

# Přednáška 4 – Náhodné vektory a regresní analýza

Náhodný vektor  $[x, y]$  – sdružené rozdělení

$$f(x, y) = \underbrace{f(x|y)}_{\text{sdružené}} \cdot \underbrace{f(y)}_{\text{podmíněné marginální}} = \overbrace{f(y|x)f(x)}^{\text{totéž obráceně}}$$

- $x, y$  – spojité nebo diskrétní
- náhodný vektor – vektor N.V.  $x, y$
- vztah mezi  $x, y$

- Sdružené rozdělení  $f(x, y)$  popisuje obě veličiny  $x$  a  $y$  najednou
- Podmíněné rozdělení  $f(x|y)$  – chování veličiny  $x$  za podmínky znalosti  $y$
- Marginální rozdělení  $f(y)$  – informace pouze o veličině  $y$


Výpočet podmíněných rozdělení

$$\underbrace{f(x|y)}_{\text{podmíněné}} = \frac{\overbrace{f(x, y)}^{\text{sdružené}}}{\underbrace{f(y)}_{\text{marginální}}}$$

$$\underbrace{f(y|x)}_{\text{podmíněné}} = \frac{\overbrace{f(x, y)}^{\text{sdružené}}}{\underbrace{f(x)}_{\text{marginální}}}$$



# Příklad pro diskrétní náhodné veličiny $x, y$



Křížovatka

$$x \in \{\text{red car} = 1, \text{blue truck} = 2\}$$

$$y \in \{\leftarrow=1, \rightarrow=2, \uparrow=3\}$$

Data:

|            |     |     |     |
|------------|-----|-----|-----|
|            | ↶   | ↷   | ↑   |
| red car    | 200 | 250 | 100 |
| blue truck | 110 | 150 | 190 |

Sdružené  $f(x, y)$ ,  $\sum_{i,j}^{n,m} p_{ij} = 1$

| $y \backslash x$ | ↶    | ↷    | ↑    |
|------------------|------|------|------|
| red car          | 0.2  | 0.25 | 0.1  |
| blue truck       | 0.11 | 0.15 | 0.19 |

⇒

Marginální  $f(x)$ ,  $\sum_{i=1}^n p_i = 1$

| $f(x)$                    |
|---------------------------|
| 0.2 + 0.25 + 0.1 = 0.55   |
| 0.11 + 0.15 + 0.19 = 0.45 |

Marginální  $f(y)$ ,  $\sum_{j=1}^m p_j = 1$

|        |                   |     |      |
|--------|-------------------|-----|------|
| $f(y)$ | 0.2 + 0.11 = 0.31 | 0.4 | 0.29 |
|--------|-------------------|-----|------|

$f(\text{auto}| \text{odbočení})?$

$f(\text{odbočení}| \text{auto})?$

# Výpočet podmíněných rozdělení

$$f(y|x) = \frac{f(x,y)}{f(x)} =$$

| $x$ | $y$ | $\leftarrow$ | $\rightarrow$ | $\uparrow$ |
|-----|-----|--------------|---------------|------------|
|     |     | 0.2          | 0.25          | 0.1        |
|     |     | 0.11         | 0.15          | 0.19       |

: 

|        |
|--------|
| $f(x)$ |
| 0.55   |
| 0.45   |

 =

| $f(\text{odbočení} \text{auto})$ | $\leftarrow$               | $\rightarrow$              | $\uparrow$ |                 |
|----------------------------------|----------------------------|----------------------------|------------|-----------------|
|                                  | $\frac{0.2}{0.55} = 0.36$  | $\frac{0.25}{0.55} = 0.46$ | 0.18       | $\Rightarrow 1$ |
|                                  | $\frac{0.11}{0.45} = 0.25$ | $\frac{0.15}{0.45} = 0.33$ | 0.42       | $\Rightarrow 1$ |

$$f(x|y) = \frac{f(x,y)}{f(y)} =$$

| $f(\text{auto} \text{odbočení})$ | $\leftarrow$               | $\rightarrow$             | $\uparrow$ |  |
|----------------------------------|----------------------------|---------------------------|------------|--|
|                                  | $\frac{0.2}{0.31} = 0.65$  | $\frac{0.25}{0.4} = 0.62$ | 0.34       |  |
|                                  | $\frac{0.11}{0.31} = 0.35$ | $\frac{0.15}{0.4} = 0.38$ | 0.66       |  |

$\downarrow$   
1

$\downarrow$   
1

$\downarrow$   
1

## Příklad pro spojité náhodné veličiny

Sdružená hp:  $f(x, y) = 6x^2y$ , pro  $x, y \in (0, 1)$ ,

Marginální hp:  $f(x) = \int_0^1 f(x, y) dy = \int_0^1 6x^2 y dy = \left[ 6x^2 \frac{y^2}{2} \right]_0^1 = 3x^2$

Marginální hp:  $f(y) = \int_0^1 f(x, y) dx = \int_0^1 6x^2 y dx = \left[ 6 \frac{x^3}{3} y \right]_0^1 = 2y$

Podmíněná hp:  $f(x|y) = \frac{f(x, y)}{f(y)} = \frac{6x^2y}{2y} = 3x^2$

Podmíněná hp:  $f(y|x) = \frac{f(x, y)}{f(x)} = \frac{6x^2y}{3x^2} = 2y$

Pokud  $f(x, y) = f(x)f(y)$ , veličiny jsou nezávislé

$$f(x)f(y) = 3x^2 2y = 6x^2y = f(x, y)$$

Porovnejte:  $f(x, y) = f(y|x)f(x) = f(y)f(x)$

# Kovariance

– charakteristika dvou náhodných veličin  $x$  a  $y$ , která vypovídá o jejích vazbě

## Kovariance diskrétních náhodných veličin

$$C[x, y] = \sum_i \sum_j (x_i - E[x])(y_j - E[y])f(x_i, y_j)$$

## Kovariance spojitéhých náhodných veličin

$$C[x, y] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - E[x])(y - E[y])f(x, y) dx dy$$

- Přímá závislost veličin

$$C[x, y] > 0$$

- Nepřímá závislost veličin

$$C[x, y] < 0$$

- Nezávislé veličiny

$$C[x, y] = 0$$

## Kovarianční matice

$$\text{cov}[x, y] = \begin{bmatrix} D[x] & C[x, y] \\ C[x, y] & D[y] \end{bmatrix}$$

# Korelace – míra vztahu mezi dvěma veličinami (síla a směr)

- Korelační koeficient

## Pearsonův korelační koeficient

$$\rho_p = \frac{C[x, y]}{\sigma_x \sigma_y}$$

lineární závislost, normální data

## Spearmanův koeficient pořadové korelace

$$\rho_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}, \quad d_i - \text{rozdíl pořadí}$$

lineární/nelineární závislost, data bez normality

- $\rho \in (-1, 1)$
- $0 < \rho \leq 1$  – přímá závislost (pozitivní korelace)
- $-1 \leq \rho < 0$  – nepřímá závislost (negativní korelace)
- pro nekorelované veličiny  $\rho = 0$

## Poznámka


- Korelace  $\neq$  kauzalita – musí existovat kauzální vztah

## Příklad:

$x$  – prodej zmrzliny,  $y$  – kriminalita

$\rho_{xy} > 0$  nebo  $r_s > 0$

- vliv – vyšší letní teploty, příliv turistů
- pečlivý výběr veličin



zdroj: [wikipedia](#)

# Regresní analýza – popis vztahu mezi korelovanými x a y



Lineární regrese – metoda proložení naměřených hodnot přímkou

$$y = b_0 + b_1 x, \quad b_0, b_1 - \text{regresní koeficienty}$$



Příklad:

$y$  – spotřeba paliva,  $x$  – poloha plynového pedálu



- přímka neprochází všemi body – odchylky (rezidua)  $e$
- minimální odchylky
- optimální regresní přímka – metoda nejmenších čtverců

# Metoda nejmenších čtverců – $b_0$ , $b_1$

Pro data  $[x_i, y_i]_{i=1}^N$

Odhad regresních koeficientů

$$\hat{b}_1 = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2}, \quad \hat{b}_0 = \bar{y} - \hat{b}_1 \bar{x}$$

- $e_i = y_i - b_0 - b_1 x_i$
- $\sum_{i=1}^N e_i^2 \rightarrow \min$

Předpověď (predikce)

$$\hat{y}_i = \hat{b}_0 + \hat{b}_1 x_i$$

$\hat{y}_i$  – hodnoty na přímce

Metoda nejmenších čtverců v maticovém tvaru

$$\underbrace{\begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_N \end{bmatrix}}_Y = \underbrace{\begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \dots & \dots \\ 1 & x_N \end{bmatrix}}_X \underbrace{\begin{bmatrix} b_0 \\ b_1 \end{bmatrix}}_b + \underbrace{\begin{bmatrix} e_1 \\ e_2 \\ \dots \\ e_N \end{bmatrix}}_E, \quad Y = Xb + E$$

Odhad koeficientů:  $\underbrace{\begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \end{bmatrix}}_{\hat{b}} = (X'X)^{-1}X'Y$

# Vícenásobná lineární regrese – více nezávislých veličin $x$

$$y = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_nx_n$$

$x_1, x_2, \dots, x_n$  – vzájemně **nezávislé**

Příklad:



- $x_1$  – poloha plynového pedálu
- $x_2$  – rychlosť
- $x_3$  – sklon vozovky
- $y$  – spotreba paliva

Odhad regresních koeficientů – maticový tvar

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} = \underbrace{\begin{bmatrix} 1 & x_{1;1} & x_{2;1} & x_{3;1} \\ 1 & x_{1;2} & x_{2;2} & x_{3;2} \\ \dots & \dots & \dots & \dots \\ 1 & x_{1;N} & x_{2;N} & x_{3;N} \end{bmatrix}}_{Y} \underbrace{\begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \end{bmatrix}}_b + \underbrace{\begin{bmatrix} e_1 \\ e_2 \\ \dots \\ e_N \end{bmatrix}}_E$$

Predikce

$$\hat{Y} = X\hat{b}$$

# Nelineární regresní metody – polynomiální regrese

Polynomiální regrese – proložení dat křivkou

$$y = b_0 + b_1x + b_2x^2 + b_3x^3 + \dots + b_nx^n$$


Odhad regresních koeficientů – maticový tvar

$$\underbrace{\begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_N \end{bmatrix}}_Y = \underbrace{\begin{bmatrix} 1 & x_1 & x_1^2 & x_1^3 \\ 1 & x_2 & x_2^2 & x_2^3 \\ \dots & \dots & \dots & \dots \\ 1 & x_N & x_N^2 & x_N^3 \end{bmatrix}}_X \underbrace{\begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \end{bmatrix}}_b + \underbrace{\begin{bmatrix} e_1 \\ e_2 \\ \dots \\ e_N \end{bmatrix}}_E$$

Predikce

$$\hat{Y} = X\hat{b}$$

Příklad:  $x$  – čas chůze/běhu,  $y$  – vzdálenost



## Logistická regrese – klasifikace dat

$$\ln\left(\frac{P_1}{P_0}\right) = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$$

$P_1, P_0$  – pravděpodobnost tříd pro klasifikaci

**Příklad:** úsek silnice

$y \in \{0, 1\}$  – dopravní prostředek  
(auto, MHD)

$x_1$  – náklady na cestu (spojitá)

$x_2$  – příjem (spojitá)

$x_3$  – dostupnost cyklostezek (diskrétní)

$x_4$  – vzdálenost od zastávky (spojitá)

Odhad a predikce v inverzní formě

Metoda maximální věrohodnosti:

Věrohodnostní funkce

$$L_t(\theta) = \prod_{t=1}^N \frac{e^{y_t z_t}}{1+e^{z_t}}$$

$$\hat{b} = \arg \max_b \ln L_t(b)$$

Predikce třídy:

$$P(y=1) = \frac{e^{\hat{b}}}{1+e^{\hat{b}}}$$