

Přednáška 10 a+b

Opakování úkolných charakteristik náhodných veličin - střední hodnota, rozptyl.

Čebyševova nerovnost

Předpokládejme, že náhodná veličina X má konečný rozptyl a uvažujeme $\varepsilon > 0$. Potom platí

$$P(|X - EX| \geq \varepsilon) \leq \frac{\text{var } X}{\varepsilon^2}$$

Důkaz: Pro náhodnou veličinu. Položíme $\mu = EX$ a počítáme podle definice

$$\text{var } X = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx = \int_{|x - \mu| \geq \varepsilon} (x - \mu)^2 f(x) dx$$

$$+ \int_{|x - \mu| < \varepsilon} (x - \mu)^2 f(x) dx \geq \int_{|x - \mu| \geq \varepsilon} \varepsilon^2 f(x) dx = \varepsilon^2 P(|X - \mu| \geq \varepsilon)$$

Důsledky: Pro $\varepsilon = k\sigma$, kde $\sigma = \sqrt{\text{var } X} \neq 0$, je

$$P(|X - EX| \geq k\sigma) \leq \frac{1}{k^2}$$

Kovariance

Pro náhodné veličiny X, Y s existujícími středními hodnotami a rozptyly definujeme

jejich kovarianci předpisem

$$\text{cov}(X, Y) = E((X - EX)(Y - EY))$$

Speciálně $\text{cov}(X, X) = \text{var } X$.

Věta (Vlastnosti rozptylu.)

Jedliže pro náhodné veličiny X, Y a Z existují jejich rozptyly, pak pro reálná čísla a, b, c, d platí

(1) $\text{cov}(X, Y) = \text{cov}(Y, X)$

(2) $\text{cov}(X, Y) = E(X \cdot Y) - (EX)(EY)$

(3) $\text{cov}(X+Y, Z) = \text{cov}(X, Z) + \text{cov}(Y, Z)$

(4) $\text{cov}(a+bX, c+dY) = bd \text{cov}(X, Y)$

(5) ~~cov~~ $\text{var}(X+Y) = \text{var } X + \text{var } Y + 2 \text{cov}(X, Y)$

jestliže veličiny X a Y nezávislé, pak $\text{cov}(X, Y) = 0$

a $\text{var}(X+Y) = \text{var } X + \text{var } Y$

Důkaz: (1) je zřejmé.

(2) $\text{cov}(X, Y) = E\{(X - E(X))(Y - E(Y))\} = E\{XY - E(X)Y - YE(Y) + E(X)E(Y)\} = E(XY) - 2E(X)E(Y) + E(X)E(Y) = E(XY) - (EX)(EY)$

$$\begin{aligned} (3) \operatorname{cov}(X+Y, Z) &= E((X+Y) \cdot Z) - E(X+Y)E(Z) \\ &= E(X \cdot Z) + E(Y \cdot Z) - EXEZ - EYEZ = \\ &= \operatorname{cov}(X, Z) + \operatorname{cov}(Y, Z) \end{aligned}$$

$$\begin{aligned} (4) \operatorname{cov}(a+bX, c+dY) &= E\{(a+bX - E(a+bX))(c+dY - \\ &E(c+dY))\} = E\{(bX - bEX)(dY - dEY)\} = \\ &= E\{bd(X - EX)(Y - EY)\} = bd \operatorname{cov}(X, Y). \end{aligned}$$

$$\begin{aligned} (5) \operatorname{var}(X+Y) &= E\left(\left((X+Y) - E(X+Y)\right)^2\right) = \\ &= E\left(\left((X - EX) + (Y - EY)\right)^2\right) = \\ &= E(X - EX)^2 + 2E\left((X - EX)(Y - EY)\right) \\ &\quad + E(Y - EY)^2 = \operatorname{var} X + 2 \operatorname{cov}(X, Y) + \operatorname{var} Y \end{aligned}$$

Pokud su X a Y nezavislé, su nezavislé
i $X - EX$, $Y - EY$ a platí

$$\begin{aligned} \operatorname{cov}(X, Y) &= E\left((X - EX)(Y - EY)\right) = E(X - EX) \cdot E(Y - EY) \\ &= 0. \end{aligned}$$

Přelo

$$\operatorname{var}(X+Y) = \operatorname{var} X + \operatorname{var} Y$$

Střední hodnota a variace binomického rozdělení $Bi(n, p)$

Binomické rozdělení je rozdělení náhodné veličiny X , která je součtem n náhodných nezávislých veličin s alternativním rozdělením.

Alternativní rozdělení $A(p)$ má

$$E = p$$

$$\sigma = p(1-p)$$

Přelo binomické rozdělení $Bi(n, p)$ má

$$E = np$$

$$\sigma = np(1-p)$$

Pauzitivní čtyřicetník

Jala je pravidelně podávána, se při 1200 kadech horkou podne rídla arpen 150 ka'k a nejryře 250 ka'k.

Přesný výpočet X je náhodná veličina počet ríděl při 1200 kadech. má binomické rozložení $Bi(1200, \frac{1}{6})$. Platí

$$P(150 \leq X \leq 250) = \sum_{k=150}^{250} \binom{1200}{k} \frac{1}{6^k} \cdot \frac{5^{n-k}}{6^{n-k}}$$

To nám třeba spočítáme. Proto uděláme odhad této pravděpodobnosti pomocí četností její.

$$E X = 1200 \cdot \frac{1}{6} (= np) = 200$$

$$\text{var } X = 1200 \cdot \frac{1}{6} \cdot \frac{5}{6} (= np(1-p)) = \frac{500}{3}$$

Jde nám o pravděpodobnost jemu $|X - 200| \leq 50$:

$$P(|X - 200| \leq 50) = 1 - P(|X - 200| \geq 51) \geq$$

$$\geq 1 - \frac{\text{var } X}{51^2} = 1 - \frac{500}{3 \cdot 51^2} \approx 0,94.$$

Tedy pravděpodobnost, že $|X - 200| \leq 50$ je aspoň 0,94. ■

Korelační koeficient

Kovariance vyjádří o závislosti náhodných veličin X a Y . Proto zavádíme korelační koeficient

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var } X} \sqrt{\text{var } Y}}$$

Poznámka 1 $\text{cov}(X, Y)$ má roli skalárního součinu na prostoru náhodných veličin s konečnou variací. $\sqrt{\text{var } X}$ má ~~podobnou~~ roli normy a $\rho_{X,Y}$ má roli úhlu. (Pozor $\text{cov}(X, X)$ musí být 0 i pro X nenulovou)

Korelační koeficient X a Y se rovná korelačnímu koeficientu normovaných náhodných veličin

$$\frac{1}{\sqrt{\text{var } X}} (X - EX) \quad \text{a} \quad \frac{1}{\sqrt{\text{var } Y}} (Y - EY)$$

Věta Je-li korelační koeficient definován, pak

$$|\rho_{X,Y}| \leq 1.$$

Rovněž nastane právě tehdy $P(Y = kX + c) = 1$ je nějaké konstanty k a c .

Variacní matice

Uvažujme náhodný vektor $X = (X_1, X_2, \dots, X_n)^T$, jehož všechny komponenty mají konečný rozptyl.

Variacní matice náhodného vektoru X je

$$\text{var } X = \begin{pmatrix} \text{var } X_1 & \text{cov}(X_1, X_2) & \dots & \text{cov}(X_1, X_n) \\ \text{cov}(X_2, X_1) & \text{var } X_2 & \dots & \text{cov}(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(X_n, X_1) & \text{cov}(X_n, X_2) & \dots & \text{var } X_n \end{pmatrix}$$

nebo pomocí střední hodnoty

$$EX = (EX_1, EX_2, \dots, EX_n)^T$$

žalo

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

Věta: Uvažujme náhodný vektor $X = (X_1, \dots, X_n)^T$
matrici B tvaru $k \times n$ a vektor $c \in \mathbb{R}^k$.

Potom

$$\text{var} (BX + c) = B(\text{var } X) B^T.$$

Momenty a momentová funkce

k -ty' moment náhodné veličiny X

$$\mu_k' = EX^k$$

k -ty' centrální moment veličiny X

$$\mu_k = E(X - EX)^k$$

Pro spojité náhodnou veličinu je

$$EX^k = \int_{-\infty}^{\infty} x^k f(x) dx,$$

kde f je hustota rozložení X . Pro diskrétní

náhodnou veličinu je

$$EX^k = \sum_i x_i^k f(x_i),$$

kde f je navedeným pulce.

Momentová transformace pulce náhodné veličiny

$$X \text{ je } M_X(t) = E e^{tX} = \sum_i e^{tx_i} f(x_i)$$

$$\int_{-\infty}^{\infty} e^{tx} f(x) dx$$

Věta

Nechť X je náhodná veličina, pro kterou na intervalu $(-a, a)$ existuje její analytická momentová pulce. Pak na tomto intervalu je

$$M_X(t) = \sum \frac{t^k}{k!} E X^k.$$

Důkaz: Pro malou náhodnou veličinu

použijeme:

$$M_X(t) = \int_{-\infty}^{\infty} e^{tx} f(x) dx = \int_{-\infty}^{\infty} \sum_{k=0}^{\infty} \frac{t^k x^k}{k!} f(x) dx =$$

$$= \sum_{k=0}^{\infty} \frac{t^k}{k!} \int_{-\infty}^{\infty} x^k f(x) dx = \sum_{k=0}^{\infty} \frac{t^k}{k!} E X^k$$

~~... ..~~

~~... ..~~

Věta Pro nezávislé náhodné veličiny X a Y platí

$$M_{X+Y}(t) = M_X(t) \cdot M_Y(t).$$

Dále

$$M_{a+bX}(t) = e^{at} M_X(bt).$$

Důkaz:

$$M_{X+Y}(t) = E e^{t(X+Y)} = E(e^{tX} \cdot e^{tY}) = E(e^{tX}) \cdot E(e^{tY})$$

neboť měřni hodnota měřnu nezávislých náhodných veličin je měřnem jejich měřnick hodnota.

$$\begin{aligned} M_{a+bX}(t) &= E e^{t(a+bX)} = E(e^{ta} \cdot e^{tbX}) = \\ &= e^{ta} \cdot E(e^{tbX}) = e^{ta} M_X(bt). \end{aligned}$$

Příklad 1 Momentová vyjádření funkce pro $X \sim \text{Bi}(n, p)$

Často je výhodnější počítat momentovou funkci než přímo počítat momenty.

Pro alternativní rozdělení náh. veličiny $Y \sim A(p)$

$$M_Y(t) = E e^{tY} = e^0(1-p) + e^t p = p(e^t - 1) + 1$$

Současně $M_Y(t) = 1 + tEY + \frac{t^2}{2} EY^2 + \frac{t^3}{3} EY^3 + \dots$

Tedy

$$EY = \left. \frac{d}{dt} (M_Y(t)) \right|_{t=0} = (pe^t)_{t=0} = p$$

$$EY^2 = \left. \frac{d^2}{dt^2} (M_Y(t)) \right|_{t=0} = (pe^t)_{t=0} = p$$

$$\text{var } Y = EY^2 - (EY)^2 = p - p^2 = p(1-p)$$

Binomické rozdělení $X \sim \text{Bi}(n, p)$ je součtem n nezávislých veličin $Y_i \sim A(p)$. Proto

$$M_X(t) = (p(e^t - 1) + 1)^n = 1 + \binom{n}{1} p(e^t - 1) + \binom{n}{2} p^2 (e^t - 1)^2 + \dots + \binom{n}{n} p^n (e^t - 1)^n$$

$$EX = \left. \left(\frac{d}{dt} M_X(t) \right) \right|_{t=0} = (npe^t)_{t=0} = np$$

$$EX^2 = \left. \left(\frac{d^2}{dt^2} M_X(t) \right) \right|_{t=0} = \left. \left(\frac{d^2}{dt^2} np(e^t - 1) + \frac{n(n-1)}{2} p^2 \frac{d^2}{dt^2} (e^t - 1)^2 \right) \right|_{t=0}$$

$$= (npe^t)_{t=0} + \frac{n(n-1)}{2} p^2 2(2e^{2t} - e^t)_{t=0} =$$

$$= np + n(n-1)p^2$$

Přelo

$$\begin{aligned} \text{var } X &= EX^2 - (EX)^2 = np + n(n-1)p^2 - n^2p^2 \\ &= np(1-p), \end{aligned}$$

což jsme odvodili již dříve.

Příklad 2 Momentová vyjádření funkce

pro $Z \sim N(0, 1)$

$$\begin{aligned} M_Z(t) &= \int_{-\infty}^{\infty} e^{tx} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) dx = \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2 - 2tx + t^2 - t^2}{2}\right) dx \\ &= \exp\left(\frac{t^2}{2}\right) \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x-t)^2}{2}\right) dx \\ &= \exp\left(\frac{t^2}{2}\right) \end{aligned}$$

Odtud

$$EZ = \left(\frac{d}{dt} M_Z(t) \right)_{t=0} = \left(t \cdot \exp\left(\frac{t^2}{2}\right) \right)_{t=0} = 0$$

$$EZ^2 = \left(\frac{d^2}{dt^2} M_Z(t) \right)_{t=0} = \left(\exp\left(\frac{t^2}{2}\right) + t^2 \exp\left(\frac{t^2}{2}\right) \right)_{t=0} = 1$$

$$\text{Tedy } \text{var } Z = EZ^2 - (EZ)^2 = 1.$$

Y_1, Y_2, \dots, Y_n nezávislé náhodné veličiny
(nejedním rozdělením a)
se střední hodnotou 0 a rozptylem 1.

Předpokládejme, že $E|Y_i|^3$ je konečný.

Pro náhodnou veličinu

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

upíšeme momentovou funkci

$$M_{S_n}(t) = \prod_{i=1}^n E e^{(t/\sqrt{n})Y_i} = \left(M_Y(t/\sqrt{n}) \right)^n,$$

keďže M_Y je momentová funkce všech Y_i .

Nyní

$$M_{S_n}(t/\sqrt{n}) = \left(1 + 0 \cdot \frac{t}{\sqrt{n}} + 1 \cdot \frac{t^2}{2n} + \dots \right)^n$$

~~$\frac{t^2}{2n} + \dots$ $\frac{t^2}{2n} + \dots$ $\frac{t^2}{2n} + \dots$~~

V limitě dostáváme (aproximace na intervalu $(-a, a)$)

$$\lim_{n \rightarrow \infty} M_{S_n}(t) = \lim_{n \rightarrow \infty} \left(1 + \frac{t^2}{2n} + o\left(\frac{1}{n}\right) \right)^n = e^{\frac{t^2}{2}}$$

což je momentová funkce pro rozdělení $N(0,1)$.

CENTRAĽNÍ LIMITNÍ VĚTA

Necht' Y_1, Y_2, \dots, Y_n jsou po dvou nesávislé
náhodné veličiny se společnou střední
hodnotou $EY_i = \mu$ a rozptylem $\text{var } Y_i = \sigma^2 > 0$
a konečným třetím absolutním momentem
 $E|Y_i|^3 < C$.

Pro distribuční funkce náhodných veličin

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

platí

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

keďže $\Phi(x)$ je distribuční funkce normálního
rozdělení $N(0, 1)$.

Aplikace Vatah binomického a normálního
rozložení. Necht' $Y_i \sim A(p)$ jsou nesávislé.

Pak $X_n = Y_1 + Y_2 + \dots + Y_n \sim Bi(n, p)$. Podle
centrální limitní věty má náhodná veličina

$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{Y_i - p}{\sqrt{p(1-p)}} = \frac{X_n - np}{\sqrt{np(1-p)}}$$

pro n velké rozložení velmi podobné $N(0,1)$

Tedy X_n má distribuční funkci blízkou

distribuční funkci normálního rozdělení

$$N(np, \sqrt{np(1-p)}).$$

Tole je obsahem Moironoy - Laplaceovy věty.

Příklad: Chceme zjistit s jakou pravděpodobností

p je v populaci zastoupena krevní skupina A.

X náhodná veličina počet osob s krevní skupinou

A v random n osob

$$X \sim B_i(n, p)$$

Chceme zjistit, pro které n bude už platit

$$P\left(\left|\frac{X}{n} - p\right| \leq 0,05\right) \approx 0,9$$

(Chceme s 90% spolehlivostí zjistit hodnotu

p s chybou nejvýše 5%.)

$$0,9 \approx P\left(\left|\frac{X}{n} - p\right| \leq 0,05\right) = P\left(\frac{X}{n} - p \leq 0,05\right)$$

$$- P\left(\frac{X}{n} - p < -0,05\right) = P\left(\frac{X - np}{\sqrt{np(p-1)}} \leq \frac{0,05n}{\sqrt{np(p-1)}}\right)$$

$$- P\left(\frac{X - np}{\sqrt{np(p-1)}} < \frac{-0,05n}{\sqrt{np(p-1)}}\right) \approx$$

$$\begin{aligned} & \Phi\left(\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}}\right) - \Phi\left(-\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}}\right) = \\ & = \Phi\left(\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}}\right) - \left(1 - \Phi\left(\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}}\right)\right) = \\ & = 2\Phi\left(\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}}\right) - 1 \end{aligned}$$

Chceme tedy

$$\Phi\left(\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}}\right) \approx \frac{1}{2}(1+0,9) = 0,95$$

Odtud

$$\frac{0,05\sqrt{n}}{\sqrt{np(p-1)}} \geq 1,64485$$

Předpokládáme $p(p-1) \leq \frac{1}{4}$ na intervalu $(0,1)$,

budeme rozdělovat

$$\frac{0,05\sqrt{n}}{\sqrt{\frac{1}{4}}} = 0,1\sqrt{n} \geq 1,64485$$

$$\sqrt{n} \geq 16,4485$$

$$n \geq 270.$$

Vybereme-li tedy vzorek 270 lidí, máme na něm pravidelně rozdělený výškový křivku křivky
A s chybou 5% se spolehlivostí 90%.