

NMAI059 Pravděpodobnost a statistika 1

6. přednáška

Robert Šámal

Přehled

Náhodné vektory

Zpátky k základům

Limitní věty – zákony velkých čísel

Sdružená distribuční funkce (Joint cdf)


(1D případ: $P(X \in (a, b]) = F_X(b) - F_X(a)$)

Definice

Pro n.v. X, Y na pravděpodobnostním prostoru (Ω, \mathcal{F}, P) definujeme jejich sdruženou distribuční funkci (joint cdf)

$F_{X,Y} : \mathbb{R}^2 \rightarrow [0, 1]$ předpisem

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



- ▶ Mohli bychom definovat i pro více než dvě n.v.

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n)$$

- ▶ Můžeme odsud odvodit pravděpodobnost obdélníku:

$$P(X \in (a, b] \& Y \in (c, d]) = F(b, d) - F(a, c)$$

$$F(b, d) - F(a, d) - F(b, c) + F(a, c)$$




Sdružená hustota (Joint pdf)

- Často můžeme sdruženou distribuční funkci psát jako integrál pomocí nezáporné funkce $f_{X,Y}$

$$\iint_{\mathbb{R}^2} f_{X,Y} = 1$$


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



- Pak nazýváme n.v. X, Y sdruženě spojitě. Funkce $f_{X,Y}$ je jejich sdružená hustota.
- Jako u jednorozměrného případu může být $f_{X,Y} > 1$!
- Stejně jako u jednorozměrného případu můžeme pak pomocí hustoty vyjádřit i další pravděpodobnosti:



$$P((X, Y) \in S) = \int_S f_{X,Y}(x,y) dx dy$$



$$f_{X,Y}(x,y) = \frac{\partial^2 F_{X,Y}(x,y)}{\partial x \partial y}$$

avartů
c = absolutní hodnota

LOTUS

- ▶ Stejně jako v diskrétním případě platí pro střední hodnotu funkce dvou n.v.

$$\mathbb{E}(g(X, Y)) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f_{X, Y}(x, y) dx dy.$$

- ▶ A stejně jako v diskrétním případě odsud odvodíme $\mathbb{E}(aX + bY + c) = a \cdot \mathbb{E}(X) + b \cdot \mathbb{E}(Y) + c.$

$$\iint f = 1$$

$$g(x, y) = ax + by + c$$

$$\mathbb{E}_g(X, Y) = \iint (ax + by + c) f(x, y) = \iint ax + by + c = \iint ax + \iint by + \iint c$$

$$a \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x, y) = a \int x_i f(x, y) = a \int x f_X(x) = a \mathbb{E}X$$

$\sim P(X=x) \quad f_X(x) (?)$

Nezávislost spojitých náhodných veličin

$\{X=x\}$ a $\{Y=y\}$ -- pro diskr. n.v.

Definice

Libovolné náhodné veličiny nazveme **nezávislé (independent)**, pokud jevy $\{X \leq x\}$ a $\{Y \leq y\}$ jsou nezávislé pro libovolná $x, y \in \mathbb{R}$. Ekvivalentně,

Průnikem

$$\rightarrow P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y),$$

$\int \int f_{X,Y}(s,t) ds dt$

$= \int \int f_X(s) f_Y(t) ds dt = \int f_X(s) ds \cdot \int f_Y(t) dt = F_X(x) \cdot F_Y(y)$

$F_{X,Y}(x,y) = F_X(x)F_Y(y)$

Věta

Nechť X, Y mají sdruženou hustotu $f_{X,Y}$. Následující tvrzení jsou ekvivalentní:

- ▶ X, Y jsou nezávislé
- ▶ $f_{X,Y}(x,y) = f_X(x)f_Y(y)$ $\Uparrow \Downarrow$
 $x, y \in \mathbb{R}$

$$f_{X,Y} = \frac{\partial^2 F_{X,Y}(x,y)}{\partial x \partial y} = \frac{\partial^2}{\partial x \partial y} [F_X(x) \cdot F_Y(y)] = \left(\frac{\partial}{\partial x} F_X(x) \right) \left(\frac{\partial}{\partial y} F_Y(y) \right) = f_X(x) f_Y(y)$$

Vícerozměrné normální rozdělení

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



φ .. hust. $N(0,1)$ / $\int_{\mathbb{R}^n} f = 1$
 $= \int_{\mathbb{R}} \varphi \cdot \int_{\mathbb{R}} \dots = 1$

► $f(t_1, \dots, t_n) = \varphi(t_1)\varphi(t_2)\dots\varphi(t_n) = \left(\frac{1}{\sqrt{2\pi}}\right)^n e^{-\frac{t_1^2 + \dots + t_n^2}{2}} > 0$

► $f(t_1, \dots, t_n) = (2\pi)^{-n/2} e^{-r^2/2}$, kde $r^2 = t_1^2 + \dots + t_n^2$
radiálně symetrická funkce

► lze použít k jednoduchému generování bodu na n -rozměrné sféře : $\frac{z}{\|z\|}$

► první souřadnice je $N(0, 1)$, $z_2 \sim N(0,1), \dots, z_n \sim N(0,1)$

► tudíž skal. součin s libovolným jednotkovým vektorem je $N(0, 1)$

→ z_1, \dots, z_n jsou n.u.v.

→ z vypr. jako n -tci $N(0,1)$

$\langle z, u \rangle = \sum u_i z_i \sim N(0,1)$

$u \in \mathbb{R}^n, \|u\|=1$... u je prvok vektor báze
 $z \sim N(0,1) \Rightarrow \langle z, u \rangle = 1$

$\langle z, u \rangle = \text{skal. } z \cdot u \sim N(0,1)$

Vícerozměrné normální rozdělení obecné

- ▶ Obecněji můžeme vzít náhodný vektor s hustotou $c \cdot e^{Q(t)}$,
kde $c > 0$ je vhodná konstanta a $Q(t)$ je obecná
kvadratická funkce.
- ▶ Používá se ve strojovém učení.
- ▶ Souřadnice nejsou nezávislé!

$$Q(t) = - \frac{t^T A t + b^T t + c}{2}$$

n^2 koef.

Součet spojitých n.v.

$$E Z = E X + E Y$$

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

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

Dk y nech., obdobný disk. případ

$$P_Z(z) = \sum_{x \in \text{supp} X} P_X(x) P_Y(z-x)$$

Podmiňování

Definice

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

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

$$\frac{P(X \leq x \cap B)}{P(B)}$$

$$= \int_{-\infty}^x f_{X|B}(s) ds$$

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

Věta

B_1, B_2, \dots
rozděl Ω

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

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

-- věta o
rozdělení případů
pro pravd.

Důkaz – spec. případ byl na cvičení (dva algoritmy).

Podmíněná hustota $B = \{y = y\}$

chceme: $f_{X|B}$... $P(B) = 0!$

Definice


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

$\int_{x=-\infty}^{\infty}$

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

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



Podmíněná, sdružená a marginální hustota

Věta


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

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

$$f_X(x) = \int_{-\infty}^{\infty} \underline{f_{X,Y}(x,y)} dy$$

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

$$= \int_B f_{X,Y}(s,t) = P((X,Y) \in B)$$



Spojité Bayesova věta

$$P(A|B) \rightsquigarrow P(B|A)$$

$$f_{x/y} \rightsquigarrow f_{y/x}$$

Přehled

Náhodné vektory

Zpátky k základům


Limitní věty – zákony velkých čísel

Kovariance

Definice

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

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



Věta

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

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

$\mathbb{E}XY = \mathbb{E}X \cdot \mathbb{E}Y$... dk jsme
použili disk.
n. n. v.
plus pro
cov. n. n. v.

Korelace

Definice

Korelace náhodných veličin X, Y je definována předpisem

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

- ▶ je to přenormovaná kovariance
- ▶ $-1 \leq \rho(X, Y) \leq 1$ (cvič.)
- ▶ korelace neznamená příčinnou souvislost!

$$X = Y \dots \rho = 1$$

$$X = -Y \dots \rho = -1$$

Rozptyl součtu

Věta

Nechť $X = \sum_{i=1}^n X_i$. 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

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

označ: $y_i = X_i - EX_i$

$$y = \sum y_i = X - EX$$
$$= \sum X_i - \sum EX_i$$

$$\text{var } X = E y^2 = E (X - EX)^2 = E \left(\sum_i y_i \cdot \sum_j y_j \right) = \sum_{i,j} E y_i y_j$$

$\text{cov}(X_i, X_j)$

Rozptyl součtu – ukázka

Problém šatnářky: n klobouků přiřadíme náhodně n lidem.

X_i je indikátor jevu „ i -tý člověk dostal svůj klobouk“

$$X = \sum_{i=1}^n X_i$$

Přehled

Náhodné vektory

Zpátky k základům

Limitní věty – zákony velkých čísel

První zákon velkých čísel

Věta

Nechť X_1, X_2, \dots jsou n.n.v. se střední hodnotou μ a rozptylem σ^2 . Označme $S_n = (X_1 + \dots + X_n)/n$. Pak

$$\mathbb{E}((S_n - \mu)^2) \rightarrow 0.$$

Říkáme, že posloupnost průměrů konverguje k μ v L_2 -normě (in mean square).

Slabý zákon velkých čísel (weak law of large numbers)

Věta

Nechť X_1, \dots, X_n jsou n.n.v. se střední 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).

Silný zákon velkých čísel (strong law of large numbers)

Věta

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

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

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

