

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

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

- ▶ 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. $P(B) > 0$.

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

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

► pokud $B = \{X \in S\}$, tak

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

Věta o rozkladu hustoty

Věta (věta o rozkladu hustoty)

Nechť X je spojitá n.v., necht' B_1, B_2, \dots je rozklad Ω . Pak

$$F_X(x) = \sum_i P(B_i) F_{X|B_i}(x) \quad \mathbf{a}$$
$$f_X(x) = \sum_i P(B_i) f_{X|B_i}(x).$$

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

Marginální hustota

Věta

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

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

Podmíněná hustota

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

Podmíněná, sdružená a marginální hustota

Věta

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

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

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

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

Ukázka konvoluce

Podmíněná hustota a střední hodnota

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

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.

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:

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

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

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

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

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

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.)

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

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

Přehled

Spojité náhodné vektory

Kovariance a korelace

Nerovnosti

Limitní věty – aproximace

Cauchyho nerovnost

Věta

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

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

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

Jensenova nerovnost

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.)

Markovova nerovnost

Věta

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

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

Čebyševova (Chebyshev) nerovnost

Věta

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

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

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.

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).

Monte Carlo integration

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

Speciálně:

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

... obsah kruhu

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

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

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.