

# NMAI059 Pravděpodobnost a statistika 1

## 7. přednáška

Robert Šámal

# Přehled

Spojité distribuce

Náhodné vektory

Zpátky k základům

Dokončení k spojitým vektorům

Nerovnosti


Limitní věty – aproximace

## Jaká rozdělení jsme už potkali

- ▶  $U(a, b)$  – uniformní – rovnoměrné na intervalu  $[a, b]$
  
- ▶  $Exp(\lambda)$  – exponenciální – za jak dlouho se utrhne ucho u džbánu
  
- ▶  $N(\mu, \sigma^2)$  – normální – kolik váží chleba

# Cauchyho rozdělení

- ▶ *Cauchyho rozdělení*: hustota  $f(x) = \frac{1}{\pi(1+x^2)}$
- ▶ nemá střední hodnotu!!!




# Gamma rozdělení

- ▶  $Gamma(w, \lambda)$ , *gamma rozdělení s parametry*  $w > 0$  a  $\lambda > 0$  má hustotu

$$f(x) = \begin{cases} 0 & \text{pro } x \leq 0 \\ \frac{1}{\Gamma(w)} \lambda^w x^{w-1} e^{-\lambda x} & \text{pro } x \geq 0 \end{cases}$$

kde  $\Gamma(w) = (w - 1)! = \int_0^\infty x^{w-1} e^{-x} dx$ .

- ▶ Pro  $w = 1$  dostáváme znovu exponenciální rozdělení.
- ▶ Pokud  $X_1, \dots, X_n$  jsou n.n.v. s rozdělením  $Exp(\lambda)$ , tak  $X_1 + \dots + X_n \sim Gamma(n, \lambda)$ .
- ▶ Modeluje mj. životnost součástky, souhrn dešťových srážek za rok, latenci webového serveru.



## A mnoho dalších

- ▶  $Beta(s, t)$  – beta rozdělení
- ▶  $\chi^2$  rozdělení s  $k$  stupni volnosti = chí-kvadrát ( $\chi_k^2$ ) je jiné jméno pro  $Gamma(\frac{1}{2}k, \frac{1}{2})$ . Je to rozdělení  $Z_1^2 + \dots + Z_k^2$ , kde  $Z_i \sim N(0, 1)$  jsou n.n.v.
- ▶ Studentova  $t$ -distribuce
- ▶ atd. atd.

# Uniformní rozdělení

- ▶ N.v.  $X$  má uniformní rozdělení na intervalu  $[a, b]$ , píšeme  $X \sim U(a, b)$ , pokud  $f_X(x) = 1/(b - a)$  pro  $x \in [a, b]$  a  $f_X(x) = 0$  jinak.

# Universalita unif.

## Věta

*Nechť  $X$  je n.v. s distribuční funkcí  $F_X = F$ , necht'  $F$  je spojitá a rostoucí. Pak  $F(X) \sim U(0, 1)$ .*

## Věta

*Nechť  $F$  je funkce „typu distribuční funkce“: neklesající zprava spojitá funkce s  $\lim_{x \rightarrow -\infty} F(x) = 0$  a  $\lim_{x \rightarrow +\infty} F(x) = 1$ . Necht'  $Q$  je odpovídající kvantilová funkce.*

*Nechť  $U \sim U(0, 1)$  a  $X = Q(U)$ . Pak  $X$  má distribuční funkci  $F$ .*





# Přehled

Spojité distribuce

**Náhodné vektory**

Zpátky k základům

Dokončení k spojitým vektorům

Nerovnosti

Limitní věty – aproximace

# 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

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

▶ Formální podmínka: potřebujeme  $\{X \leq x \ \& \ Y \leq y\} \in \mathcal{F}$ , jinak  $(X, Y)$  není náhodný vektor.

▶ 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, pro „rozumnou množinu  $A$ “.

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

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

$$\blacktriangleright f_{X,Y}(x,y) \doteq \frac{P(x \leq X \leq x + \Delta_x \ \& \ y \leq Y \leq y + \Delta_y)}{\Delta_x \Delta_y}$$

# LOTUS

- ▶ Analogicky 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 tak 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  $f_{X,Y}$  (a hustoty  $f_X, f_Y$ ). 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*




Image by Wikipedia editor Piotrg.

- ▶ Necht'  $Z = (Z_1, \dots, Z_n)$  má hustotu  $f$ .
- ▶  $Z_1, \dots, Z_n$  jsou n.n.v.,  $Z_i \sim N(0, 1)$
- ▶  $Z/\|Z\|$  je uniformně náhodný bod na  $n$ -rozměrné sféře.
- ▶ tudíž skal. součin  $Z$  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!




Image by Wikipedia editor Bscan.

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

# Přehled

Spojité distribuce

Náhodné vektory

**Zpátky k základům**

Dokončení k spojitým vektorům

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 distribuce

Náhodné vektory

Zpátky k základům

**Dokončení k spojitým vektorům**

Nerovnosti

Limitní věty – aproximace



# 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

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

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

# Podmíněná hustota a střední hodnota

- ▶  $F_{X|B}(x) := P(X \leq x | B)$  ... distr. funkce n.v.  $X$  zúžené na  $B \subseteq \Omega$ , potřebujeme  $P(B) > 0$ .
- ▶  $f_{X|B}$  odpovídající hustota
- ▶ pokud  $B = \{X \in S\}$ , tak

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

- ▶  $\mathbb{E}(X | B) = \int_{-\infty}^{\infty} x \cdot f_{X|B}(x) dx$
- ▶  $\mathbb{E}(g(X) | B) = \int_{-\infty}^{\infty} g(x) f_{X|B}(x) dx$
- ▶ Pokud  $B_1, B_2, \dots$  je rozklad, tak

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

## 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
- ▶  $\mathbb{E}(g(X) | Y = y) = \int_{-\infty}^{\infty} g(x) \cdot f_{X|Y}(x, y) dx$



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

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

# Přehled

Spojité distribuce

Náhodné vektory

Zpátky k základům

Dokončení k spojitým vektorům

**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  $\mu$  a rozptyl  $\sigma^2$ . 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  $\pm 1$  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 distribuce

Náhodné vektory

Zpátky k základům

Dokončení k spojitým vektorům

Nerovnosti

**Limitní věty – aproximace**

# Silný zákon velkých čísel (strong law of large numbers)

## Věta

*Nechť  $X_1, \dots, X_n$  jsou n.n.v. se stř. hodnotou  $\mu$  a rozptylem  $\sigma^2$ . 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  $\mu$  skoro jistě (almost surely).*

# Monte Carlo integration

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

# Slabý zákon velkých čísel (weak law of large numbers)

## Věta

*Nechť  $X_1, \dots, X_n$  jsou n.n.v. se stř. 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).*

# Centrální Limitní věta

# Centrální Limitní věta

## Věta

*Nechť  $X_1, \dots, X_n$  jsou n.n.v. se střední hodnotou  $\mu$  a rozptylem  $\sigma^2$ . 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.