

Matematika III – 12. přednáška

Funkce náhodných veličin

Michal Bulant

Masarykova univerzita
Fakulta informatiky

4. 12. 2013

Obsah přednášky

1 Funkce náhodných veličin

- Transformace náhodných veličin

2 Číselné charakteristiky náhodných veličin

3 Limitní věty a odhady

Doporučené zdroje

- Jan Slovák, Martin Panák, Michal Bulant, *Matematika drsně a svižně*, MU Brno, 2013, 774 s. (též jako 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.

Příklady k procvičení

Příklad

Nechť má X binomické rozdělení s parametry $n = 4, p = 2/3$. Určete rozdělení transformované náhodné veličiny $Y = (X - 2)^2$ a nakreslete graf její distribuční funkce.

Příklad

Mějme náhodnou veličinu X hustoty $f(x) = 2xe^{-x^2}$ pro $x > 0$ (a jinde nulové). Určete hustotu pravděpodobnosti náhodné veličiny $Y = X^2$.

Transformace náhodných veličin

Příklad

Nechť má náhodná veličina X rovnoměrné rozdělení na intervalu $\langle 0, r \rangle$. Určete distribuční funkci a hustotu pravděpodobnosti rozdělení objemu koule o poloměru X .

Řešení

Určeme nejprve distribuční funkci F (pro $0 < d < \frac{4}{3}\pi r^3$)

$$F(d) = P\left[\frac{4}{3}\pi X^3 \leq d\right] = P\left[X \leq \sqrt[3]{\frac{3d}{4\pi}}\right] = \frac{\sqrt[3]{\frac{3d}{4\pi}}}{r},$$

celkem

$$F(x) = \begin{cases} 0 & \text{pro } x \leq 0 \\ \sqrt[3]{\frac{3}{4\pi r^3}} x^{\frac{1}{3}} & \text{pro } 0 < x < \frac{4}{3}\pi r^3 \\ 1 & \text{pro } x \geq \frac{4}{3}\pi r^3 \end{cases}$$

Příklad (rozdělení $\chi^2(1)$)

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

Řešení

Zřejmě je pro $x \leq 0$ distribuční funkce nulová, pro $x > 0$ dostáváme: $F_X(x) = P[Z^2 < x] = P[-\sqrt{x} < Z < \sqrt{x}] =$

$$= \int_{-\sqrt{x}}^{\sqrt{x}} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz = 2 \int_0^x \frac{1}{2\sqrt{2\pi}} t^{-\frac{1}{2}} e^{-\frac{t}{2}} dt$$

a derivací podle x dostaneme hustotu $f_X(x) = \frac{1}{\sqrt{2\pi}} x^{-\frac{1}{2}} e^{-\frac{x}{2}}$.

Rozdělení náhodné veličiny s touto hustotou se nazývá

(Pearsonovo) χ^2 rozdělení s jedním stupněm volnosti a značí se $X \sim \chi^2(1)$.

Jemný úvod k limitním větám

Místo náhodné veličiny X , např. „roční plat zaměstnance“, budeme vyčíslovat jinou závislou hodnotu $\psi(X)$, např. „roční čistý příjem zaměstnance po zdanění a včetně sociálních dávek“.

V systému se značnou sociální solidaritou je první veličina hodně variabilní, zatímco druhá může být skoro konstantní. Statisticky se proto budou značně odlišovat.

Připomeňme si přechod od binomického k Poissonovu rozdělení:

Věta (Poissonova)

Je-li $X_n \sim \text{Bi}(n, p_n)$ taková, že $\lim_{n \rightarrow \infty} np_n = \lambda$ a $X \sim \text{Po}(\lambda)$, pak

$$\lim_{n \rightarrow \infty} P[X_n = k] = P[X = k]$$

pro $k = 0, 1, \dots$

Nejjednodušší funkcí, po konstantách, je affinní závislost
 $\psi(x) = a + bx$.

V případě affinní transformace diskrétní náhodné veličiny

$x = \frac{1}{a}(y - b)$ je proto pravděpodobnostní funkce nenulová právě v bodech $y_i = ax_i + b$. Ukážeme si, že v případě rozdělení X_n typu $\text{Bi}(n, p)$ převádí transformace $x = y\sqrt{np(1-p)} + np$ náhodnou veličinu X_n na rozdělení Y_n s distribuční funkcí blízkou distribuční funkci spojitého rozdělení $N(0, 1)$.

Dříve uvedená Poissonova věta popisuje asymptotické chování binomického rozdělení při $n \rightarrow \infty$ a $p \rightarrow 0$, následující věta pak chování v případě konstantní pravděpodobnosti zdaru p .

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.

Příklad

Hodíme kostkou celkem 12 000 krát. Určete pravděpodobnost toho, že počet hozených šestek je mezi 1 800 a 2 100.

Řešení

Přesná pravděpodobnost je dána výrazem

$$\sum_{k=1800}^{2100} \binom{12000}{k} \left(\frac{1}{6}\right)^k \left(\frac{5}{6}\right)^{12000-k}, \text{ což je obtížně vyčíslitelné.}$$

Využijeme tvrzení Moivre-Laplaceovy věty, přepsaného do tvaru

$$P[A < X_n < B] = \left(\Phi\left(\frac{B - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{A - np}{\sqrt{np(1-p)}}\right) \right) \rightarrow 0$$

pro $n \rightarrow 0$.

Řešení (pokr.)

Volbou $p = 1/6$, $A = 1800$, $B = 2100$, $n = 12000$ dostáváme odhad

$$\begin{aligned} P &\approx \Phi\left(\frac{2100 - 2000}{\sqrt{12000 \cdot \frac{1}{6}\frac{5}{6}}}\right) - \Phi\left(\frac{1800 - 2000}{\sqrt{12000 \cdot \frac{1}{6}\frac{5}{6}}}\right) = \\ &= \Phi(\sqrt{6}) - \Phi(-2\sqrt{6}) \approx 0,992. \end{aligned}$$

Poznámka

Statistické tabulky – viz např. <https://is.muni.cz/auth/el/1433/podzim2013/MB103/um/StatTab.pdf> nebo sbírka příkladů [BMO].

Příklad

Pravděpodobnost narození chlapce je 0,515. Jaká je pravděpodobnost, že mezi tisíci novorozenci bude alespoň kolik děvčat jako chlapců?

Příklad

Nezávisle opakujeme pokus s výsledky 1 a 0, které mají **neznámé** pravděpodobnosti p a $1 - p$. Parametr p chceme odhadnout pomocí *relativních četností* X_n/n (X_n je počet jedniček při n pokusech). Víme, že je $X_n \sim Bi(n, p)$, proto nám Moivre-Laplaceova věta umožní určit počet pokusů n potřebný k zajištění požadované přesnosti odhadu δ se spolehlivostí $1 - \beta$.

Řešení

Využijeme Moivre-Laplaceovu větu zapsanou ve tvaru

$$0 = \lim_{n \rightarrow \infty} \left| P \left[\left| \frac{X_n}{n} - p \right| < \delta \right] - \left(\Phi \left(\frac{n\delta}{\sqrt{np(1-p)}} \right) - \Phi \left(-\frac{n\delta}{\sqrt{np(1-p)}} \right) \right) \right|$$

Řešení

Hledáme nejmenší n , splňující nerovnost

$P[|X_n/n - p| < \delta] \geq 1 - \beta$, kterou můžeme podle věty approximovat nerovností

$$\begin{aligned}\Phi\left(\frac{n\delta}{\sqrt{np(1-p)}}\right) - \Phi\left(-\frac{n\delta}{\sqrt{np(1-p)}}\right) = \\ = 2\Phi\left(\frac{n\delta}{\sqrt{np(1-p)}}\right) - 1 \geq 1 - \beta.\end{aligned}$$

Ta je ekvivalentní s podmínkou $n\delta/\sqrt{np(1-p)} \geq z(\beta/2)$, kde $z(p)$ je řešení rovnice $\Phi(z(p)) = 1 - p$ (tzv. *kritická hodnota* normovaného normálního rozdělení). Pro $\delta = 0,05$ a $1 - \beta = 0,9$ máme z tabulek $z(\beta/2) \approx 1,645$ a s využitím zřejmého odhadu $p(1-p) \leq 1/4$ dostáváme $n \geq (z(\beta/2)/2\delta)^2 \approx 270,6$.

Příklady k procvičení

Příklad

Náhodně vybraná konzerva v armádním skladu je vadná s pravděpodobností 0,1. Kolik konzerv musí zásobovací důstojník ze skladu vzít, aby mezi nimi bylo s pravděpodobností 99% alespoň 60 bezvadných konzerv. (Předpokládejte, že konzervy jsou vydávány náhodně).

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 spočitelná 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 $X \sim Bi(n, p)$ 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 veličiny 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.

Koefficient korelace

Koefficient korelace 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) $|R(X, Y)| \leq 1.$*

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 $D(X) = np(1 - p)$.

Příklady k procvičení

Příklad

Náhodná veličina X je dána pravděpodobnostní funkcí

$$p(x) = \begin{cases} \frac{1}{3} & \text{pro } x = -2 \\ \frac{1}{2} & \text{pro } x = 3 \\ \frac{1}{6} & \text{pro } x = 1 \\ 0 & \text{jinak.} \end{cases}$$

Určete $E(X)$, $E(2X + 5)$, $E(X^2)$, $D(X)$ a $D(2X + 1)$.

Příklad

Nekorelované náhodné veličiny X a Y mají rozptyly $D(X) = a$ a $D(Y) = 2$. Určete konstantu a , jestliže rozptyl náhodné veličiny $Z = 3Y - X$ je $D(Z) = 25$.

Normovaná náhodná veličina a limitní věty

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 $N(0, 1)$.

Jde o speciální případ limitních vět, ukazujících, že za určitých podmínek platí „zákon velkých čísel“, kdy se obdobným způsobem transformované náhodné veličiny chovají jako normální rozdělení.

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**

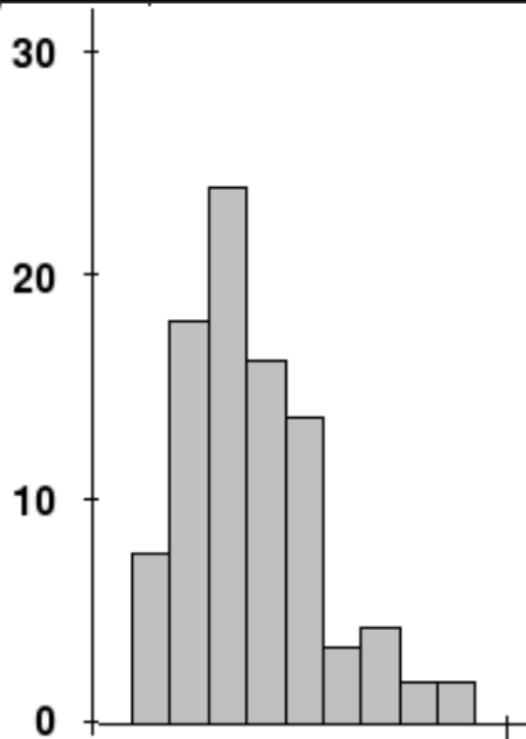
$$\mu_k = E([X - E(X)]^k).$$

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 vytvořující funkci platí:

- $\mu'_k = \frac{d^k}{dt^k} M_X(t) |_{t=0}$.
- Platí-li $M_X(t) = M_Y(t)$ pro všechna $t \in (-b, b)$, mají náhodné veličiny stejné rozdělení, tj. $F_X(x) = F_Y(x)$.
- $M_{a+bX}(t) = e^{at} M_X(bt)$.
- Jsou-li X, Y nezávislé, je $M_{X+Y}(t) = M_X(t)M_Y(t)$.

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 vytvořující 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 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 vytvořující funkce dostaváme

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

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

Příklady k procvičení

Příklad

Náhodná veličina X má na intervalu $(0, a)$ konstantní hustotu pravděpodobnosti (a jinde nulovou). S využitím vlastností střední hodnoty a rozptylu určete:

- ① $E(2X + 3)$,
- ② $E(3X^2 - 2X + 1)$,
- ③ $D(2X + 3)$,
- ④ $D(X^2 + 1)$,

Příklad

Náhodná veličina X má Poissonovo rozdělení (tj. pravděpodobnostní funkci $p(x) = \frac{\lambda^x}{x!} e^{-\lambda}$). Určete její (momentovou vytvořující funkci,) střední hodnotu a rozptyl.

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

$$\begin{aligned}0,95 &\leq P(0,08n \leq Y_n \leq 0,12n) = \\&= P\left(\frac{0,08 - 0,1}{\sqrt{0,09n}}n \leq \frac{Y_n - 0,1n}{\sqrt{0,09n}} \leq \frac{0,12 - 0,1}{\sqrt{0,09n}}n\right) = \\&= P\left(\frac{-\sqrt{n}}{15} \leq \frac{Y_n - 0,1n}{\sqrt{0,09n}} \leq \frac{\sqrt{n}}{15}\right) \approx \Phi\left(\frac{\sqrt{n}}{15}\right) - \Phi\left(-\frac{\sqrt{n}}{15}\right).\end{aligned}$$

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).