

Matematika IV – 10. přednáška

Číselné charakteristiky náhodných veličin, normální rozdělení, limitní věty

Michal Bulant

Masarykova univerzita
Fakulta informatiky

24. 4. 2013

Obsah přednášky

- 1 Číselné charakteristiky náhodných veličin
- 2 Normální rozdělení a rozdělení odvezená
- 3 Limitní věty a odhadování
- 4 Náhodný vektor
- 5 Náhodný výběr

Doporučené zdroje

- Martin Panák, Jan Slovák, **Drsná matematika**, e-text.
- Karel Zvára, Josef Štěpán, **Pravděpodobnost a matematická statistika**, Matfyzpress, 4. vydání, 2006, 230 stran, ISBN 80-867-3271-1.
- Marie Budíková, Štěpán Mikoláš, Pavel Osecký, **Teorie pravděpodobnosti a matematická statistika (sbírka příkladů)**, Masarykova univerzita, 3. vydání, 2004, 117 stran, ISBN 80-210-3313-4.
- Marie Budíková, **Statistika**, Masarykova univerzita, 2004, distanční studijní opora ESF, <http://www.math.muni.cz/~budikova/esf/Statistika.zip>.
- Marie Budíková, Tomáš Lerch, Štěpán Mikoláš, **Základní statistické metody**, Masarykova univerzita, 2005, 170 stran, ISBN 80-210-3886-1.

Střední hodnota

Při statistickém zkoumání hodnot náhodných veličin (např. zpracování výsledků nějakého měření) hledáme výpovědi o náhodné veličině pomocí různých z ní odvozených čísel.

Jako nejjednodušší příklad může sloužit **střední hodnota**¹ $E(X)$ náhodné veličiny X , která je definována

$$E(X) = \begin{cases} \sum_i x_i \cdot f_X(x_i) & \text{pro diskrétní veličinu} \\ \int_{-\infty}^{\infty} x \cdot f_X(x) dx & \text{pro spojitou veličinu.} \end{cases}$$

Obecně střední hodnota náhodných veličin nemusí existovat, protože příslušné sumy či integrály nemusí konvergovat.

¹Často se místo $E(X)$ píše EX .

Střední hodnota transformované náhodné veličiny

Střední hodnotu můžeme přímo vyjádřit také pro funkce $Y = \psi(X)$ náhodné veličiny X . V diskrétním případě můžeme přímo spočítat

$$\begin{aligned}
 E(Y) &= \sum_j y_j P(Y = y_j) \\
 &= \sum_j y_j \sum_{\psi(x_i)=y_j} P(X = x_i) \\
 &= \sum_i \psi(x_i) P(X = x_i) = \sum_i \psi(x_i) f_X(x_i).
 \end{aligned}$$

Je tedy $E(\psi(X))$ přímo spočítatelná pomocí pravděpodobnostní funkce f_X .

Podobně vyjadřujeme střední hodnotu funkce ze spojité náhodné veličiny:

$$E(\psi(X)) = \int_{-\infty}^{\infty} \psi(x) f_X(x) dx,$$

pokud tento integrál absolutně konverguje.

Příklad

Spočtěme střední hodnotu binomického rozdělení.

Řešení

Pro $X \sim \text{Bi}(n, p)$ je

$$\begin{aligned}
 E(X) &= \sum_{k=0}^n k \cdot \binom{n}{k} p^k (1-p)^{n-k} = \\
 &= np \sum_{k=1}^n \frac{(n-1)!}{(n-k)!(k-1)!} p^{k-1} (1-p)^{n-k} = \\
 &= np \sum_{j=0}^{n-1} \frac{(n-1)!}{(n-1-j)!j!} p^j (1-p)^{n-1-j} = \\
 &= np(p + (1-p))^{n-1} = np.
 \end{aligned}$$

Základní vlastnosti střední hodnoty

Věta

Nechť $a, b \in \mathbb{R}$ a X, Y jsou náhodné veličina s existující střední hodnotou. Pak

- $E(a) = a,$
- $E(a + bX) = a + bE(X),$
- $E(X + Y) = E(X) + E(Y),$
- jsou-li X a Y nezávislé, pak $E(XY) = E(X) \cdot E(Y).$

Důkazy těchto tvrzení jsou přímočaré, zkuste si je udělat!
Analogická tvrzení platí i pro náhodné vektory.

Příklad

Spočtěme ještě jednou střední hodnotu binomického rozdělení, tentokrát s využitím vlastnosti střední hodnoty.

Řešení

Vyjádříme počet zdarů v n pokusech jako počet zdarů v jednotlivých pokusech

$$X = \sum_{k=1}^n Y_i,$$

přičemž náhodné veličiny Y_k mají všechny alternativní rozdělení $A(p)$. Snadno spočítáme $E(Y_k) = 1 \cdot p + 0 \cdot (1 - p) = p$. Dále víme, že střední hodnota součtu je součtem středních hodnot, proto

$$E(X) = \sum_{k=1}^n E(Y_k) = np.$$

Kvantily

Dalšími užitečnými charakteristikami jsou tzv. **kvantily**. Pro ryze monotónní distribuční funkci F_X (tj. spojitou náhodnou veličinu X s všude nenulovou hustotou, jako je tomu např. u normálního rozdělení) jde prostě o inverzní funkci $F_X^{-1} : (0, 1) \rightarrow \mathbb{R}$. To znamená, že hodnota $y = F^{-1}(\alpha)$ je taková, že $P(X < y) = \alpha$. Obecněji, je-li $F_X(x)$ distribuční funkce náhodné veličiny X , pak definujeme **kvantilovou funkci**²

$$F^{-1}(\alpha) = \inf\{x \in \mathbb{R}; F(x) \geq \alpha\}, \quad \alpha \in (0, 1).$$

Zřejmě jde o zobecnění předchozí definice.

Nejčastěji jsou používané kvantily s $\alpha = 0.5$, tzv. **medián**, s $\alpha = 0.25$, tzv. **první kvartil**, $\alpha = 0.75$, tzv. **třetí kvartil**, a podobně pro **decily** a **percentily** (kdy je α rovno násobkům desetin a setin). K těmto hodnotám se vrátíme v popisné statistice později.

²Uvědomte si, že jsme se již s kvantily setkali, jen jsme jím tak zatím neříkali.

Rozptyl a směrodatná odchylka

Tyto číselné charakteristiky rozdělení náhodné veličiny nepopisují nějakou střední či typickou hodnotu (jako střední hodnota či medián), ale míru „kolísání“ náhodné veličiny kolem střední hodnoty.

Rozptylem (variancí) náhodné veličiny X , která má konečnou střední hodnotu, nazýváme číslo

$$D(X) = \text{var } X = E([X - E(X)]^2),$$

odmocnina z rozptylu $\sqrt{D(x)}$ se pak nazývá **směrodatná odchylka**.

Základní vlastnosti rozptylu

Věta

Pro náhodnou veličinu X a reálná čísla a, b platí:

- ① $D(X) = E(X^2) - E(X)^2,$
- ② $D(a + bX) = b^2 D(X),$
- ③ $\sqrt{D(a + bX)} = |b| \sqrt{D(X)}.$

Důkaz.

Důkaz je přímočarý. Poznamenejme, že tvrzení 1 se často používá k výpočtům $D(X)$. □

Kovariance

O závislosti dvou náhodných veličin do jisté míry vypovídá tzv. **kovariance**, definovaná předpisem

$$C(X, Y) = \text{cov}(X, Y) = E([X - E(X)][Y - E(Y)]).$$

Veličinám X, Y , pro něž je $C(X, Y) = 0$, říkáme **nekorelované**.

Věta

Pro náhodné veličiny s existujícími rozptyly platí:

- ① $C(X, Y) = C(Y, X)$,
- ② $C(X, X) = D(X)$,
- ③ $C(X, Y) = E(XY) - E(X)E(Y)$,
- ④ $C(a + bX, c + dY) = bd \cdot C(X, Y)$,
- ⑤ $D(X + Y) = D(X) + D(Y) + 2C(X, Y)$, speciálně, jsou-li X, Y nezávislé, je $D(X + Y) = D(X) + D(Y)$, tj.
 $C(X, Y) = 0$ a X, Y jsou nekorelované.

Koeficient korelace

Koeficient korelace³ je jen speciální název pro kovarianci dvou normovaných náhodných veličin:

$$R(X, Y) = \rho_{X,Y} = C \left(\frac{X - E(X)}{\sqrt{D(X)}}, \frac{Y - E(Y)}{\sqrt{D(Y)}} \right).$$

Věta

- ① $R(X, X) = 1$,
- ② $R(a + bX, c + dY) = \text{sgn}(bd)R(X, Y)$,
- ③ jsou-li X, Y nezávislé, je $R(X, Y) = 0$,
- ④ (Cauchyova nerovnost) $|R(X, Y)| \leq 1$.

³Viz např. http://upload.wikimedia.org/wikipedia/commons/0/02/Correlation_examples.png

Příklad

Spočtěme rozptyl binomického rozdělení.

Řešení

Stejně jako dříve lze psát $X = \sum_{k=1}^n Y_k$, kde Y_1, \dots, Y_n jsou nezávislé náhodné veličiny vyjadřující úspěch v k -tému pokusu.

Snadno vypočteme $E(Y_k^2) = 1^2 \cdot p + 0^2 \cdot (1 - p) = p$, proto $D(Y_k) = E(Y_k^2) - E(Y_k)^2 = p - p^2 = p(1 - p)$. Protože pro **nezávislé** Y_k platí $D(\sum Y_k) = \sum D(Y_k)$, je $D(X) = np(1 - p)$.

Normovaná náhodná veličina a limitní věty

Připomenutí:

Věta (de Moivre-Laplaceova)

Pro náhodné veličiny X_n s rozdělením $\text{Bi}(n, p)$ platí

$$\lim_{n \rightarrow \infty} P \left[a < \frac{X_n - np}{\sqrt{np(1-p)}} < b \right] = \Phi(b) - \Phi(a),$$

kde Φ je distribuční funkce normovaného normálního rozdělení.

Všimněme si, že výraz $\frac{X_n - np}{\sqrt{np(1-p)}}$ vystupující v Moivre-Laplaceově větě je totéž, co $\frac{X_n - E(X_n)}{\sqrt{D(x)}}$ a jde tedy o tzv. **normovanou** náhodnou veličinu (tj. veličinu lineárně transformovanou tak, aby měla střední hodnotu 0 a rozptyl 1). Moivre-Laplaceova věta pak říká, že pro $n \rightarrow \infty$ se rozložení této náhodné veličiny blíží normovanému normálnímu rozdělení $N(0, 1)$.

Je o speciální případ limitních vět, ukazujících, že za určitých

Další momenty

Někdy je užitečné studovat řadu dalších charakteristik rozdělení náhodných veličin. Za rozumných předpokladů jsou definovány ***k*-té obecné momenty**

$$\mu'_k = E(X^k)$$

a ***k*-té centrální momenty**

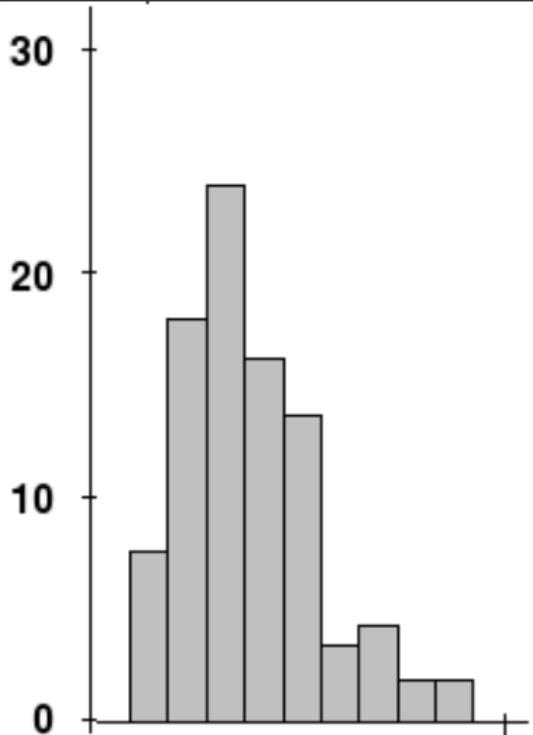
$$\mu_k = E([X - E(X)]^k).$$

Pomocí momentů pak definujeme např. **šikmost** (asymetrie) náhodné veličiny X jako

$$\frac{\mu_3}{\sqrt{D(x)}^3}$$

nebo **špičatost** (exces) jako

$$\frac{\mu_4}{D(x)^2} - 3.$$



Kladná šikmost distribuce (více vysokých kladných hodnot než odpovídá normálnímu rozdělení s nulovou šikmostí).

Momentová vytvořující funkce

Definice

Reálnou funkci proměnné $t \in \mathbb{R}$ $M_X(t) = E(e^{tX})$ nazveme **momentovou vytvořující funkcí** náhodné veličiny X .

Poznámka

Je-li X např. spojitá, platí

$$\begin{aligned} M_X(t) &= \int_{-\infty}^{\infty} e^{tx} f(x) dx = \\ &= \int_{-\infty}^{\infty} \left(1 + tx + \frac{t^2 x^2}{2!} + \dots\right) f(x) dx = \\ &= 1 + t\mu'_1 + \frac{t^2 \mu'_2}{2!} + \dots \end{aligned}$$

a jde vlastně o *exponenciální vytvořující funkci* posloupnosti k -tých obecných momentů μ'_k .

Věta

Pro momentovou vytvářející funkci platí:

- *Pro nezávislé náhodné veličiny platí*
 $M_{X+Y}(t) = M_X(t)M_Y(t)$.
- *r-tý obecný moment μ'_r náhodné veličiny X je koeficient u $\frac{t^r}{r!}$ v rozvoji M_X do exponenciální mocninné řady. Tedy např.*
 $EX = \mu'_1, DX = \mu'_2 - (\mu'_1)^2$.
- *Je-li $Y = a + bX$, pak $M_Y(t) = e^{at} M_X(bt)$.*
- *Platí-li $M_X(t) = M_Y(t)$ pro všechna $t \in (-b, b)$, mají náhodné veličiny stejné rozdělení, tj. $F_X(x) = F_Y(x)$ ($b > 0$ libovolné).*

Příklad

Určete momentovou vytvořující funkci binomického rozdělení.

Řešení

$$\begin{aligned}
 M(t) &= E(e^{tX}) = \sum_{k=0}^n e^{tk} \binom{n}{k} p^k (1-p)^{n-k} = \\
 &= \sum_{k=0}^n \binom{n}{k} (pe^t)^k (1-p)^{n-k} = \\
 &= (pe^t + (1-p))^n = (p(e^t - 1) + 1)^n.
 \end{aligned}$$

Snáze jsme mohli funkci určit s využitím předchozích vět a momentové vytvořující funkce alternativního rozdělení, neboť pro $Y \sim A(p)$ je $E(e^{tY}) = e^{t \cdot 1} \cdot p + e^{t \cdot 0} (1-p) = p(e^t - 1) + 1$.

Příklad

Naposled spočtěme střední hodnotu a rozptyl binomického rozdělení, tentokrát s využitím vytvořující funkce.

Řešení

$M(t) = (p(e^t - 1) + 1)^n$, proto je

$$\frac{d}{dt} M(t) = n(p(e^t - 1) + 1)^{n-1} e^t p,$$

což pro $t = 0$ dá $E(X) = \mu'_1 = np$.

Podobně spočítáme i $D(x) = \mu'_2 - (\mu'_1)^2$.

Momenty normálního rozdělení

Přímý výpočet střední hodnoty a rozptylu normovaného normálního rozdělení není triviální. S využitím momentové vytvářející funkce je ale poměrně jednoduchý.

Nechť $Z \sim N(0, 1)$. Pak

$$\begin{aligned} M_Z(t) &= \int_{-\infty}^{\infty} e^{tz} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z^2}{2}\right) dz = \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z^2 - 2tz + t^2 - t^2}{2}\right) dz = \\ &= \exp\left(\frac{t^2}{2}\right) \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(z-t)^2}{2}\right) dz = \exp\left(\frac{t^2}{2}\right). \end{aligned}$$

Poslední integrál je roven 1 díky tomu, že na místě integrované funkce je funkce s vlastnostmi hustoty.

Střední hodnota a rozptyl normálního rozdělení

S využitím předchozího výpočtu $M_Z(t) = \exp\left(\frac{t^2}{2}\right)$ snadno spočítáme, že

$$M'_Z(t) = t \exp\left(\frac{t^2}{2}\right),$$

$$M''_Z(t) = t^2 \exp\left(\frac{t^2}{2}\right) + \exp\left(\frac{t^2}{2}\right).$$

Dosazením $t = 0$ pak dostaneme

$$E(Z) = 0, D(Z) = 1.$$

Pro transformovanou náhodnou veličinu $Y = \mu + \sigma Z \sim N(\mu, \sigma^2)$ pak snadno odvodíme z vlastností střední hodnoty, resp. rozptylu, že $E(Y) = \mu$, $D(Y) = \sigma^2$ (což zpětně zdůvodňuje zápis $N(\mu, \sigma^2)$). Momentová vytvořující funkce pro Y má tvar

$$M_Y(t) = \exp\left(\mu t + \sigma^2 \frac{t^2}{2}\right).$$

Příklad

Určete rozdělení součtu nezávislých náhodných veličin $X \sim N(\mu_X, \sigma_X^2)$, $Y \sim N(\mu_Y, \sigma_Y^2)$.

Řešení

Z vlastností momentové vytvárající funkce dostáváme

$$\begin{aligned} M_{X+Y}(t) &= \exp\left(\mu_X t + \sigma_X^2 \frac{t^2}{2}\right) \exp\left(\mu_Y t + \sigma_Y^2 \frac{t^2}{2}\right) = \\ &= \exp\left((\mu_X + \mu_Y)t + (\sigma_X^2 + \sigma_Y^2)\frac{t^2}{2}\right). \end{aligned}$$

$$\text{Proto } X + Y \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2).$$

Γ (gamma) rozdělení

Γ rozdělení se často používá u modelů čekání (např. v pojistné matematice je čas dožití často modelován pomocí gamma rozdělení).

Příklad

Určete konstantu c tak, aby funkce $cx^{a-1}e^{-bx}$ pro $x > 0$ a nulová jinde ($a, b > 0$ jsou parametry) byla hustotou náhodné veličiny.

Řešení

Hustota musí splňovat

$$\begin{aligned} 1 &= \int_0^{\infty} cx^{a-1}e^{-bx} dx = \int_0^{\infty} c\left(\frac{t}{b}\right)^{a-1} e^{-t} \frac{1}{b} dt = \\ &= \frac{c}{b^a} \int_0^{\infty} t^{a-1} e^{-t} dt = \frac{c}{b^a} \Gamma(a), \end{aligned}$$

$$\text{proto } c = \frac{b^a}{\Gamma(a)}.$$

Poznámka

Funkce Γ je zobecnění faktoriálu ($\Gamma(n) = (n - 1)!$ pro $n \in \mathbb{N}$), definované předpisem $\Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx$. Často počítáme hodnoty této funkce s využitím vlastností $\Gamma(1/2) = \sqrt{\pi}$, $\Gamma(a + 1) = a \cdot \Gamma(a)$.

Definice

Rozdělení náhodné veličiny s hustotou

$$f(x) = \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx}$$

spočítanou v předchozím příkladu nazýváme **gamma rozdělení** s parametry a, b a značíme $\Gamma(a, b)$. Momentová vytvořující funkce je pak $M(t) = (\frac{b}{b-t})^a$, střední hodnota $E(X) = a/b$ a rozptyl $D(X) = a/b^2$.

Příklad (rozdelení χ^2 podruhé)

Nechť Z má normované normální rozdelení. Určete hustotu transformované náhodné veličiny $X = Z^2$.

Řešení

Již dříve jsme vypočetli přímým výpočtem přes distribuční funkci, že hustota

$$f_Z(x) = \frac{1}{\sqrt{2\pi}} x^{-\frac{1}{2}} e^{-\frac{x}{2}}$$

a řekli jsme si, že jde o (Pearsonovo) χ^2 rozdelení s jedním stupněm volnosti, které značíme $Z \sim \chi^2(1)$. Nyní vidíme, že jde o speciální případ Γ -rozdelení, totiž $\Gamma(1/2, 1/2)$.

Obecně pro součet Y čtverců n nezávislých náhodných veličin s rozdelením $N(0, 1)$ obdobně odvodíme, že má rozdelení $\Gamma(n/2, 1/2)$ a říkáme, že Y má rozdelení $\chi^2(n)$ (*chí kvadrát s n stupni volnosti*). Toto rozdelení se ve statistice používá velmi často.

Další důležitá rozdělení

F-rozdělení

Jsou-li X, Y nezávislé náhodné veličiny s rozděleními $X \sim \chi^2(k)$, $Y \sim \chi^2(m)$, pak má transformovaná náhodná veličina

$$U = \frac{X/k}{Y/m}$$

takzvané Fisher-Snedecorovo F-rozdělení $F(k, m)$ s k a m stupni volnosti.

Studentovo t-rozdělení

Jsou-li $Z \sim N(0, 1)$ a $X \sim \chi^2(n)$ nezávislé náhodné veličiny, pak má veličina

$$T = \frac{Z}{\sqrt{X/n}}$$

tzv. Studentovo t-rozdělení $t(n)$ s n stupni volnosti.

Přehled rozdělení odvozených od normálního

$Z_1, \dots, Z_k \sim N(0, 1)$ nezávislá normovaná normální

$X_k^2 = \sum_{i=1}^k Z_i^2 \sim \chi^2(k)$. . . chí-kvadrát o k stupních volnosti

$F_{k,m} = \frac{X_k^2/k}{X_m^2/m} \sim F(k, m)$. . . F-rozdělení s k a m stupni volnosti

$T_k = \frac{Z}{\sqrt{X_k^2/k}} \sim t(k)$ t-rozdělení s k stupni volnosti

Odtud zejména $Z^2 \sim \chi^2(1)$ a $T_k^2 \sim F(1, k)$.

| rozdělení | střední hodnota | rozptyl |
|--------------------|-----------------|-------------------------------------|
| $N(\mu, \sigma^2)$ | μ | σ^2 |
| $\chi^2(k)$ | k | $2k$ |
| $t(k)$ | 0 | $k/(k - 2)$ |
| $F(k, m)$ | $m/(m - 2)$ | $2m^2(k + m - 2)/k(m - 2)^2(m - 4)$ |

Motivace

S jedním případem limitní věty jsme se již setkali – de Moivre-Laplaceova věta říká, že binomické rozdělení $\text{Bi}(n, p)$ lze za určitých podmínek approximovat normovaným normálním rozdělením. Obvykle se k approximaci přistupuje při splnění podmínek $np(1 - p) > 9$ a $\frac{1}{n+1} < p < \frac{n}{n+1}$. V této kapitole zformulujeme zobecnění této věty a rovněž další tvrzení umožňující odhadovat chování náhodných veličin při velkém počtu nezávislých opakování náhodného pokusu.

Čebyševova nerovnost

Věta

Pro libovolné $\epsilon > 0$ platí

$$P(|X - EX| \geq \epsilon) \leq \frac{DX}{\epsilon^2}.$$

Důkaz.

Budeme odhadovat rozptyl DX ve spojitém případě (diskrétní analogicky):

$$\begin{aligned} DX &= \int_{-\infty}^{\infty} (X - EX)^2 f(x) dx \geq \int_{|x-EX| \geq \epsilon} (X - EX)^2 f(x) dx \geq \\ &\geq \int_{|x-EX| \geq \epsilon} \epsilon^2 f(x) dx = \epsilon^2 P(|X - EX| \geq \epsilon). \end{aligned}$$



Pomocí Čebyševovy nerovnosti můžeme odhadovat pravděpodobnost, s jakou se náhodná veličina s neznámým rozdělením odchylí od své střední hodnoty o více než k -násobek směrodatné odchylky (zřejmě je totiž $P(|X - E(X)| \geq k\sigma) \leq \frac{1}{k^2})$.

Příklad

Nechť je $E(X) = \mu$, $D(X) = \sigma^2$.

- ① Odhadněte $P(|X - \mu| \geq 3\sigma)$.
- ② Vypočtěte $P(|X - \mu| \geq 3\sigma)$, jestliže navíc víte, že $X \sim N(0, 1)$.

Řešení

- ① $1/9$,
- ② $0,0027$.

Zákon velkých čísel

Věta (Čebyševova – slabý zákon velkých čísel)

Nechť jsou X_1, X_2, \dots po dvou nezávislé náhodné veličiny, které mají všechny stejnou střední hodnotu μ a rozptyl shora ohraničený stejnou hodnotou σ^2 . Pak pro libovolné $\epsilon > 0$ platí

$$\lim_{n \rightarrow \infty} P \left(\left| \frac{1}{n} \sum_{i=1}^n X_i - \mu \right| < \epsilon \right) = 1.$$

Říkáme, že posloupnost aritmetických průměrů konverguje podle pravděpodobnosti ke střední hodnotě μ .

Speciálním případem této věty je Bernoulliova věta, která říká, že je-li $Y_n \sim Bi(n, p)$, pak posloupnost relativních četností Y_n/n konverguje podle pravděpodobnosti k p .

Věta (Bernoulliova)

Pro náhodnou veličinu s binomickým rozdělením $Y_n \sim Bi(n, p)$ a pro libovolné $\epsilon > 0$ platí

$$P\left(\left|\frac{Y_n}{n} - p\right| > \epsilon\right) \leq \frac{p(1-p)}{n\epsilon^2}.$$

Důkaz.

Plyne snadno z Čebyševovy nerovnosti, neboť

$$E(Y_n/n) = np/n = p \text{ a}$$

$$D(Y_n/n) = np(1-p)/n^2 = p(1-p)/n.$$



Příklad

Při zkoušce bylo zjištěno, že mezi 600 kontrolovanými studenty je 5 studentů, kteří neumí ani malou násobilku. Odhadněte pravděpodobnost, že relativní četnost takových studentů se od jejich pravděpodobnosti výskytu liší o více než 0,01? (Můžete předpokládat, že pravděpodobnost výskytu studenta bez znalosti násobilky je menší než 0,02).

Centrální limitní věta

Centrální limitní věta dá odpověď na otázku, proč je normální rozdělení nejdůležitějším rozdělením. Ukazuje totiž, že rozdělení součtu dostatečně velkého počtu nezávislých a stejně rozdělených náhodných veličin lze approximovat normálním rozdělením.

Věta

Nechť je Y_1, Y_2, \dots posloupnost **nezávislých stejně rozdělených náhodných veličin** se střední hodnotou μ a rozptylem σ^2 . Pak pro **normované náhodné veličiny**

$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{Y_i - \mu}{\sigma}$$

platí

$$\lim_{n \rightarrow \infty} P(S_n < x) = \Phi(x),$$

kde Φ je distribuční funkce rozdělení $N(0, 1)$.

Příklad

Mezi učiteli matematiky v ČR je jich 10% s příjmem přesahujícím celostátní průměr. Kolik matematiků je třeba pozvat na konferenci, aby s pravděpodobností aspoň 0,95 mezi nimi bylo 8 až 12 procent s nadprůměrným příjmem?

Řešení

$Y_n \sim Bi(n; 0,1)$, $E(Y_n) = 0,1 \cdot n$, $D(Y_n) = 0,1 \cdot 0,9 \cdot n$. Pak

$$0,95 \leq P(0,08n \leq Y_n \leq 0,12n) =$$

$$= P\left(\frac{0,08 - 0,1}{\sqrt{0,09n}}n \leq \frac{Y_n - 0,1n}{\sqrt{0,09n}} \leq \frac{0,12 - 0,1}{\sqrt{0,09n}}n\right) =$$

$$= P\left(\frac{-\sqrt{n}}{15} \leq \frac{Y_n - 0,1n}{\sqrt{0,09n}} \leq \frac{\sqrt{n}}{15}\right) \approx \Phi\left(\frac{\sqrt{n}}{15}\right) - \Phi\left(-\frac{\sqrt{n}}{15}\right).$$

Je tedy $\Phi\left(\frac{\sqrt{n}}{15}\right) \geq 0,975$, což je ekvivalentní $\sqrt{n}/15 \geq 1,96$, tj.
 $n \geq 865$.

Řešení (Pomocí Bernoulliovy nerovnosti)

Nyní využijme Bernoulliovu nerovnost – ta dává

$$P\left(\left|\frac{Y_n}{n} - 0,1\right| \leq 0,02\right) \geq 1 - \frac{0,1 \cdot 0,9}{n \cdot 0,02^2},$$

což má být alespoň 0,95. Odtud

$$n \geq \frac{0,09}{0,05 \cdot 0,02^2} = 4500.$$

Vidíme, že odhad prostřednictvím Bernoulliovy nerovnosti je podstatně slabší než odhad s využitím centrální limitní věty (resp. de Moivre-Laplaceovy věty).

Náhodný vektor – připomenutí

Je-li (Ω, \mathcal{A}, P) pravděpodobnostní prostor a X_1, \dots, X_n na něm definované náhodné veličiny s distribučními funkcemi F_1, \dots, F_n , pak **náhodným vektorem** je n -tice $X = (X_1, \dots, X_n)$ s distribuční funkcí definovanou vztahem

$$F_X(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n).$$

V tomto kontextu nazýváme F *simultánní distribuční funkcí* náhodného vektoru X a F_i *marginální distribuční funkcí* náhodné veličiny X_i .

Podobně jako v případě diskrétní náhodné veličiny označuje $p(x_1, \dots, x_n)$ pravděpodobnostní funkci **diskrétního náhodného vektoru X** , je-li

$$F_X(x_1, \dots, x_n) = \sum_{t_1 \leq x_1} \cdots \sum_{t_n \leq x_n} p(t_1, \dots, t_n).$$

Funkci f_X nazveme **hustotou** normálního vektoru X , pokud pro libovolnou n -tici (x_1, \dots, x_n) platí

$$F_X(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_n} f_X(t_1, \dots, t_n) dt_1 \dots dt_n.$$

Uvážíme-li diskrétní náhodný vektor ⁴ (X, Y) , pak je vztah mezi sdruženým rozdělením vektoru (X, Y) a marginálním rozdělením promenné X určen rovností $P(X = x_i) = \sum_{j=1}^{\infty} P(X = x_i, Y = y_j)$, kde y_1, \dots tvoří úplný systém jevů. Vztah pro spojitě rozdělený náhodný vektor je analogický.

⁴Obvykle zapisujeme ve statistice vektory do sloupců, proto bychom spíše měli psát $(X, Y)^T$.

(stochastická) Nezávislost náhodných veličin

Dříve uvedenou definici nezávislosti náhodných veličin X_1, \dots, X_n pomocí vztahu

$$P(X_1 = x_1, \dots, X_n = x_n) = P(X_1 = x_1) \cdots P(X_n = x_n)$$

pro libovolné x_1, \dots, x_n , tak můžeme nyní přepsat pomocí vztahu mezi sdruženou distribuční funkcí náhodného vektoru

$X = (X_1, \dots, X_n)$ a marginálních distribučních funkcí náhodných veličin X_1, \dots, X_n :

$$F_X(x_1, \dots, x_n) = F_{X_1}(x_1) \cdots F_{X_n}(x_n).$$

Příklad

Házíme dvěma běžnými kostkami, jako náhodnou veličinu X označme součet bodů na obou kostkách, jako náhodnou veličinu Y absolutní hodnotu rozdílu. Určete sdružené rozdělení náhodného vektoru (X, Y) , obě marginální rozdělení a odvod'te, jsou-li X a Y nezávislé.

Číselné charakteristiky náhodných vektorů

$E(X) = (E(X_1), \dots, E(X_n))$ se nazývá vektor středních hodnot,

$$\text{var}(X) = \begin{pmatrix} D(X_1) & C(X_1, X_2) & \cdots & C(X_1, X_n) \\ \cdots & \cdots & \cdots & \cdots \\ C(X_n, X_1) & C(X_n, X_2) & \cdots & D(X_n) \end{pmatrix}$$

varianční (rozptylová) matice a

$$\text{cor } X = \begin{pmatrix} 1 & R(X_1, X_2) & \cdots & R(X_1, X_n) \\ \cdots & \cdots & \cdots & \cdots \\ R(X_n, X_1) & R(X_n, X_2) & \cdots & 1 \end{pmatrix}$$

je korelační matice.

Snadno je po rozepsání po jednotlivých složkách vidět, že

$$\text{var}(X) = E((X - E(X)) \cdot (X - E(X))^T)$$

Ukážeme na příkladech, že pravděpodobnostní struktura náhodného vektoru (X, Y) není určena pouze marginálními rozděleními veličin X a Y . Podstatný je rovněž pravděpodobnostní vztah mezi X a Y , který je částečně popsán např. prostřednictvím korelačního koeficientu.

Příklad

Jsou-li X a Y náhodné veličiny, nabývající hodnot 0 a 1, pak

$$\begin{aligned} P(X = 1, Y = 1) - P(X = 1)P(Y = 1) &= E(XY) - E(X)E(Y) = \\ &= \text{cov}(X, Y). \end{aligned}$$

Odtud je snadno vidět, že pokud jsou X a Y nekorelované, jsou i nezávislé (což obecně neplatí).

Uved'me ještě příklad, ilustrující, že nekorelovanost nemusí implikovat nezávislost:

Příklad

Bud'te A a X nezávislé náhodné veličiny, splňující $X \sim N(0, 1)$ a $P(A = 1) = P(A = -1) = 1/2$. Položíme-li $Y = AX$, pak

$$P(Y < y) = \frac{1}{2}P(X < y) + \frac{1}{2}P(-X < y) = \Phi(y),$$

proto má rovněž Y rozdělení $N(0, 1)$.

Dále $\text{cov}(X, Y) = E(XY) - E(X)E(Y) = E(AX^2) = E(A)E(X^2) = 0 \cdot 1 = 0$, přitom $P(X = Y) = P(X = -Y) = 1/2$ a X, Y zřejmě nejsou nezávislé.

Příklad

Nechť (X, Y) je náhodný vektor, který má rovnoměrné rozdělení na jednotkovém kruhu $K = \{(x, y) : x^2 + y^2 \leq 1\}$. Zřejmě je hustota tohoto rozdělení rovna $1/\pi$ pro $(x, y) \in K$ a 0 jinde a je rovněž vidět, že X, Y **nejsou nezávislé**. Označme $R = R(X, Y)$ a $\Phi = \Phi(X, Y)$ polární souřadnice náhodného vektoru (X, Y) a určíme rozdělení vektoru (R, Φ) .

Pro $0 < r_1 \leq 1$ a $0 < \varphi_1 \leq 2\pi$ je

$$\begin{aligned} P(R < r_1, \Phi \leq \varphi_1) &= \frac{1}{\pi} \pi r_1^2 \frac{\varphi_1}{2\pi} = \\ &= \int_0^{r_1} \int_0^{\varphi_1} \frac{1}{2\pi} 2r d\varphi dr. \end{aligned}$$

Hustota je tedy rovna $f(r, \varphi) = \frac{r}{\pi}$ pro $0 < r \leq 1$, $0 < \varphi \leq 2\pi$ a rovna 0 všude jinde.

Příklad (pokr.)

Marginální hustoty $g(r)$ a $h(\varphi)$ veličin R a Φ se nyní snadno dopočtou:

$$g(r) = \int_{-\infty}^{\infty} f(r, \varphi) d\varphi = \int_0^{2\pi} \frac{r}{\pi} d\varphi = 2r$$

$$h(\varphi) = \int_{-\infty}^{\infty} f(r, \varphi) dr = \int_0^1 \frac{r}{\pi} dr = \frac{1}{2\pi}.$$

Veličina Φ má rovnoměrné rozdělení na $(0, 2\pi)$, odkud $E(\Phi) = \pi$ a $D(\Phi) = \pi^2/3$, snadno rovněž odvodíme $E(R) = 2/3$,
 $D(R) = 1/18$.

Všimněme si ale zejména, že $f(r, \varphi) = g(r)h(\varphi)$, což znamená **nezávislost veličin R a Φ** .

Vlastnosti charakteristik náhodného vektoru

Věta

Pro náhodné vektory X, Y stejné dimenze, konstantní matici B a konstantní vektor a (odpovídajících dimenzí) platí

- $E(X + Y) = E(X) + E(Y),$
- $E(a + BX) = a + B \cdot E(X),$
- $\text{var}(a + B \cdot X) = B \text{var}(X)B^T.$

Důkaz.

Důkaz vyplývá z vlastností náhodných veličin a ze vztahu
 $\text{var}(X) = E((X - E(X))(X - E(X))^T).$



oooooooooooooooooo

Normální rozdělení a rozdělení odvezená
oooooooooo

Limitní věty a odhadů
oooooooooo

Náhodný vektor
oooooooooooo● ooooo

Definice

Náhodným výběrem rozsahu n rozumíme n -tici **nezávislých a stejně rozdelených** náhodných veličin $X_1, \dots, X_n \sim F_X(x)$ (někdy také hovoříme o n nezávislých kopiích náhodné veličiny X).

Náhodným výběrem rozsahu n z p -rozměrného rozdělení rozumíme n -tici **nezávislých a stejně rozdelených** p -rozměrných náhodných vektorů.

V matematické statistice často pracujeme s transformacemi náhodného výběru, takovým náhodným veličinám (příp. vektorům) říkáme **statistiky**. V následujícím zavedeme několik důležitých statistik a ukážeme jejich souvislost s číselnými charakteristikami náhodných veličin.

Základní statistiky

Definice

Nechť X_1, \dots, X_n je náhodný výběr. Statistiku

$$M = \frac{1}{n} \sum_{i=1}^n X_i$$

nazýváme **výběrový průměr**, statistiku

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M)^2$$

výběrový rozptyl a statistiku $S = \sqrt{S^2}$ **výběrová směrodatná odchylka**. Analogicky se definují i výběrová kovariance, příp. výběrový korelační koeficient pro dvouozměrný náhodný výběr.

Vlastnosti statistik

Protože jsou uvedené statistiky náhodnými veličinami, lze se přirozeně ptát po jejich číselných charakteristikách.

Věta

Nechť X_1, \dots, X_n je náhodný výběr rozsahu n z rozdělení se střední hodnotou μ a rozptylem σ^2 . Pak platí:

- $E(M) = \mu$,
- $D(M) = \text{var}(M) = \sigma^2/n$,
- $E(S^2) = \sigma^2$.

Důkaz.

Ukážeme jen (nejsložitější) 3. tvrzení.

Snadno se odvodí, že platí

$$\sum(X_i - \mu)^2 = \sum(X_i - M)^2 + n(M - \mu)^2.$$

Proto je

$$\begin{aligned} E(S^2) &= \frac{1}{n-1} E\left(\sum(X_i - \mu)^2\right) - \frac{n}{n-1} E(M - \mu)^2 = \\ &= \frac{1}{n-1} \sum D(X_i) - \frac{n}{n-1} D(M) = \\ &= \frac{n}{n-1} \sigma^2 - \frac{1}{n-1} \sigma^2 = \sigma^2. \end{aligned}$$



V předchozí větě jsme ukázali, že výběrový průměr M splňuje $E(M) = \mu$, jeho střední hodnota je tedy rovna odhadovanému parametru μ . V takovém případě říkáme, že statistika M je **nestranným odhadem** parametru μ .

Podobně jsme viděli, že S^2 je nestranným odhadem parametru σ^2 . Všimněme si rovněž, že „přirozeněji“ definovaná statistika $\frac{1}{n} \sum (X_i - M)^2$ není nestranným odhadem σ^2 , její střední hodnota je totiž $\frac{n-1}{n} \sigma^2$. Rozmyslete si, je-li S nestranným odhadem směrodatné odchylky σ .

Náhodný výběr z normálního rozdělení

Uvažme nyní speciální případ, kdy je X_1, \dots, X_n náhodný výběr z normálního rozdělení $N(\mu, \sigma^2)$.

Věta

- M a S^2 jsou nezávislé náhodné veličiny.
- $M \sim N(\mu, \sigma^2/n)$, a tedy $U = (M - \mu)/(\sigma/\sqrt{n}) \sim N(0, 1)$.
- $K = (n-1)S^2/\sigma^2 \sim \chi^2(n-1)$.
- $\sum(X_i - \mu)^2/\sigma^2 \sim \chi^2(n)$.
- $T = (M - \mu)/(S/\sqrt{n}) \sim t(n-1)$.

Poznámka

K odhadu μ , známe-li σ^2 , slouží U , v opačném případě T .

K odhadu σ^2 , neznáme-li μ , slouží K , v opačném případě následující (bezejmenná?) statistika, která je vlastně statistikou K , v níž místo odhadu M použijeme přímo μ .

Příklad

V roce 1951 bylo rozsáhlým statistickým průzkumem zjištěno, že střední hodnota výšky desetiletých chlapců je $136,1$ cm se směrodatnou odchylkou $\sigma = 6,4$ cm.

V roce 1961 byla zjištěna výška pouze u 15 náhodně vybraných chlapců:

| | | | | | | | |
|-----|-----|-----|-----|-----|-----|-----|-----|
| 130 | 140 | 136 | 141 | 139 | 133 | 149 | 151 |
| 139 | 136 | 138 | 142 | 127 | 139 | 147 | |

Otázkou je, zda se v porovnání s rokem 1951 změnila střední výška chlapců, pokud předpokládáme, že variabilita výšek se v různých generacích příliš nemění.

Řešení

Vzhledem k tomu, že základní soubor všech desetiletých chlapců je rozsáhlý, lze zmíněná data považovat za náhodný výběr. Zjistíme, že $M = 139,133$, $n = 15$ a s využitím statistiky U dostáváme, že s 95% pravděpodobností leží hodnota μ v intervalu

$$(M - 1,96\sigma/\sqrt{n}; M + 1,96\sigma/\sqrt{n}) = (135,9; 142,4).$$

Protože i střední hodnota výšek z roku 1951 leží v tomto intervalu, nemá vážný důvod tvrdit, že se střední výška změnila. Pokud bychom ovšem připustili vyšší možnost omylu a stanovili interval se spolehlivostí pouze 90%, pak bychom na této hladině hypotézu, že se střední výška změnila, přijali – interval je nyní $(136,41; 141,85)$. Podobně, pokud nás zajímá pouze **dolní odhad** střední hodnoty výšek chlapců (a vůbec tedy nepřipouštíme možnost, že by se střední výška snížila), pak s 95% pravděpodobností je střední výška větší než 136,41, a tedy nyní opět přijímáme hypotézu, že se střední výška zvýšila.

Dva nezávislé výběry z normálního rozdělení

Věta

Nechť je X_{11}, \dots, X_{m1} náhodný výběr rozsahu m z rozdělení $N(\mu, \sigma_1^2)$ a X_{12}, \dots, X_{n2} je na něm nezávislý náhodný výběr rozsahu n z rozdělení $N(\mu, \sigma_2^2)$, přičemž $m, n \geq 2$. Označme M_1, M_2 jejich výběrové průměry a S_1^2, S_2^2 výběrové rozptyly. Dále nechť je

$$S_*^2 = \frac{(m-1)S_1^2 + (n-1)S_2^2}{m+n-2}$$

vážený průměr výběrových rozptylů. Pak platí:

- $M_1 - M_2$ a S_*^2 jsou stochasticky nezávislé,
- $M_1 - M_2 \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n})$,
- je-li $\sigma_1^2 = \sigma_2^2 = \sigma^2$, pak $K = (m+n-2)S_*^2/\sigma^2 \sim \chi^2(m+n-2)$,
- $F = \frac{S_1^2/S_*^2}{\sigma_1^2/\sigma^2} \sim F(m-1, n-1)$.

Užití statistik dvou nezávislých výběrů

- Statistika U , vzniklá normováním $M_1 - M_2$, se používá pro odhad rozdílu $\mu_1 - \mu_2$, známe-li rozptyly σ_1^2, σ_2^2 .
- Je-li $\sigma_1^2 = \sigma_2^2 = \sigma^2$, pak statistika T (vzniklá z U nahrazením teoretického společného rozptylu σ^2 váženým průměrem výběrových rozptylů S_*^2) slouží pro odhad rozdílu $\mu_1 - \mu_2$, neznáme-li rozptyl σ^2 .
- Statistika $K = (m + n - 2)S_*^2/\sigma^2$ slouží k odhadu společného rozptylu σ^2 .
- Statistika $F = \frac{S_1^2/S_2^2}{\sigma_1^2/\sigma_2^2}$ slouží k odhadu podílu rozptylů σ_1^2/σ_2^2 .

Příklad

Mějme dva nezávislé náhodné výběry; první rozsahu 10 z rozdělení $N(2; 1,5)$ a druhý rozsahu 5 z rozdělení $N(3, 4)$. Určete pravděpodobnost, že výběrový průměr prvního výběru bude menší než výběrový průměr druhého výběru.

Řešení

$$P(M_1 < M_2) = P(M_1 - M_2 < 0) =$$

$$= P\left(\frac{(M_1 - M_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}}} < \frac{0 - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}}}\right) =$$

$$P\left(U < \frac{-2 + 3}{\sqrt{\frac{1,5}{10} + \frac{4}{5}}}\right) = P(U < 1,05) =$$

$$= \Phi(1,05) = 0,853.$$