

NMAI059 Pravděpodobnost a statistika 1

8. přednáška

Robert Šámal

Přehled

Spojité náhodné vektory

Kovariance a korelace

Nerovnosti

Limitní věty – aproximace

Co už známe



- ▶ sdružená distribuční funkce

$$F_{X,Y}(x, y) = P(X \leq x \& Y \leq y).$$

- ▶ sdružená hustota: $f_{X,Y} \geq 0$ taková, že

$$F_{X,Y}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X,Y}(s, t) ds dt.$$

- ▶ důležitý příklad: vícerozměrné normální rozdělení



Obrázek od editorů Wikipedie Piotr a Bscan.

Podmiňování

Definice (zúžení náhodné veličiny na množinu)


X je n.v. na (Ω, \mathcal{F}, P) , $B \in \mathcal{F}$, t.ž. $P(B) > 0$.

$$F_{X|B}(x) := \underline{P(X \leq x | B)}$$

K tomu přísluší hustotní funkce $f_{X|B}$. = $f_{X|B}$.

► pokud $B = \{X \in S\}$, tak

$$f_{X|B}(x) = \begin{cases} \frac{f_X(x)}{P(X \in S)} & \text{pokud } x \in S \\ 0 & \text{jinak } (x \notin S) \end{cases}$$



Věta o rozkladu hustoty

Věta (věta o rozkladu hustoty)

Necheť X je spojitá n.v., necheť B_1, B_2, \dots je rozklad Ω . Pak

$$F_X(x) = \sum_i P(B_i) \underline{F_{X|B_i}(x)} \quad a$$

$$f_X(x) = \sum_i P(B_i) f_{X|B_i}(x).$$

✓
↓
derivace
obou
stran


Důkaz: věta o úplné pravděpodobnosti. (Spec. případ byl na cvičení – dva algoritmy.)

$$P(X \leq x) = \sum_i P(B_i) \cdot P(X \leq x | B_i)$$

Marginální hustota

Věta

X_i spoj. vektor




distribuce
milt. vektor

$$P_X(x) = \sum_y P_{X,Y}(x,y)$$

$$f_X(x) = \int_{y \in \mathbb{R}} f_{X,Y}(x,y) dy$$

$$f_Y(y) = \int_{x \in \mathbb{R}} f_{X,Y}(x,y) dx$$



$$F_X(x) = P(X \leq x) = P((X_i, Y_i) \in A) = \int \int_{A} f_{X,Y}(s,t) ds dt$$

$$A = \{(s,t) : s \leq x, t \in \mathbb{R}\}$$

$$= \int_{-\infty}^x \int_{-\infty}^{\infty} f_{X,Y}(s,t) dt ds$$

$$F_X(x) = \int_{-\infty}^x \bigcirc$$

\rightarrow uvažovat \bigcirc je hustota f_X

Podmíněná hustota

pro dvo-u.v.

$$P_{X|Y}(x|y) \cdot \frac{P_{X,Y}(x,y)}{P_Y(y)} = \underline{\underline{P(X=x|Y=y)}}$$

Definice

Pro spojité n.v. X, Y definujeme podmíněnou hustotu (conditional pdf) předpisem

$$f_{X|Y}(x|y) = \frac{f_{X,Y}(x,y)}{f_Y(y)}$$

pokud je $f_Y(y) > 0$, jinak ji nedefinujeme.

- ▶ připomeňme, že $f_Y(y) = \int_{x \in \mathbb{R}} f_{X,Y}(x,y) dx$
- ▶ pro fixované y je $f_{X|Y}(x|y)$ hustota

$\int_{x \in \mathbb{R}} f_{X|Y}(x|y) = 1$

\Rightarrow n.v. $X|Y=y$ má hustotu $f_{X|Y}(x|y)$

Podmíněná, sdružená a marginální hustota

Věta

$$f_{X,Y}(x,y) = f_Y(y)f_{X|Y}(x|y)$$

$$\rightarrow f_X(x) = \int_{-\infty}^{\infty} f_{X|Y}(x|y)f_Y(y)dy$$

$$f_X = \int_{y \in \mathcal{R}} f_{X|Y}$$

$$x \rightarrow z$$

$$y \rightarrow X$$

Součet spojitých n.v.

Věta

Nechť spojitě X, Y jsou n.n.v. Pak $Z = X + Y$ je také spojitá n.v. a její hustotu dostaneme jako konvoluci funkcí f_X, f_Y , neboli

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx.$$

$$P_Z(z) = \sum P_X(x) \cdot P_Y(z-x)$$

Dk $f_{Z|X}(z|x) = f_Y(z-x)$

(n.v. $Z|X=x$ je stejná jako $Y+x$)

$$\begin{aligned} f_Z(z) &= \int_{-\infty}^{\infty} f_{Z|X}(z|x) \cdot f_X(x) dx \\ &= \int_{-\infty}^{\infty} f_Y(z-x) f_X(x) dx \end{aligned}$$

$P(Z=z|X=x) = P(Y=z-x)$

$X: \Omega \rightarrow \mathbb{R}$

$(X+Y)(\omega)$

$Y: \Omega \rightarrow \mathbb{R}$

$= X(\omega) + Y(\omega)$

$X+Y: \Omega \rightarrow \mathbb{R}$

Ukázka konvoluce

$$\underline{X, Y \sim N(0, 1)} \quad \text{n.n.v.} \quad f_X = f_Y = \varphi$$

$$\underline{\varphi(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}}}$$

$$Z = X + Y$$

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx$$

$$= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{(z-x)^2}{2}} dx$$

$$= \frac{1}{2\pi} e^{-\frac{z^2}{2}} \int_{-\infty}^{\infty} e^{-x^2 - zx} dx =$$

$$\frac{1}{2\pi} e^{-\frac{z^2}{2} + \frac{z^2}{2}} \int_{-\infty}^{\infty} e^{-\frac{(x-\frac{z}{2})^2}{2}} dx$$

$\int_{-\infty}^{\infty} e^{-x^2} = \sqrt{\pi}$

$$= \frac{1}{\sqrt{2} \cdot \sqrt{2\pi}} \cdot e^{-\frac{z^2}{4}}$$

..... hustota $N(0, 2)$

Podmíněná hustota a střední hodnota

- ▶ $\mathbb{E}(X | B) := \int_{-\infty}^{\infty} x \cdot f_{X|B}(x) dx$ DF
- ▶ $\mathbb{E}(g(X)|B) = \int_{-\infty}^{\infty} g(x) f_{X|B}(x) dx$ věta LOTUS

Věta (o úplné střední hodnotě)

Nechť X je spojitá n.v. Pokud B_1, B_2, \dots je rozklad, tak

$$\mathbb{E}(X) = \sum_i P(B_i) \mathbb{E}(X | B_i).$$

Důkaz: pomocí rozkladu hustoty.

$$\int_{-\infty}^{\infty} x f_X(x) dx = \int_{-\infty}^{\infty} x \sum_i P(B_i) f_{X|B_i}(x) dx = \sum_i P(B_i) \int_{-\infty}^{\infty} x f_{X|B_i}(x) dx$$

Podmíněná hustota a střední hodnota

- ▶ $f_{X|Y}(x|y) := \frac{f_{X,Y}(x,y)}{f_Y(y)}$ je hustota n.v. X , pokud $Y = y$
- ▶ $\mathbb{E}(X | Y = y) := \int_{-\infty}^{\infty} x \cdot f_{X|Y}(x, y) dx$ je střední hodnota této veličiny
- ▶ $\mathbb{E}(g(X) | Y = y) = \int_{-\infty}^{\infty} g(x) \cdot f_{X|Y}(x, y) dx$
- ▶ Analogie věty o úplné střední hodnotě:

$$\mathbb{E}(X) = \int_{-\infty}^{\infty} \mathbb{E}(X | Y = y) f_Y(y) dy$$

▶ $\mathbb{E}(X) = \mathbb{E}(\mathbb{E}(X | Y))$

$\sum \mathbb{E}(X|B_i) P(B_i)$

$g(y)$

" $\mathbb{E}(g(Y))$ "

Přehled

Spojité náhodné vektory

Kovariance a korelace

Nerovnosti


Limitní věty – aproximace

Kovariance

Definice

Pro n.v. X, Y definujeme jejich kovarianci (covariance) předpisem

$$\text{cov}(X, Y) = \mathbb{E}((X - \mathbb{E}X)(Y - \mathbb{E}Y)).$$



Věta

$$\text{cov}(X, Y) = \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)$$

l.u. stálo.

$$\mathbb{E}(XY - \mathbb{E}X \cdot Y - X \cdot \mathbb{E}Y + \mathbb{E}X \cdot \mathbb{E}Y) = \mathbb{E}(XY) - \mathbb{E}X \cdot \mathbb{E}Y$$

- ▶ $\text{var}(X) = \text{cov}(X, X)$ ✓
- ▶ $\text{cov}(X, aY + bZ + c) = a \text{cov}(X, Y) + b \text{cov}(X, Z)$
- ▶ $\text{cov}(X, Y) = 0$ pokud X, Y jsou nezávislé
- ▶ ale nejen tehdy

$$\mathbb{E}(cY) = c \mathbb{E}(Y)$$


$$\mathbb{E}(\dots - \mathbb{E}X \cdot Y - \dots) = \dots - \mathbb{E}(\mathbb{E}X \cdot Y) - \dots$$

číslo

Korelace

Definice


Korelace náhodných veličin X, Y je definována předpisem



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

- ▶ je to přenormovaná kovariance
- ▶ $-1 \leq \rho(X, Y) \leq 1$ (cvič.)
- ▶ Korelace neznamená příčinnou souvislost! (Např., korelace je symetrická, kauzalita nikoli!)
- ▶ Naopak, nekorelace neznamená nezávislost. (Př: X libovolná, $Y = +X$ nebo $Y = -X$, obojí se stejnou pravděpodobností.)

“
 $\rho = 1$ ---- $X = Y$
 $\rho = -1$ ---- $X = -Y$
 $\rho = 0$ ---- $X \& Y$ nav. nez.



$X = \pm Y$

Rozptyl součtu

Věta

Necht' $X = \sum_{i=1}^n X_i$. Pak

$$\text{var}(X) = \sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_i, X_j) = \sum_{i=1}^n \text{var}(X_i) + \sum_{i \neq j} \text{cov}(X_i, X_j).$$

Spec. jsou-li X_1, \dots, X_n nezávislé, pak

$$\Rightarrow \text{cov}(X_i, X_j) = 0$$

$$\text{var}(X) = \sum_{i=1}^n \text{var}(X_i).$$

Důk $\text{var } X = E(X \cdot X) - (EX)^2$

$$\begin{aligned} &= E\left(\sum_{i=1}^n X_i \cdot \sum_{j=1}^n X_j\right) - \left(\sum_{i=1}^n EX_i\right) \left(\sum_{j=1}^n EX_j\right) \\ &= E\left(\sum_{i,j=1}^n X_i \cdot X_j\right) - \sum_{i,j=1}^n EX_i \cdot EX_j = \sum_{i,j=1}^n EX_i X_j - EX_i EX_j \end{aligned}$$

Přehled

Spojité náhodné vektory

Kovariance a korelace

Nerovnosti

Limitní věty – aproximace

Cauchyho nerovnost

Věta

Nechť X, Y mají konečnou střední hodnotu a rozptyl. Pak

$$\underline{\mathbb{E}(XY) \leq \sqrt{\mathbb{E}(X^2)\mathbb{E}(Y^2)}}$$

DK - jako Cauchyho nev. v LA

skal. součin $X, Y \rightarrow \mathbb{E}(X \cdot Y)$

norma $X \rightarrow \sqrt{\mathbb{E}(X^2)}$

- Důsledek pro korelaci: $-1 \leq \rho(X, Y) \leq 1$

Jensenova nerovnost

$$g(z) = z^2$$


$$\mathbb{E}(X^2) \geq (\mathbb{E}X)^2$$

Věta

Nechť X má konečnou střední hodnotu a necht' g je konvexní reálná funkce. Pak

$$\mathbb{E}(g(X)) \geq g(\mathbb{E}(X)).$$

(Pro konkávní platí opačná nerovnost.)



Dk $\mu = \mathbb{E}(X)$ $L(\mu) = g(\mu)$

$\forall z \in \text{obst.}$ $L(z) \leq g(z)$

\Downarrow
 $L(X) \leq g(X)$

$\mathbb{E}(L(X)) \leq \mathbb{E}g(X)$
 $L(\mathbb{E}X) = \mathbb{E}(L(X)) \leq \mathbb{E}g(X)$

na dvoje sdr. n.l. fce $\mathbb{R} \rightarrow \mathbb{R}$

Markovova nerovnost

$$B_1 = \{X \geq a\}, \quad B_2 = \{X < a\}$$

Věta

Nechť náhodná veličina X splňuje $X \geq 0$. Pak

$$P(X \geq a) \leq \frac{\mathbb{E}(X)}{a}. \quad \checkmark$$

Dk

$$\mathbb{E}(X) = P(X \geq a) \underbrace{\mathbb{E}(X | X \geq a)}_{\geq a} + \underbrace{P(X < a)}_{\geq 0} \underbrace{\mathbb{E}(X | X < a)}_{\geq 0}$$

$$\mathbb{E}(X) \geq P(X \geq a) \cdot a$$

$X(\omega)$ vět: ω $a = 2\mathbb{E}(X)$
 Ω : skupina lidí $P(X \geq 2\mathbb{E}(X)) \leq \frac{\mathbb{E}(X)}{2\mathbb{E}(X)} = \frac{1}{2}$
 \Rightarrow odp. 2 je ne.

Čebyševova (Chebyshev) nerovnost

Věta

Nechť X má konečnou střední hodnotu μ a rozptyl σ^2 . Pak

$$P(|X - \mu| \geq a \cdot \sigma) \leq \frac{1}{a^2}.$$

Dk $Y = \frac{(X - \mu)^2}{\sigma^2}$

$$P(Y \geq a^2 \sigma^2) \leq \frac{E(Y)}{a^2 \sigma^2} = \frac{\text{var}(X)}{a^2 \sigma^2}$$

Markov
$$= \frac{\sigma^2}{a^2 \sigma^2}$$

Chernoffova (Černovova) nerovnost

Věta

Nechť $X = \sum_{i=1}^n X_i$, kde X_i jsou n.n.v. nabývající hodnot ± 1 s pravděpodobností $1/2$. Pak pro $t > 0$ platí

$$P(X \leq -t) = P(X \geq t) \leq e^{-t^2/2\sigma^2},$$

kde $\sigma = \sigma_X = \sqrt{n}$.

Bez dk.

Chetyshevova věta

$$\frac{\text{const.}}{t^2} \gg e^{-\frac{t^2}{2\sigma^2}}$$

Přehled

Spojité náhodné vektory

Kovariance a korelace

Nerovnosti

Limitní věty – aproximace

Silný zákon velkých čísel (strong law of large numbers)

Věta

Nechť X_1, \dots, X_n jsou stejně rozdělené n.n.v. se stř. hodnotou μ a rozptylem σ^2 . Označme $S_n = (X_1 + \dots + X_n)/n$ tzv. výběrový průměr (sample mean). Pak platí

$$\lim_{n \rightarrow \infty} S_n = \mu \quad \text{skoro jistě (tj. s pravděpodobností 1).}$$

Říkáme, že posloupnost S_n konverguje k μ skoro jistě (almost surely).


$$P\left(\lim_{n \rightarrow \infty} S_n = \mu\right) \equiv 1$$

Monte Carlo integration


Jak spočítat $\int_{x \in A} g(x) dx$? = μ

Speciálně:

$$g(x) = \begin{cases} 1 & \text{pro } x \in S \\ 0 & \text{jinak} \end{cases}$$



... obsah kruhu



$\Omega = A$... n nez. bodů $\omega_i \in A$

$$X_i(\omega_i) = g(\omega_i)$$

$$EX_i = \int_A g(x) \cdot \frac{1}{|A|} = \frac{\mu}{|A|} = \mu$$

TADY SNAŽE: $EX_i = 1 \cdot P(X_i = 1) = 1 \cdot \frac{\mu}{|A|}$

$$S_n = \frac{X_1 + \dots + X_n}{n}$$

$\rightarrow \mu$ s. j.

$|A|$ - plocha A
 $|g|$ - plocha obrazu
 $|g| = \mu$

Slabý zákon velkých čísel (weak law of large numbers)

Věta

Nechť X_1, \dots, X_n jsou stejně rozdělené n.n.v. se stř. hodnotou μ a rozptylem σ^2 . Označme $S_n = (X_1 + \dots + X_n)/n$. Pak pro každé $\varepsilon > 0$ platí

$$\lim_{n \rightarrow \infty} P(|S_n - \mu| > \varepsilon) = 0.$$

Říkáme, že posloupnost S_n konverguje k μ v pravděpodobnosti (in probability).

Centrální Limitní věta

Centrální Limitní věta

Věta

Nechť X_1, \dots, X_n jsou stejně rozdělené n.n.v. se střední hodnotou μ a rozptylem σ^2 . Označme

$$Y_n = ((X_1 + \dots + X_n) - n\mu) / (\sqrt{n} \cdot \sigma).$$

Pak $Y_n \xrightarrow{d} N(0, 1)$. Neboli, pokud F_n je distribuční funkce Y_n , tak

$$\lim_{n \rightarrow \infty} F_n(x) = \Phi(x) \quad \text{for every } x \in \mathbb{R}.$$

Říkáme, že posloupnost Y_n konverguje k $N(0, 1)$ v distribuci (in distribution).

Momentová vytvořující funkce

Definice

Pro náhodnou veličinu X označíme

$$M_X(t) = \mathbb{E}(e^{tX}).$$

Funkci $M_X(t)$ nazýváme momentová vytvořující funkce (moment generating function).

- ▶ $M_{Bern(p)}(t) = p \cdot e^t + (1 - p)$.
- ▶ $M_X(t) = \sum_{n=0}^{\infty} \mathbb{E}(X^n) \frac{t^n}{n!}$.
- ▶ $M_{X+Y}(t) = M_X(t)M_Y(t)$, jsou-li X, Y n.n.v.
- ▶ $M_{Bin(n,p)} = (pe^t + 1 - p)^n$
- ▶ $M_{N(0,1)} = e^{t^2/2}$
- ▶ $M_{Exp(\lambda)} = \frac{1}{1-t/\lambda}$
- ▶ Pokud $M_X(t) = M_Y(t)$ na intervalu $(-a, a)$ pro nějaké $a > 0$, tak je $X = Y$ s.j.