F(y)| \leq \max_{1 \leq k \leq r} |\mathcal{F}_n(y_{rk}) - F(y_{rk})| + \frac{1}{r}.$$

Todėl

$$\sup_{-\infty < y < \infty} |\mathcal{F}_n(y) - F(y)| \leq \max_{1 \leq k \leq r} |\mathcal{F}_n(y_{rk}) - F(y_{rk})| + \frac{1}{r}.$$

Kadangi ši nelygybė yra teisinga kiekvienam  $r$ , tai galime padaryti išvadą, kad  $E \subset C$ .  $\square$

Pažymėję

$$\mathcal{D}_n = \sup_y |\mathcal{F}_n(y) - F(y)|,$$

Glivenkos teoremą galime užrašyti šitaip:

$$\mathcal{P}(\mathcal{D}_n \xrightarrow[n \rightarrow \infty]{} 0) = 1.$$

Statistika  $\mathcal{D}_n$  yra funkcijos  $\mathcal{F}_n$  nuokrypio nuo  $F$  matas. Pasirodo, kad tolydziosioms pasiskirstymo funkcijoms (įprasta matematinėje analizėje prasme)  $\mathcal{D}_n$  pasiskirstymas nepriklauso nuo  $F$ .

**2 lema.** *Jei  $Z$  yra atsitiktinis dydis su tolydzia pasiskirstymo funkcija  $H(z)$ , tai atsitiktinio dydžio  $Y = H(Z)$  pasiskirstymo funkcija yra*

$$G(y) = \begin{cases} 0, & \text{kai } y \leq 0, \\ y, & \text{kai } 0 < y \leq 1, \\ 1, & \text{kai } y > 1. \end{cases}$$

*Vadinasi,  $Y$  yra tolygiai pasiskirstęs intervale  $(0, 1)$ .*

**I r o d y m a s.** Tolydi funkcija  $y = H(z)$  atvaizduoja tiesę  $R$  į vieną iš intervalų  $[0, 1]$ ,  $[0, 1)$ ,  $(0, 1]$ ,  $(0, 1)$ . Jei  $H(z)$  yra (griežtai) didėjanti, tai tas atvaizdis yra abipus vienareikšmis. Bendresniu atveju (kai  $H(z)$  yra nemažėjanti ir egzistuoja intervalai, kuriuose ji yra pastovi) vieną  $y$  reikšmę gali atitikti daugiau  $z$  reikšmių – visas neišsigimęs intervalas. Kiekvienam  $y \in (0, 1]$  apibrėžkime

$$z_y = \inf\{z : H(z) = y\}.$$

Iš funkcijos  $H(z)$  tolydumo išplaukia, kad  $H(z_y) = y$ .

Lemą pakanka įrodyti tik visiems  $y \in (0, 1)$ . Turime

$$\begin{aligned} G(y) &= P(Y < y) = P\{H(Z) < y\} = P\{H(Z) < H(z_y)\} = \\ &= P(Z < z_y) = H(z_y) = y. \quad \square \end{aligned}$$

**2 teorema.** *Kiekvienai tolydziajai pasiskirstymo funkcijai  $F(y)$  statistika  $\mathcal{D}_n$  turi tą patį pasiskirstymą.*

**I r o d y m a s.** Kaip ir visame šiame skyrelyje,  $(X_1, \dots, X_n)$  žymėsime atsitiktinę imtį. Stebimojo atsitiktinio dydžio pasiskirstymo funkcijos  $F(y)$  pastovumo intervalu vadinsime kiekvieną uždara intervalą  $[b, c]$ , jei  $\mathcal{P}\{X_1 \in [b, c]\} = 0$  ir nėra kito uždaro intervalo, kuriam priklausytų  $[b, c]$  su ta

savybe. Išmeskime iš  $R$  visus pastovumo intervalus. Gautą aibę pažymėkime  $A$ . Tada

$$\mathcal{D}_n = \sup_{y \in R} |\mathcal{F}_n(y) - F(y)| = \sup_{y \in A} |\mathcal{F}_n(y) - F(y)|$$

ir kiekvienam  $y \in A$

$$\{X_k < y\} = \{F(X_k) < F(y)\}.$$

Pažymėkime  $U_k = F(X_k)$  ir

$$\mathcal{G}_n(y) = \frac{1}{n} \sum_{U_k < y} 1.$$

Tada visiems  $y \in A$

$$\mathcal{G}_n(F(y)) = \frac{1}{n} \sum_{F(X_k) < F(y)} 1 = \frac{1}{n} \sum_{X_k < y} 1 = \mathcal{F}_n(y).$$

Vadinasi,

$$\begin{aligned} \mathcal{D}_n &= \sup_{y \in A} |\mathcal{G}_n(F(y)) - F(y)| = \\ &= \sup_{y \in R} |\mathcal{G}_n(F(y)) - F(y)| = \sup_{0 \leq u \leq 1} |\mathcal{G}_n(u) - u|. \end{aligned}$$

Teorema išplaukia iš 2 lemos.  $\square$

Teoremos įrodymas yra ir būdas statistikos  $\mathcal{D}_n$  pasiskirstymo funkcijai rasti. Tam reikia imti atsitiktinio dydžio, tolygiai pasiskirsčiusio intervale  $(0, 1)$ , empirinę pasiskirstymo funkciją  $\mathcal{G}_n(u)$  ir apskaičiuoti statistikos

$$\sup_{0 \leq u \leq 1} |\mathcal{G}_n(u) - u|$$

pasiskirstymo funkciją. Ji bus ir  $\mathcal{D}_n$  pasiskirstymo funkcija.

Galima rasti gana paprastą ribinį statistikos  $\mathcal{D}_n$  pasiskirstymą.

**3 (Kolmogorovo) teorema.** *Kiekvienai tolydžiajai pasiskirstymo funkcijai  $F(y)$*

$$\mathcal{P}(\sqrt{n}\mathcal{D}_n < y) \rightarrow K(y);$$

čia

$$K(y) = \begin{cases} 0, & \text{kai } y \leq 0, \\ \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2 y^2}, & \text{kai } y > 0. \end{cases}$$

Šios teoremos įrodymo idėja išdėstyta 14 skyrelyje.

Funkcija  $K(y)$  yra tabuluota (žr. [17], XII lentelę, [2], 6.1, 6.2 lenteles).

Remdamiesi šiais rezultatais, pagal jau gerai žinomą schemą galime sudaryti Kolmogorovo kriterijų tikrinti hipotezei, kad stebimasis dydis yra pasiskirstęs pagal tolydujį dėsnį  $F(x)$ . Tarkime, kad konkretūs stebėjimo rezultatai surašyti nemažėjančia tvarka. Turime variacinę seką  $x_1^* \leq x_2^* \leq \dots \leq x_n^*$ . Apskaičiuojame dydžius

$$D_n^+ = \max_{1 \leq k \leq n} \left( \frac{k}{n} - F_n(x_k^*) \right), \quad D_n^- = \max_{1 \leq k \leq n} \left( F_n(x_k^*) - \frac{k-1}{n} \right).$$

Tada

$$D_n = \max(D_n^+, D_n^-).$$

Paėmę reikšmingumo lygmenį  $\alpha$ , iš lentelių randame  $\mathcal{D}_n$  pasiskirstymo  $(1-\alpha)$ -kvantilį  $u_\alpha$ . Kai  $n$  dideli, galima remtis Kolmogorovo teorema. Kai  $n \geq 10$  ir  $0,01 \leq \alpha \leq 0,2$ , galima naudotis apytiksle formule

$$u_\alpha \approx \sqrt{\frac{1}{2n} \left( v - \frac{2v^2 - 4v - 1}{18n} \right)} - \frac{1}{6n} \approx \sqrt{\frac{v}{2n}} - \frac{1}{6n};$$

čia  $v = -\ln(\alpha/2)$ .

Jei  $D_n > u_\alpha$ , tai hipotezė atmestina, priešingu atveju galime manyti, kad ji neprieštarauja stebėjimo duomenims.

Empirinės funkcijos nuokrypį nuo teorinės galima apibūdinti ir kitais būdais. H. Krameras 1928 m. ir nepriklausomai nuo jo R. Mizesas<sup>1</sup> 1931 m. pasiūlė tam reikalui naudoti statistiką

$$\int_{-\infty}^{\infty} (\mathcal{F}_n(y) - F(y))^2 dL(y)$$

su nemažėjančia funkcija  $L(y)$ . Paprastai naudojamos dvi statistikos

$$\omega_n^2 = \int_{-\infty}^{\infty} (\mathcal{F}_n(y) - F(y))^2 dF(y),$$

$$\Omega_n^2 = \int_{-\infty}^{\infty} \frac{(\mathcal{F}_n(y) - F(y))^2}{F(y)(1-F(y))} dF(y).$$

Čia funkcija  $F(y)$ , kaip ir anksčiau, yra tolydi. Galima būtų įrodyti, kad

$$n\omega_n^2 = \sum_{k=1}^n \left( F(X_k^*) - \frac{2k-1}{2n} \right)^2 + \frac{1}{12n},$$

$$n\Omega_n^2 = -2 \sum_{k=1}^n \left[ \frac{2k-1}{2n} \ln F(X_k^*) + \left( 1 - \frac{2k-1}{2n} \right) \ln \left( 1 - F(X_k^*) \right) \right] - n$$

<sup>1</sup> Richard von Mises (1883–1953) – vokiečių matematikas.

ir kad tų statistikų pasiskirstymai nepriklauso nuo funkcijos  $F(y)$ . Įrodyta, kad egzistuoja ir tų statistikų ribiniai pasiskirstymai

$$\mathcal{P}(n\omega_n^2 < u) \rightarrow a_1(u),$$

$$\mathcal{P}(n\Omega_n^2 < u) \rightarrow a_2(u).$$

Funkcijų  $a_1(u)$  ir  $a_2(u)$  analizinės išraiškos yra gana sudėtingos. Jos – tabuliuotos (žr. [17], XV, XVI lentelės, [2], 6.4 lentelę ir artutines formules). Šiais rezultatais pagrįstas vadinamasis  $\omega^2$ , arba Kramero–Mizeso, kriterijus tikrinti hipotezei, kad stebimasis dydis yra pasiskirstęs pagal tolydujį dėsnį  $F(y)$ . Jis sudaromas jau mums žinomais metodais.

P a v y z d y s. Automatinės staklės gamina rutuliukus. Atsitiktinai parinkti 25 rutuliukai ir išmatuotas jų skersmuo (milimetrais). Gautieji rezultatai surašyti lentelėje didėjančia tvarka. Su reikšmingumo lygmeniu  $\alpha = 0,05$  reikia patikrinti hipotezę, kad rutuliukų skersmenys pasiskirstę pagal  $N(12; 0, 1)$ . Skaičiavimų rezultatai surašyti lentelėje. Čia  $z_k = 10(x_k^* - 12)$ . Rezultatai apvalinami 0,001 tikslumu.

k	$x_k^*$	$k/n$	$z_k$	$\Phi(z_k)$	$k/n - \Phi(z_k)$	$\Phi(z_k) - (k - 1)/n$
1	11,790	0,04	-2,10	0,018	0,022	0,018
2	11,834	0,08	-1,66	0,048	0,032	0,008
3	11,862	0,12	-1,38	0,084	0,036	0,004
4	11,882	0,16	-1,18	0,119	0,041	-0,001
5	11,902	0,20	-0,98	0,164	0,036	0,004
6	11,912	0,24	-0,88	0,189	0,051	-0,011
7	11,916	0,28	-0,84	0,200	0,080	-0,040
8	11,944	0,32	-0,56	0,288	0,032	0,008
9	11,954	0,36	-0,46	0,323	0,037	0,003
10	11,970	0,40	-0,30	0,382	0,018	0,022
11	11,986	0,44	-0,14	0,444	-0,004	0,044
12	11,990	0,48	-0,10	0,460	0,020	0,016
13	12,002	0,52	0,02	0,508	0,012	0,028
14	12,006	0,56	0,06	0,524	0,036	0,004
15	12,018	0,60	0,18	0,571	0,029	0,011
16	12,030	0,64	0,30	0,618	0,022	0,018
17	12,034	0,68	0,34	0,633	0,047	-0,007
18	12,040	0,72	0,40	0,655	0,017	-0,025
19	12,052	0,76	0,52	0,698	0,062	-0,022
20	12,062	0,80	0,62	0,732	0,068	-0,028

k	$x_k^*$	$k/n$	$z_k$	$\Phi(z_k)$	$k/n - \Phi(z_k)$	$\Phi(z_k) - (k-1)/n$
21	12,072	0,84	0,72	0,764	0,076	-0,036
22	12,090	0,88	0,90	0,816	0,064	-0,024
23	12,100	0,92	1,00	0,841	0,079	-0,039
24	12,122	0,96	1,22	0,889	0,071	-0,031
25	12,130	1,00	1,30	0,903	0,097	-0,057

Skaičiavimai rodo, kad

$$D_n = 0,097.$$

Iš lentelių randame, kad  $D_n$  pasiskirstymo 0,95-kvantis yra apytiksliai lygus 0,264. Hipotezė atitinka stebėjimo duomenis.

Analogišką išvadą gautume ir pritaikę  $\omega^2$  kriterijų.

## 14. SMIRNOVO KRITERIJUS

Sakykime, stebime du atsitiktinius dydžius ir turime dvi tų dydžių nepriklausomų stebėjimų serijas

$$X_1, \dots, X_n,$$

$$Y_1, \dots, Y_m.$$

Remiantis stebėjimų duomenimis, reikia patikrinti hipotezę, kad abu dydžiai yra vienodai pasiskirstę. Su tokiais uždaviniais jau susidūrėme, kai abu stebimieji dydžiai turėjo tą patį pasiskirstymo tipą ir reikėjo patikrinti hipotezę, kad pasiskirstymų parametrai yra lygūs. Sprendžiant šį uždavinį, galima buvo taikyti ir  $\chi^2$  kriterijų.

Jei apie abiejų dydžių pasiskirstymą žinoma tik tiek, kad jie yra tolydūs, tai galima taikyti Smirnovo<sup>1</sup> kriterijų, su kurio teorija dabar susipažinsime.

Taigi tarkime, kad abu dydžiai turi tą pačią tolydžią pasiskirstymo funkciją  $F(u)$ . Pažymėkime pirmosios imties empirinę pasiskirstymo funkciją  $\mathcal{F}_n(u)$ , o antrosios –  $\mathcal{G}_m(u)$  ir sudarykime statistikas

$$\mathcal{D}_{nm}^+ = \sup_{-\infty < u < \infty} (\mathcal{F}_n(u) - \mathcal{G}_m(u)),$$

$$\mathcal{D}_{nm} = \sup_{-\infty < u < \infty} |\mathcal{F}_n(u) - \mathcal{G}_m(u)|.$$

Pasirodo, kad abiejų tų statistikų pasiskirstymas priklauso tik nuo  $n$  ir  $m$ , bet nepriklauso nuo  $F$ , jei tik ji yra tolydi.

Kad būtų paprasčiau, nagrinėsime tik specialų atvejį  $n = m$ . Žymėsime

<sup>1</sup> Nikolajus Smirnovas (1900–1966) – rusų matematikas.

$$\mathcal{D}_n^+ = \mathcal{D}_{nn}^+, \quad \mathcal{D}_n = \mathcal{D}_{nn}.$$

**1 teorema.** *Jei abu stebimieji dydžiai yra tolydūs ir vienodai pasiskirstę, tai sveikiesiems  $s$*

$$\mathcal{P}(n\mathcal{D}_n^+ < s) = \begin{cases} 0, & \text{kai } s \leq 0, \\ 1 - \frac{\binom{2n}{n-s}}{\binom{2n}{n}}, & \text{kai } 0 < s \leq n, \\ 1, & \text{kai } s > n. \end{cases}$$

**I r o d y m a s.** Kadangi stebimieji dydžiai yra tolydūs, tai tarp stebėjimo rezultatų  $X_1, \dots, X_n, Y_1, \dots, Y_n$  lygūs galės būti tik su tikimybe 0. Todėl laikysime visus stebėjimo rezultatus skirtingais. Surašysime juos didėjančia tvarka

$$Z_1 < Z_2 < \dots < Z_{2n}.$$

Įvesime pagalbinius dydžius  $U_1, \dots, U_{2n}$ , imdami  $U_k = 1$ , kai  $Z_k$  yra iš pirmosios, ir  $U_k = -1$ , kai  $Z_k$  yra iš antrosios imties. Pažymėkime  $V_0 = 0, V_k = U_1 + \dots + U_k$  ( $k = 1, \dots, 2n$ ). Skaičius  $n(\mathcal{F}_n(u) - \mathcal{G}_n(u))$  yra imties  $X_1, \dots, X_n$  elementų, mažesnių už  $u$ , ir imties  $Y_1, \dots, Y_n$  elementų, mažesnių už  $u$ , skaičių skirtumas. Jei  $u$  prabėga visą realiųjų skaičių tiesę, tai  $n(\mathcal{F}_n(u) - \mathcal{G}_n(u))$  pasikeičia tik tada, kai  $u$  peržengia reikšmes  $Z_k$  ( $k = 1, \dots, 2n$ ); pokytis yra  $U_k$ . Todėl

$$n\mathcal{D}_n^+ = \max_{1 \leq k \leq 2n} n(\mathcal{F}_n(Z_k + 0) - \mathcal{G}_n(Z_k + 0)) = \max_{1 \leq k \leq 2n} V_k.$$

Skaičius galimų sekų  $U_1, \dots, U_{2n}$  yra lygus skaičiui derinių iš  $2n$  elementų po  $n$ , t. y.

$$\binom{2n}{n}.$$

Kadangi  $X_1, \dots, X_n, Y_1, \dots, Y_n$  yra nepriklausomi ir turi tuos pačius pasiskirstymus, tai kiekviena seka  $U_1, \dots, U_{2n}$  turi tą pačią tikimybę

$$1/\binom{2n}{n}.$$

Reikia rasti skaičių tų sekų  $U_1, \dots, U_{2n}$ , kurioms  $\max V_k < s$ . Tam pravers geometrinė interpretacija. Plokštumoje  $(v, t)$  atidėkime taškus su koordinatėmis  $(k, V_k)$  ( $k = 0, 1, \dots, 2n$ ) ir sujunkime juos atkarpomis. Gausime lauztę. Jos pradžia bus taške  $(0, 0)$ , galas – taške  $(2n, 0)$ . Atkarpos su abscesijų ašimi sudaro  $45^\circ$  arba  $-45^\circ$  kampus; abiejų rūšių atkarpų bus po  $n$ . Reikia rasti skaičių lauzčių, nekertančių tiesės  $t = s$ . Tuo tikslu kiekvieną lauztę,

pasiekiančią tiesę  $t = s$ , pakeiskime nauja laužte, kuri nuo  $(0, 0)$  iki pirmojo susikirtimo su  $t = s$  sutampa su pirmąsiais laužte, o vėliau yra pastarosios veidrodinis atspindys tos tiesės atžvilgiu. Naujoji laužtė prasidės taške  $(0, 0)$  ir baigsis taške  $(2n, 2s)$ . Joje turi būti  $n + s$  pakilimų ir  $n - s$  nusileidimų. Todėl tokių laužčių bus

$$\binom{2n}{n-s}.$$

Vadinasi, skaičius pirmųjų laužčių, nepasiekiančių tiesės  $t = s$ , yra

$$\binom{2n}{n} - \binom{2n}{n-s}. \quad \square$$

**2 teorema.** *Jei išpildytos 1 teoremos sąlygos, tai*

$$\mathcal{P}\left(\mathcal{D}_n^+ \sqrt{\frac{n}{2}} < z\right) \rightarrow \begin{cases} 0, & \text{kai } z \leq 0, \\ 1 - e^{-2z^2}, & \text{kai } z > 0. \end{cases}$$

**I r o d y m a s.** Pastebėsime, kad

$$\mathcal{P}\left(\mathcal{D}_n^+ \sqrt{\frac{n}{2}} < z\right) = \mathcal{P}(n\mathcal{D}_n^+ < z\sqrt{2n}).$$

Tirdami šios tikimybės asimptotiką, remsimės 1 teorema. Pakanka nagrinėti atvejį, kai  $z > 0$ . Pažymėkime  $s = z\sqrt{2n}$ , kai tas skaičius yra sveikasis, ir  $s = [z\sqrt{2n}] + 1$ , kai jis nėra sveikas. Taigi  $s = z\sqrt{2n} + \delta$ ,  $0 \leq \delta < 1$ . Laikysime, kad  $n$  yra didelis.

Iš Stirlingo formulės (žr. I.6 skyrelį), pažymėję

$$p = \frac{\binom{2n}{n-s}}{\binom{2n}{n}} = \frac{(n!)^2}{(n+s)!(n-s)!},$$

gauname

$$(1) \quad \begin{aligned} \ln p &= (2n+1) \ln n - \left(n+s+\frac{1}{2}\right) \ln(n+s) - \\ &\quad - \left(n-s+\frac{1}{2}\right) \ln(n-s) + O\left(\frac{1}{n}\right). \end{aligned}$$

Kadangi pagal 12 skyrelio lema

$$\ln(n+s) = \ln n + \ln\left(1 + \frac{s}{n}\right) = \ln n + \frac{s}{n} - \frac{s^2}{2n^2} + O\left(\frac{s^3}{n^3}\right),$$

$$\ln(n-s) = \ln n - \frac{s}{n} - \frac{s^2}{2n^2} + O\left(\frac{s^3}{n^3}\right),$$

tai iš (1), atlikę paprastus skaičiavimus, gauname

$$\ln p = -\frac{s^2}{n} + O(n^{-1/2}) = -2z^2 + O(n^{-1/2}).$$

Vadinasi,

$$\mathcal{P}\left(\mathcal{D}_n^+ \sqrt{\frac{n}{2}} < z\right) = 1 - \exp\{-2z^2 + O(n^{-1/2})\} \rightarrow 1 - e^{-2z^2},$$

kai  $n \rightarrow \infty$ .  $\square$

**3 teorema.** *Jei teisingos 1 teoremos sąlygos, tai sveikiesiems  $s$*

$$\mathcal{P}(n\mathcal{D}_n < s) = \begin{cases} 0, & \text{kai } s \leq 1, \\ \frac{1}{\binom{2n}{n}} \sum_{k=-\lfloor n/s \rfloor}^{\lfloor n/s \rfloor} \binom{2n}{n-ks}, & \text{kai } 1 < s \leq n, \\ 1, & \text{kai } s > n. \end{cases}$$

Į r o d y m a s panašus į 1 teoremos įrodymą. Vartosime vėl tuos pačius žymėjimus ir remsimės ta pačia geometrine interpretacija. Ši kartą ieškosime skaičiaus  $N_0$  laužčių, kurios telpa tarp tiesių  $t = -s$  ir  $t = s$ , jų nepasiekdamos.

Kaip žinome, laužčių yra iš viso

$$N = \binom{2n}{n}.$$

Ieškomąjį laužčių skaičių  $N_0$  gausime, atmetę iš  $N$  skaičių laužčių, kurios turi bendrą tašką su tiesėmis  $t = -s, t = s$ . Pirmiausia atmesime skaičių  $N(+)$  laužčių, kurios turi bendrą tašką su  $t = s$ , ir skaičių  $N(-)$  laužčių, kurios turi bendrą tašką su  $t = -s$ . Tačiau tada bus du kartus atmestos laužtės, turinčios bendrą tašką su abiem tiesėmis. Todėl pridėsime skaičių  $N(+, -)$  laužčių, kurios po bendro taško su  $t = s$  turi bendrą tašką su  $t = -s$ , ir skaičių  $N(-, +)$  laužčių, kurios po bendro taško su  $t = -s$  turi bendrą tašką su  $t = s$ . Kai kurios laužtės bus pridėtos du kartus. Todėl tęsime šiuos samprotavimus. Vartodami lengvai suvokiamus žymėjimus, gausime

$$N_0 = N - N(+)-N(-) + N(+, -) + N(-, +) - N(+, -, +) - \\ - N(-, +, -) + \dots$$

1 teoremos įrodyme gavome

$$N(+)=\binom{2n}{n-s}.$$

Skaičius  $N(-)=N(+)$ . Tai išplaukia iš simetriškumo.

Apskaičiuosime  $N(+,-)$ . Kiekvieną laužtę, išeinančią iš taško  $(0,0)$  ir pasiekiančią tiesę  $t=s$ , pakeisime nauja laužte, kuri sutampa su pirmąja nuo  $(0,0)$  iki bendro taško su  $t=s$ , o toliau yra jos veidrodinis atspindys tiesės  $t=s$  atžvilgiu. Taip gauta laužtė pasibaigs taške  $(2n,2s)$ . Jei pirmąją laužtę iš pradžių turi bendrą tašką su  $t=s$ , o po to su  $t=-s$ , tai ką tik gauta naujoji laužtė pasieks tiesę  $t=3s$ . Konstruojame dar vieną laužtę, kuri sutaps su naująja iki bendro taško su  $t=3s$ , o po to sutaps su pirmąją laužtės veidrodiniu atspindžiu tiesės  $t=3s$  atžvilgiu. Vadinasi, naujausioji laužtė baigsis taške  $(2n,4s)$ . Tokių naujausių laužčių yra

$$\binom{2n}{n-2s}.$$

Taigi

$$N(+,-)=N(-,+)=\binom{2n}{n-2s}=\binom{2n}{n+2s}.$$

Analogiškai samprotaudami, galime gauti

$$N(\varepsilon_1,\varepsilon_2,\dots,\varepsilon_k)=\binom{2n}{n-ks}=\binom{2n}{n+ks},$$

kai  $\varepsilon_1,\dots,\varepsilon_k$  yra alternuojanti  $+$  ir  $-$  seka.

Galutinai

$$N_0=\sum_{k=-[n/s]}^{[n/s]}(-1)^k\binom{2n}{n-ks}.\quad \square$$

**4 teorema.** *Jei teisingos 1 teoremos sąlygos, tai*

$$\mathcal{P}\left(\mathcal{D}_n\sqrt{\frac{n}{2}}<z\right)\rightarrow K(z),$$

kai  $n\rightarrow\infty$ ; čia  $K(z)$  yra 13.3 teoremoje apibrėžta funkcija.

**Į r o d y m a s.** Pakanka nagrinėti atvejį, kai  $z>0$ . Toliau  $z$  laikysime fiksuotu, o  $n$  – pakankamai dideliu. Atkreipsime dėmesį, kad

$$\mathcal{P}\left(\mathcal{D}_n\sqrt{\frac{n}{2}}<z\right)=\mathcal{P}(n\mathcal{D}_n<z_n);$$

čia  $z_n = z\sqrt{2n}$ , kai pastarasis skaičius yra sveikasis, ir  $z_n = [z\sqrt{2n}] + 1$ , kai jis nėra sveikasis. Tada

$$\begin{aligned} \mathcal{P}\left(\mathcal{D}_n\sqrt{\frac{n}{2}} < z\right) &= \sum_{k=-[n/z_n]}^{[n/z_n]} (-1)^k \frac{\binom{2n}{n-kz_n}}{\binom{2n}{n}} = \\ &= \sum_{k=-[n/z_n]}^{[n/z_n]} (-1)^k \frac{(n!)^2}{(n-kz_n)!(n+kz_n)!}. \end{aligned}$$

Paėmę bet koki  $\varepsilon > 0$ , parinkime tokį sveikąjį teigiamą  $n_0$ , kad būtų

$$e^{-2n_0^2 z^2} < \frac{\varepsilon}{16}, \quad \left| \sum_{|k|>n_0} (-1)^k e^{-2k^2 z^2} \right| < \frac{\varepsilon}{6}.$$

Kaip ir 2 teoremos įrodyme, iš Stirlingo formulės gauname (skaičiavimus paliekame skaitytojui)

$$\frac{(n!)^2}{(n-kz_n)!(n+kz_n)!} = e^{-2k^2 z^2} (1 + o(1))$$

tolygiai visiems  $k$  su sąlyga  $|k| \leq n_0$ . Todėl

$$\begin{aligned} &\left| \sum_{k=-n_0}^{n_0} (-1)^k e^{-2k^2 z^2} - \sum_{k=-n_0}^{n_0} (-1)^k \frac{(n!)^2}{(n-kz_n)!(n+kz_n)!} \right| = \\ &= o(1) \sum_{k=-n_0}^{n_0} e^{-2k^2 z^2} < \frac{\varepsilon}{2} \end{aligned}$$

pakankamai dideliems  $n$ . Kadangi

$$\binom{2n}{n-kz_n} > \binom{2n}{n-(k+1)z_n},$$

tai

$$\begin{aligned} &\left| \sum_{n_0 < |k| \leq z_n} (-1)^k \frac{(n!)^2}{(n-kz_n)!(n+kz_n)!} \right| < \\ &< \frac{4(n!)^2}{(n-n_0z_n)!(n+n_0z_n)!} = 4e^{-2n_0^2 z^2} (1 + o(1)) < \frac{\varepsilon}{3}, \end{aligned}$$

kai  $n$  yra pakankamai didelis. Todėl pakankamai dideliems  $n$

$$\begin{aligned}
 & \left| \mathcal{P}\left(\mathcal{D}_n \sqrt{\frac{n}{2}} < z\right) - K(z) \right| \leq \left| \sum_{k=-n_0}^{n_0} (-1)^k e^{-2k^2 z^2} - \right. \\
 & \left. - \sum_{k=-n_0}^{n_0} (-1)^k \frac{(n!)^2}{(n - kz_n)!(n + kz_n)!} \right| + \\
 & + \left| \sum_{n_0 < |k| \leq z_n} (-1)^k \frac{(n!)^2}{(n - kz_n)!(n + kz_n)!} \right| + \\
 & + \left| \sum_{|k| > n_0} (-1)^k e^{-2k^2 z^2} \right| < \frac{\varepsilon}{2} + \frac{\varepsilon}{3} + \frac{\varepsilon}{6} = \varepsilon. \quad \square
 \end{aligned}$$

Pateiksime be įrodymo statistikų  $\mathcal{D}_{nm}^+$  ir  $\mathcal{D}_{nm}$  pasiskirstymo ribines teoremas, kai  $n$  ir  $m$  yra bet kokie.

**5 teorema.** *Jei stebimieji dydžiai yra tolydūs ir vienodai pasiskirstę, tai*

$$\begin{aligned}
 \mathcal{P}\left(\mathcal{D}_{nm}^+ \sqrt{\frac{nm}{n+m}} < z\right) & \rightarrow \begin{cases} 0, & \text{kai } z \leq 0, \\ 1 - e^{-2z^2}, & \text{kai } z > 0, \end{cases} \\
 \mathcal{P}\left(\mathcal{D}_{nm} \sqrt{\frac{nm}{n+m}} < z\right) & \rightarrow K(z),
 \end{aligned}$$

kai  $n \rightarrow \infty$ ,  $m \rightarrow \infty$ ; čia  $K(z)$  yra 13.3 teoremoje apibrėžta funkcija.

Statistikų  $\mathcal{D}_{nm}^+$  ir  $\mathcal{D}_{nm}$  pasiskirstymu grindžiamas Smirnovo kriterijus tikrinti hipotezei, kad abu stebimi tolydieji atsitiktiniai dydžiai turi tą patį pasiskirstymą. Tų statistikų pasiskirstymai yra tabuliuoti (žr. [17], XVII lentelę; [2], 6.5<sup>a</sup> lentelę). Skaičiavimams suprastinti naudojamos formulės

$$\begin{aligned}
 \mathcal{D}_{nm}^+ & = \max_{1 \leq k \leq n} \left( \frac{k}{n} - \mathcal{G}_m(X_k^*) \right) = \max_{1 \leq k \leq m} \left( \mathcal{F}_n(Y_k^*) - \frac{k-1}{m} \right), \\
 \mathcal{D}_{nm}^- & = \max_{1 \leq k \leq n} \left( \mathcal{G}_m(X_k^*) - \frac{k-1}{n} \right) = \max_{1 \leq k \leq m} \left( \frac{k}{m} - \mathcal{F}_n(Y_k^*) \right), \\
 \mathcal{D}_{nm} & = \max(\mathcal{D}_{nm}^+, \mathcal{D}_{nm}^-);
 \end{aligned}$$

čia  $\{X_k^*\}$  yra pirmojo stebimo dydžio, o  $\{Y_k^*\}$  – antrojo dydžio variacinės sekos.

## 15. ŽENKLŲ KRITERIJUS

11 skyrelyje nagrinėjome šitokią uždavinį. Stebėjome atsitiktinį dydį, įgyjantį dvi reikšmes 1 ir 0 atitinkamai su tikimybėmis  $p$  ir  $1 - p$ . Tikimybė  $p$  buvo nežinoma. Nurodėme metodą tikrinti hipotezei, kad  $p$  yra koks nors konkretus skaičius  $p_0 \in (0, 1)$ . Dabar mums pravėrs specialus atvejis  $p_0 = 1/2$ . Priminsime tą kriterijų.

Atliekame  $n$  nepriklausomų stebėjimų. Pažymėkime  $\kappa_n$  skaičių atvejų, kai stebimasis atsitiktinis dydis įgyja reikšmę 1. Statistika  $\kappa_n$  turi binominį pasiskirstymą

$$\mathcal{P}(\kappa_n = k) = \binom{n}{k} \left(\frac{1}{2}\right)^n \quad (k = 0, 1, \dots, n).$$

Nerandomizuotas kriterijus sudaromas šitaip. Imkime reikšmingumo lygmenį  $\alpha$ . Pažymėkime  $k_n$  statistikos  $\kappa_n$  realizaciją. Jei alternuojanti hipotezė yra  $p = p_1 < 1/2$ , tai hipotezę atmetame, kai

$$\sum_{k=0}^{k_n} \binom{n}{k} \left(\frac{1}{2}\right)^n \leq \alpha.$$

Jei alternatyva yra  $p = p_1 > 1/2$ , tai hipotezę atmetame, kai

$$\sum_{k=k_n}^n \binom{n}{k} \left(\frac{1}{2}\right)^n \leq \alpha.$$

Pagaliau, jei alternatyva yra  $p = p_1 \neq 1/2$ , tai hipotezę atmetame, kai

$$\sum_{k=0}^{k_n} \binom{n}{k} \left(\frac{1}{2}\right)^n \leq \frac{\alpha}{2}$$

arba

$$\sum_{k=k_n}^n \binom{n}{k} \left(\frac{1}{2}\right)^n \leq \frac{\alpha}{2}.$$

Šiuo kriterijumi yra pagrįstas vadinamasis *ženklų kriterijus*, vienas iš paprasčiausių statistikoje. Panagrinėsime porą jo taikymo atvejų.

1. Sakykime, stebime tolydujį atsitiktinį dydį. Reikia patikrinti hipotezę, kad jo mediana yra lygi  $z_0$ . Kaip paprastai, tarkime, kad  $X_1, \dots, X_n$  yra atsitiktinė imtis. Kadangi stebimasis dydis yra tolydus, tai jo mediana tenkina sąlygą

$$P(X_1 < z_0) = P(X_1 > z_0) = \frac{1}{2}.$$

Pažymėkime  $\kappa_n$  skaičių tų  $k$ , kuriems  $X_k - z_0$  yra neigiamas. Ši statistika yra pasiskirsčiusi pagal binominį dėsnį. Todėl hipotezei tikrinti galima taikyti anksčiau aprašytą procedūrą. Praktiškai ją taikant, tenka suskaičiuoti, kiek yra neigiamų ir kiek yra teigiamų skirtumų  $X_k - z_0$ . Iš čia ir kilęs ženklų kriterijaus pavadinimas.

2. Sakykime, stebime dvimatį tolydujį atsitiktinį dydį su tankio funkcija  $p(u, v)$ . Reikia patikrinti hipotezę, kad  $p(u, v) = p(v, u)$ . Jei stebimojo dydžio

komponentai yra nepriklausomi, tai tikrinamoji hipotezė reiškia, kad jie yra vienodai pasiskirstę. Imkime  $n$  nepriklausomų stebėjimų  $(X_1, Y_1), \dots, (X_n, Y_n)$ . Jei hipotezė yra teisinga, tai skirtumai  $X_k - Y_k$  įgyja teigiamas ir neigiamas reikšmes su ta pačia tikimybe  $1/2$ . Todėl galime taikyti ženklų kriterijų.

## 16. RANGINIAI KRITERIJAI

Sakykime, tiriamo du tolydžiuosius atsitiktinius dydžius. Jų nepriklausomų stebėjimų rezultatai yra  $X_1, \dots, X_n$  ir  $Y_1, \dots, Y_m$ . Reikia patikrinti hipotezę, kad tie dydžiai turi tą pačią pasiskirstymo funkciją.

Sujunkime visus stebėjimo rezultatus ir iš jų sudarykime vieną variacinę seką. Joje bus  $N = n + m$  narių. Praleiskime indeksus. Gausime, pavyzdžiui, šitokio tipo seką

$$\begin{array}{ccccccccccc} X & X & Y & X & Y & Y & \dots & X & Y & Y \\ 1 & 2 & 3 & 4 & 5 & 6 & & N-2 & N-1 & N \end{array}$$

Apačioje surašyti narių numeriai – jų rangai. Tiesa, gali pasitaikyti vienodų pirmosios ir antrosios imties narių. Tada gautoji seka nebus vienareikšmiškai nusakyta. Tačiau tokie atvejai galės pasitaikyti tik su tikimybe 0, nes dydžiai yra tolydieji. Jei vis dėlto taip atsitiko, tai lygius stebėjimo rezultatus išdėstome bet kaip.

Tarkime, kad  $R_1 < R_2 < \dots < R_n$  yra  $X$  numeriai. Parenkame kokią nors funkciją  $f(r)$ , apibrėžtą visiems  $r = 1, \dots, N$ , ir imame statistiką

$$W = f(R_1) + \dots + f(R_n).$$

Atitinkamai konkretizavę funkciją  $f(r)$ , gauname Vilkoksono ir Van der Vardeno kriterijus.

1. **V i l k o k s o n o<sup>1</sup> k r i t e r i j u s.** Tarkime, kad  $s(1), s(2), \dots, s(N)$  yra skaičiai  $1, 2, \dots, N$ , surašyti kokia nors iš anksto fiksuota (nepriklausančia nuo stebėjimo rezultatų) tvarka, kitaip tariant,  $s(1), s(2), \dots, s(N)$  yra skaičių  $1, 2, \dots, N$  kėlinys. Paėmę  $f(r) = s(r)$ , turime statistiką

$$W = f(R_1) + \dots + f(R_n).$$

Galima įrodyti: jei hipotezė yra teisinga, tai taip sudarytos statistikos pasiskirstymas nepriklauso nuo teorinės pasiskirstymo funkcijos ir funkcijos  $s(r)$ , priklauso tik nuo  $n$  ir  $m$ . Statistikos  $W$  pasiskirstymo funkcija yra tabuluota (žr. [2], 6.8 lentelę). Kai  $n$  ir  $m$  dideli, galima naudotis asimptotine formule

<sup>1</sup> F. Wilcoxon – anglų matematikas.

$$\mathcal{P} \left( \frac{W - \frac{m}{2}(m+n+1)}{\sqrt{\frac{mn}{12}(m+n+1)}} < u \right) \rightarrow \Phi(u),$$

kai  $N = n + m \rightarrow \infty$ .

2. Van der Waerden<sup>1</sup> kriterijus yra panašus į Vilkoksono, tik funkcija  $f(r)$  parenkama šiek tiek kitaip:

$$f(r) = \Phi^{-1} \left( \frac{s(r)}{n+m+1} \right);$$

čia  $\Phi^{-1}$  reiškia funkciją, atvirkštinę standartinei normaliajai pasiskirstymo funkcijai  $\Phi$ . Ir šiuo atveju statistikos

$$W = \sum_{k=1}^n \Phi^{-1} \left( \frac{s(R)}{n+m+1} \right)$$

pasiskirstymas priklauso tik nuo  $n$  ir  $m$ . Kai  $N \rightarrow \infty$ ,

$$\mathcal{P}(W < u\sqrt{DW}) \rightarrow \Phi(u);$$

čia

$$DW = \frac{nm}{n+m+1} \frac{1}{n+m} \sum_{k=1}^{n+m} \left( \Phi^{-1} \left( \frac{k}{n+m+1} \right) \right)^2.$$

Statistikos  $W$  pasiskirstymo funkcija yra tabuluota (žr. [17], XIX lentelę, [2], 6.9 lentelę).

Kriterijus, pagrįstas šia statistika, yra gana tikslus, kai stebimieji atsitiktiniai dydžiai pasiskirstę pagal normalųjį dėsnį arba artimą jam.

---

<sup>1</sup> Van der Waerden (g. 1903) – olandų matematikas, šiuo metu dirbąs Šveicarijoje.