

# 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)

## Definice

Pro n.v.  $X, Y$  na pravděpodobnostním prostoru  $(\Omega, \mathcal{F}, P)$  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.  
 $F_{X_1, \dots, X_n}(x_1, \dots, x_n)$ .
- ▶ Můžeme odsud odvodit pravděpodobnost obdélníku:  
 $P(X \in (a, b] \& Y \in (c, d]) =$

## Sdružená hustota (Joint pdf)

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

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

- ▶ Pak nazýváme n.v.  $X, Y$  sdruženě spojité. 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:

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

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

# 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  $\mathbb{E}(aX + bY + c) = a \cdot \mathbb{E}(X) + b \cdot \mathbb{E}(Y) + c.$

# Nezávislost spojitých náhodných veličin

## 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,*

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

## Věta

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

- ▶  $X, Y$  jsou nezávislé
- ▶  $f_{X,Y}(x, y) = f_X(x)f_Y(y)$

# Vícerozměrné normální rozdělení

- ▶  $\varphi(t) = \frac{1}{\sqrt{2\pi}} e^{-t^2/2}$
- ▶  $f(t_1, \dots, t_n) = \varphi(t_1)\varphi(t_2)\cdots\varphi(t_n) = \frac{1}{\sqrt{2\pi}^n} e^{-\frac{t_1^2 + \dots + t_n^2}{2}}$
- ▶  $f(t_1, \dots, t_n) = (2\pi)^{-n/2} e^{-r^2/2}$ , kde  $r^2 = t_1^2 + \dots + t_n^2$   
*radiálně symetrická funkce*
- ▶ Necht  $Z = (Z_1, \dots, Z_n)$  má hustotu  $f$ .
- ▶  $Z/\|Z\|$  je uniformně náhodný bod na  $n$ -rozměrné sféře.
- ▶  $Z_i \sim N(0, 1)$
- ▶ tudíž skal. součin s libovolným jednotkovým vektorem je  $N(0, 1)$
- ▶  $\langle u, Z \rangle = \sum_{i=1}^n u_i Z_i$  má také rozdělení  $N(0, 1)$

# 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!



# 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*

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

# Podmiňování

## Definice

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

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

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

## Věta

Nechť  $B_1, B_2, \dots$  je rozklad  $\Omega$ . Pak

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

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

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

# 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

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

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

# Spojité Bayesova věta

# Přehled

Náhodné vektory

Zpátky k základům

Limitní věty – zákony velkých čísel

# 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!



# 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*

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

## 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  $\mu$  a rozptylem  $\sigma^2$ . Označme  $S_n = (X_1 + \dots + X_n)/n$ . Pak*

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

*Říkáme, že posloupnost průměrů konverguje k  $\mu$  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  $\mu$  a rozptylem  $\sigma^2$ . 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  $\mu$  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  $\mu$  a rozptylem  $\sigma^2$ . 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  $\mu$  skoro jistě (almost surely).*

# CLT