

Poznámky k předmětu Aplikovaná statistika, 4. téma

4. Náhodné vektory

V praxi se nám může hodit postihnout více vlastností jednoho objektu najednou, např. výšku, váhu a pohlaví člověka; rychlost chemické reakce a množství katalyzátoru; či počet dnů přípravy na zkoušku, výsledek zkoušky a hodinová dotace zkoušeného předmětu. Takové situace lze modelovat **n -rozměrným náhodným vektorem**, což je uspořádaná n -tice náhodných veličin (X_1, \dots, X_n) .

V následujícím výkladu se (pro jednoduchost) omezíme na dvourozměrný náhodný vektor (X, Y) . Rozdělení pravděpodobnosti náhodného vektoru (X, Y) je jednoznačně určeno **sdrúženou distribuční funkcí**

$$F(x, y) = \mathbb{P}(X \leq x, Y \leq y), \quad x, y \in \mathbb{R},$$

kde

$$\{X \leq x, Y \leq y\} = \{X \leq x\} \cap \{Y \leq y\} = \{\omega \in \Omega; X(\omega) \leq x\} \cap \{\omega \in \Omega; Y(\omega) \leq y\}.$$

Vlastnosti sdrúžené distribuční funkce $F(x, y)$ jsou obdobné jako vlastnosti distribuční funkce jedné náhodné veličiny:

- $0 \leq F(x, y) \leq 1$,
- F je neklesající a zprava spojitá v každé z proměnných x, y ,
- $\lim_{x \rightarrow -\infty} F(x, y) = \lim_{y \rightarrow -\infty} F(x, y) = 0$ a $\lim_{x \rightarrow \infty} \lim_{y \rightarrow \infty} F(x, y) = 1$,
- $\lim_{x \rightarrow +\infty} F(x, y) = F_Y(y)$ a $\lim_{y \rightarrow +\infty} F(x, y) = F_X(x)$, kde $F_X(x)$ a $F_Y(y)$ jsou distribuční funkce náhodných veličin X a Y .

Poznámka 1. Rozdělení náhodných veličin X, Y nazýváme **marginální rozdělení**.

(D) Nechtě diskrétní náhodný vektor (X, Y) nabývá hodnot z množiny

$$M = \{(x_i, y_j) \in \mathbb{R}^2; i = 1, 2, \dots, j = 1, 2, \dots\}.$$

Pak jeho rozdělení lze popsat **sdrúženou pravděpodobnostní funkcí**

$$p(x, y) = \mathbb{P}(X = x, Y = y) = \begin{cases} p(x_i, y_j) & , (x, y) = (x_i, y_j) \in M, \\ 0 & , (x, y) \notin M. \end{cases}$$

VLASTNOSTI SDRUŽENÉ PRAVDĚPODOBNOSTNÍ FUNKCE

- $p(x_i, y_j) \geq 0, (x_i, y_j) \in M$,
- $\sum \sum_{(x_i, y_j) \in M} p(x_i, y_j) = 1$,
- $\mathbb{P}(X \leq x, Y \leq y) = \sum \sum_{x_i \leq x, y_j \leq y, (x_i, y_j) \in M} p(x_i, y_j)$.

Často je užitečné znát rozdělení jednotlivých složek náhodného vektoru, např. náhodnou veličinu popisující rychlost chemické reakce z úvodního příkladu. Máme-li sdruženou pravděpodobnostní funkci p náhodného vektoru (X, Y) , lze **marginální pravděpodobnostní funkci**

- $p_X(x_i)$ náhodné veličiny X určit jako

$$p_X(x_i) = \mathbb{P}(X = x_i) = \sum_{y_j: (x_i, y_j) \in M} p(x_i, y_j),$$

- $p_Y(y_j)$ náhodné veličiny Y spočítat jako

$$p_Y(y_j) = \mathbb{P}(Y = y_j) = \sum_{x_i: (x_i, y_j) \in M} p(x_i, y_j).$$

Příklad 1. Náhodný vektor (M, CH) popisuje výsledky maturity z matematiky a chemie studentů přijatých na VŠCHT v Praze. Rozdělení (M, CH) je zadáno sdruženou pravděpodobnostní funkcí $p(i, j) = \mathbb{P}(M = i, CH = j)$, $i, j = 1, \dots, 4$, v tabulce

CH	M			
	1	2	3	4
1	0,38	0,11	0,05	0,01
2	0,08	0,17	0,03	0,02
3	0,02	0,06	0,03	0,01
4	0	0,01	0,01	0,01

- Určete marginální pravděpodobnostní funkce známek z maturity z matematiky a chemie.
- Stanovte střední hodnotu a rozptyl M, CH a směrodatnou odchylku CH .
- Zjistěte pravděpodobnost, že náhodně vybraný student VŠCHT maturoval z matematiky i chemie
 - výborně,
 - ani výborně, ani dostatečně.

- (S) Rozdělení spojitého náhodného vektoru (X, Y) lze popsat **sdruženou hustotou pravděpodobnosti** $f(x, y)$, což je taková nezáporná funkce, že

$$F(x, y) \equiv \mathbb{P}(X \leq x, Y \leq y) = \int_{-\infty}^x \int_{-\infty}^y f(t, s) dt ds, \quad (x, y) \in \mathbb{R}^2.$$

VLASTNOSTI SDRUŽENÉ HUSTOTY PRAVDĚPODOBNOСТИ

- $f(x, y) \geq 0$, $(x, y) \in \mathbb{R}^2$,
- $\int_{\mathbb{R}} \int_{\mathbb{R}} f(x, y) dx dy = 1$,
- $\mathbb{P}(X \in [a, b], Y \in [c, d]) = \int_a^b \int_c^d f(x, y) dy dx$. Tuto pravděpodobnost lze geometricky interpretovat jako objem tělesa pod grafem hustoty zúžené na množinu $[a, b] \times [c, d]$.

Jako u diskrétního náhodného vektoru lze i v případě spojitého náhodného vektoru (X, Y) definovat **marginální rozdělení pravděpodobnosti**

- hustotu $f_X(x)$ náhodné veličiny X jako

$$f_X(x) = \int_{\mathbb{R}} f(x, y) dy, \quad x \in \mathbb{R},$$

- hustotu $f_Y(y)$ náhodné veličiny Y jako

$$f_Y(y) = \int_{\mathbb{R}} f(x, y) dx, \quad y \in \mathbb{R}.$$

Příklad 2. Náhodný vektor (X, Y) má sdružené rozdělení dané hustotou

$$f(x, y) = \begin{cases} \frac{1}{5}(3x + y) & , \quad x \in [0, 1], y \in [0, 2], \\ 0 & , \quad \text{jinde.} \end{cases}$$

- Stanovte marginální hustoty náhodných veličin X, Y .
- Určete střední hodnotu, rozptyl a směrodatnou odchylku náhodných veličin X, Y .
- Spočítejte $\mathbb{P}(X \in [0, 5; 1], Y \in [1, 2])$.

Nyní můžeme definovat nezávislost dvojice náhodných veličin.

Definice 1. Náhodné veličiny X, Y jsou (vzájemně) **nezávislé**, jestliže

(D) pro diskrétní náhodné veličiny platí

$$\forall (x_i, y_j) \in M \quad p(x_i, y_j) = p_X(x_i)p_Y(y_j),$$

(S) pro spojité náhodné veličiny platí

$$\forall (x, y) \in \mathbb{R}^2 \quad f(x, y) = f_X(x)f_Y(y).$$

Poznámka 2. (i) V případě nezávislosti se o sdruženém rozdělení náhodného vektoru (X, Y) říká, že je součinnové.

(ii) Pojem nezávislosti dvojice diskrétních náhodných veličin lze vidět ve světle nezávislosti náhodných jevů následovně:

$$P(\{X = x_i\} \cap \{Y = y_j\}) = \mathbb{P}(X = x_i)\mathbb{P}(Y = y_j), \quad (x_i, y_j) \in M.$$

Příklad 3. Jsou výsledky maturity z matematiky a chemie z Příkladu 1 nezávislé? Jsou náhodné veličiny X, Y z Příkladu 2 nezávislé?

Nejsou-li náhodné veličiny X, Y nezávislé, zkoumáme míru jejich závislosti.

MÍRY STATISTICKÉ LINEÁRNÍ ZÁVISLOSTI NÁHODNÝCH VELIČIN (např. výsledky maturity z matematiky vs. chemie)

Budte X, Y náhodné veličiny s vlastnostmi $\mathbb{E}X^2 < +\infty, \mathbb{E}Y^2 < +\infty$. Pak **kovariance** náhodných veličin X, Y je definována vztahem

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

(speciálně $\text{cov}(X, X) = \text{var}X$),

kde

- pro diskrétní náhodné veličiny je

$$\begin{aligned}\operatorname{cov}(X, Y) &= \sum_{x_i} \sum_{y_j} (x_i - \mathbb{E}X)(y_j - \mathbb{E}Y)p(x_i, y_j) \\ &= \sum_{x_i} \sum_{y_j} x_i y_j p(x_i, y_j) - \mathbb{E}X\mathbb{E}Y,\end{aligned}$$

- pro spojité náhodné veličiny je

$$\begin{aligned}\operatorname{cov}(X, Y) &= \int_{\mathbb{R}} \int_{\mathbb{R}} (x - \mathbb{E}X)(y - \mathbb{E}Y)f(x, y)dx dy \\ &= \int_{\mathbb{R}} \int_{\mathbb{R}} xyf(x, y)dx dy - \mathbb{E}X\mathbb{E}Y.\end{aligned}$$

Znormujeme-li vhodně kovarianci¹, dostaneme velmi užitečnou míru statistické lineární závislosti náhodných veličin X, Y , tzv. **korelační koeficient**

$$\rho(X, Y) := \frac{\operatorname{cov}(X, Y)}{\sqrt{\operatorname{var}X}\sqrt{\operatorname{var}Y}}$$

za předpokladu, že $0 < \operatorname{var}X < +\infty, 0 < \operatorname{var}Y < +\infty$.

VLASTNOSTI KORELAČNÍHO KOEFICIENTU

- $-1 \leq \rho(X, Y) \leq 1, \rho(X, X) = 1$,
- $\rho(X, Y) = 1$ právě tehdy, když $Y = kX + q$, kde $k > 0, q \in \mathbb{R}$,
- $\rho(X, Y) = -1$ právě tehdy, když $Y = kX + q$, kde $k < 0, q \in \mathbb{R}$,
- X, Y nezávislé, pak $\rho(X, Y) = 0$,
- $\rho(X, Y) = 0$ (tedy i $\operatorname{cov}(X, Y) = 0$), pak náhodné veličiny X, Y nazýváme **nekorelované** (tzn. X, Y nejsou statisticky lineárně závislé)
- s rostoucí $|\rho(X, Y)|$ roste i statistická lineární závislost X, Y .

Na závěr si uveďme některé důležité pojmy související s dvourozměrným náhodným vektorem (X, Y) :

- **střední hodnota**

$$\mathbb{E}(X, Y) = (\mathbb{E}X, \mathbb{E}Y),$$

- **kovarianční (varianční) matice**

$$\operatorname{var}(X, Y) = \begin{pmatrix} \operatorname{var}X & , & \operatorname{cov}(X, Y) \\ \operatorname{cov}(X, Y) & , & \operatorname{var}Y \end{pmatrix},$$

což je obdoba rozptylu jedné náhodné veličiny,

¹Laskavý čtenář si může povšimnout, že pro normované náhodné veličiny $X_N = \frac{X - \mathbb{E}X}{\sqrt{\operatorname{var}X}}$ a $Y_N = \frac{Y - \mathbb{E}Y}{\sqrt{\operatorname{var}Y}}$ platí

$$\rho(X_N, Y_N) = \operatorname{cov}(X_N, Y_N).$$

• **korelační matice**

$$\text{corr}(X, Y) = \begin{pmatrix} 1 & , & \rho(X, Y) \\ \rho(X, Y) & , & 1 \end{pmatrix},$$

• pro $a, b, c \in \mathbb{R}$ platí

$$\begin{aligned} \mathbb{E}(aX + bY + c) &= a\mathbb{E}X + b\mathbb{E}Y + c, \\ \text{var}(aX + bY + c) &= a^2\text{var}X + b^2\text{var}Y + 2ab\text{cov}(X, Y). \end{aligned}$$

Druhý vztah v případě nezávislosti X, Y přejde na tvar

$$\text{var}(aX + bY + c) = a^2\text{var}X + b^2\text{var}Y.$$

Příklad 4. Určete kovarianci, korelaci, kovarianční a korelační matici náhodného vektoru (X, Y) z Příkladu 1 a 2.

Cvičení k tomuto tématu

- (i) Mějme dvě náhodné veličiny X, Y , pro které platí $\mathbb{E}X = 1$, $\text{var}X = 36$, $\mathbb{E}Y = -4$, $\text{var}Y = 25$ a $\rho(X, Y) = 0,8$. Definujme náhodné veličiny

$$Z := 2X - 3Y - 3, \quad U := XY.$$

Určete $\mathbb{E}Z$, $\text{var}Z$, $\mathbb{E}U$.

- (ii) Mějme nezávislé náhodné veličiny X, Y s vlastnostmi $\mathbb{E}X = 2$, $\text{var}X = 16$, $\mathbb{E}Y = -1$ a $\text{var}Y = 4$. Definujme náhodné veličiny

$$U := -2X + 3, \quad V := 2X - 3Y + 2.$$

Stanovte $\mathbb{E}U$, $\sqrt{\text{var}U}$, $\rho(X, U)$, $\rho(X, Y)$, $\mathbb{E}V$, $\text{var}V$.

- (dcv1) Buď (X, Y) náhodný vektor, jehož rozdělení je dané hustotou

$$f(x, y) = \begin{cases} \frac{3}{2}xy^2 & , \quad x \in [0, 2], y \in [0, 1], \\ 0 & , \quad \text{jinde.} \end{cases}$$

Udělejte úkoly (a), (b) z Příkladu 2, vyšetřete nezávislost náhodných veličin X, Y , spočtete kovarianci, korelaci, kovarianční a korelační matici náhodného vektoru (X, Y) a dále určete

$$\mathbb{P}\left(1 < X < 2, \frac{1}{2} < Y < 1\right), \quad \mathbb{P}\left(0 < X < 1, 0 < Y < \frac{1}{2}\right).$$

- (dcv2) Rozdělení náhodného vektoru (X, Y) je dáno sdruženou pravděpodobnostní funkcí $p(x_i, y_j)$

Y	X		
	-1	0	1
0	$\frac{1}{18}$	$\frac{2}{9}$	$\frac{1}{18}$
1	$\frac{1}{9}$	$\frac{4}{9}$	$\frac{1}{9}$

Jsou náhodné veličiny X, Y nezávislé? Stanovte střední hodnotu náhodných veličin X, Y a dále určete $\text{var}(X, Y)$ a $\text{corr}(X, Y)$.