

Část III. – Náhodný vektor

Náhodný vektor

- **Náhodným vektorem** budeme rozumět sloupcový vektor složený z náhodných veličin

$$X = (X_1, X_2, \dots, X_n)^T.$$

- Pro jednoduchost se omezíme pouze na dvousložkový náhodný vektor.
- Např. u osobních automobilů můžeme sledovat dvě proměnné – výkon motoru a maximální rychlost.

Náhodný vektor

Průzkum spokojenosti cestujících s MHD	
Hodnocení ceny jízdného	Hodnocení kvality cestování
1	1
1	2
1	3
2	2
2	3
2	3
3	2
3	2
3	3
3	3
3	3
3	3
3	3
3	3
3	4
3	4
4	3
4	3
4	4
4	4
4	4

Legenda	
1	Velmi nespokojen
2	Nespokojen
3	Spokojen
4	Velmi spokojen

Ukázka diskrétního náhodného vektoru – při průzkumu spokojenosti cestujících se systémem MHD nás zajímá více údajů, např. viz tabulka.

Náhodný vektor

- **Sdružená (simultánní) distribuční funkce** náhodných veličin X a Y je definována vztahem:

$$F(x, y) = P(X < x; Y < y).$$

- **Vlastnosti sdružené distribuční funkce:**
 1. $0 \leq F(x, y) \leq 1.$
 2. $F(x, -\infty) = F(-\infty, y) = F(-\infty, -\infty) = 0; F(\infty, \infty) = 1.$

Náhodný vektor

3. Funkce $F(x,y)$ je neklesající v každé proměnné.
4. Funkce $F(x,y)$ je zleva spojitá v každé proměnné.
5. $P(a_1 \leq X < b_1; a_2 \leq Y < b_2) = F(b_1; b_2) - F(b_1; a_2) - F(a_1; b_2) + F(a_1; a_2)$.



Náhodný vektor

- Podle oboru hodnot, kterých mohou proměnné X a Y nabývat, rozeznáváme:
 - Náhodný vektor s diskrétním rozdělením.

$$F(x, y) = \sum_{x_i < x} \sum_{y_j < y} \underbrace{P(X = x_i; Y = y_j)}$$

Sdružená pravděpodobnostní funkce

- Náhodný vektor se spojitým rozdělením.

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y \underbrace{f(r, s) dr ds}$$

Sdružená hustota pravděpodobnosti

Náhodný vektor

- Pro sdruženou pravděpodobnostní funkci diskrétního náhodného vektoru dále platí:

$$1. \sum_i \sum_j P(X = x_i, Y = y_j) = 1.$$

$$2. 0 \leq P(X = x_i, Y = y_j) \leq 1.$$

Náhodný vektor

- Pro sdruženou hustotu pravděpodobnosti spojitého náhodného vektoru dále platí:

1. $f(x, y) \geq 0$.

2. $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$.

3. $P(a_1 \leq X < b_1; a_2 \leq Y < b_2) = \int_{a_1}^{b_1} \int_{a_2}^{b_2} f(x, y) dx dy$.

Náhodný vektor

- **Marginální distribuční funkcí** rozumíme distribuční funkci složky X nebo Y .

$$F_X(x) = P(X < x) = \lim_{y \rightarrow \infty} F(x, y)$$

$$F_Y(y) = P(Y < y) = \lim_{x \rightarrow \infty} F(x, y)$$

- Pro diskrétní náhodný vektor potom platí:

$$P_X(x) = \sum_{y_j} P(X = x; Y = y_j),$$

$$P_Y(y) = \sum_{x_i} P(X = x_i; Y = y).$$

**Marginální
pravděpodobnostní
funkce**

Náhodný vektor

- Pro spojitý náhodný vektor potom platí:

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy,$$

$$f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx.$$

**Marginální hustoty
pravděpodobnosti**

Náhodný vektor

- Nezávislost složek náhodného vektoru:
 - Složky X a Y náhodného vektoru jsou navzájem nezávislé, jsou-li nezávislé náhodné proměnné X a Y , tedy:

$$F(x, y) = F_X(x) \cdot F_Y(y).$$

- Náhodný vektor s diskrétním rozdělením:

$$P(X = x_i, Y = y_j) = P_X(X = x_i) \cdot P_Y(Y = y_j).$$

- Náhodný vektor se spojitým rozdělením:

$$f(x, y) = f_X(x) \cdot f_Y(y).$$

Náhodný vektor

- Sdružená pravděpodobnostní funkce diskrétního dvousložkové náhodného vektoru se často zobrazuje v podobě **korelační tabulky**.

Náhodný vektor

X / Y	y_1	y_2	$\dots\dots\dots$	y_n	$\sum_{j=1}^n P(X = x_i; Y = y_j)$
x_1	$P(X = x_1; Y = y_1)$	$P(X = x_1; Y = y_2)$		$P(X = x_1; Y = y_n)$	$P_x(x_1)$
x_2	$P(X = x_2; Y = y_1)$	$P(X = x_2; Y = y_2)$		$P(X = x_2; Y = y_n)$	$P_x(x_2)$
\vdots					\vdots
x_m	$P(X = x_m; Y = y_1)$	$P(X = x_m; Y = y_2)$		$P(X = x_m; Y = y_n)$	$P_x(x_m)$
$\sum_{i=1}^m P(X = x_i; Y = y_j)$	$P_Y(y_1)$	$P_Y(y_2)$	$\dots\dots\dots$	$P_Y(y_n)$	$\sum_{i=1}^m P_x(x_i) = \sum_{j=1}^n P_Y(y_j) = 1$

Náhodný vektor

- Podmíněné rozdělení pravděpodobnosti:
 - Pro náhodný vektor s diskrétním rozdělením je definována podmíněná pravděpodobnostní funkce ve tvaru:

$$P(X = x|Y = y) = \frac{P(X = x, Y = y)}{P_Y(Y = y)} \text{ pro } P_Y(Y = y) \neq 0,$$

$$P(Y = y|X = x) = \frac{P(X = x, Y = y)}{P_X(X = x)} \text{ pro } P_X(X = x) \neq 0.$$

Náhodný vektor

- Podmíněné rozdělení pravděpodobnosti:
 - Pro náhodný vektor se spojitým rozdělením je definována podmíněná hustota pravděpodobnosti:

$$f(x|y) = \frac{f(x, y)}{f_Y(y)} \text{ pro } f_Y(y) \neq 0,$$

$$f(y|x) = \frac{f(x, y)}{f_X(x)} \text{ pro } f_X(x) \neq 0.$$

Náhodný vektor

- Číselné charakteristiky náhodného vektoru:
 - **Smíšený počáteční (obecný) moment řádu k, n :**

$$\mu_{k,n} = E(X^k \cdot Y^n).$$

- Pro diskrétní náhodný vektor potom platí:

$$\mu_{k,n} = \sum_{i=1}^m \sum_{j=1}^n x_i^k \cdot y_j^n \cdot P(X = x_i; Y = y_j).$$

- Pro spojitý náhodný vektor platí:

$$\mu_{k,n} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^k \cdot y^n \cdot f(x, y) dx dy.$$

Náhodný vektor

– Smíšený centrální moment řádu k, n :

$$v_{k,n} = E\left[(X - EX)^k \cdot (Y - EY)^n\right].$$

– Pro diskrétní náhodný vektor potom platí:

$$v_{k,n} = \sum_{i=1}^m \sum_{j=1}^n (x_i - EX)^k \cdot (y_j - EY)^n \cdot P(X = x_i, Y = y_j).$$

– Pro spojitý náhodný vektor platí:

$$v_{k,n} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - EX)^k \cdot (y - EY)^n \cdot f(x, y) dx dy.$$

Náhodný vektor

- Marginální číselné charakteristiky složek náhodného vektoru:

– Střední hodnota proměnné X :

$$EX = \mu_{1,0} = \sum_{i=1}^m x_i \cdot P_X(x_i) \text{ – pro diskrétní proměnnou.}$$

$$EX = \mu_{1,0} = \int_{-\infty}^{\infty} x \cdot f_X(x) dx \text{ – pro spojitou proměnnou.}$$

- Obdobně bychom definovali vztahy pro proměnnou Y .

Náhodný vektor

– Rozptyl proměnné X :

$$DX = v_{2,0} = \sum_{i=1}^m (x_i - EX)^2 \cdot P_X(x_i) \quad \text{– pro diskrétní}$$

proměnnou.

$$DX = v_{2,0} = \int_{-\infty}^{\infty} (x - EX)^2 \cdot f_X(x) dx \quad \text{– pro spojitou}$$

proměnnou.

- Obdobně bychom definovali vztahy pro proměnnou Y .

Náhodný vektor

- Nejdůležitější číselnou charakteristikou náhodného vektoru je **kovariance** – smíšený centrální moment řádu 1,1:

$$\text{Cov}(X, Y) = v_{1,1} = E[(X - EX) \cdot (Y - EY)].$$

- Pro diskrétní náhodný vektor platí:

$$\text{Cov}(X, Y) = \sum_{i=1}^m \sum_{j=1}^n (x_i - EX) \cdot (y_j - EY) \cdot P(X = x_i, Y = y_j).$$

- Pro spojitý náhodný vektor platí:

$$\text{Cov}(X, Y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - EX) \cdot (y - EY) \cdot f(x, y) dx dy.$$

Náhodný vektor

- Vlastnosti kovariance náhodného vektoru:
 1. $Cov(X, Y) = E(X \cdot Y) - EX \cdot EY$,
 2. $Cov(X, X) = DX$, $Cov(Y, Y) = DY$,
 3. $Cov(X, Y) = Cov(Y, X)$,
 4. Jsou-li složky X a Y náhodného vektoru nezávislé, potom platí: $Cov(X, Y) = 0$.

Náhodný vektor

- Kovariance představuje nejjednodušší ukazatel souvislosti dvou náhodných veličin.
- Kladná hodnota kovariance znamená, že s rostoucí proměnnou X roste i proměnná Y .
- Záporná hodnota kovariance znamená, že s rostoucím X klesá Y .
- **Kovarianční matice** –
$$\begin{vmatrix} DX & Cov(X, Y) \\ Cov(X, Y) & DY \end{vmatrix}.$$

Náhodný vektor

- **Jednoduchý korelační koeficient** – vyjadřuje míru **lineární závislosti** (korelaci) mezi složkami X a Y náhodného vektoru, je definován:

$$\rho_{X,Y} = \frac{\text{Cov}(X,Y)}{\sqrt{DX \cdot DY}} \text{ pro } DX, DY \neq 0$$

Pro jednoduchý korelační koeficient platí:

1. $\rho_{X,Y} \in \langle -1;1 \rangle$.
2. $\rho_{X,Y} = \rho_{Y,X}$.

Náhodný vektor

- Pokud $\rho_{X,Y} = 0$, proměnné X a Y náhodného vektoru jsou nekorelované (lineárně nezávislé).
- Pokud $\rho_{X,Y} > 0$, proměnné X a Y náhodného vektoru jsou pozitivně korelované.
- Pokud $\rho_{X,Y} < 0$, proměnné X a Y náhodného vektoru jsou negativně korelované.

Náhodný vektor

- Je-li potřeba testovat vzájemnou nezávislost složek náhodného vektoru X a Y , kde X a Y jsou kategoriální proměnné, můžeme použít **χ^2 test nezávislosti v kombinační (kontingenční) tabulce**.
- Kategoriální proměnná je proměnná, kterou nemůžeme měřit, ale pouze zařadit do tříd (např. známka ve škole apod.). Necht' složka X nabývá k různých variant, složka Y m různých variant.
- Kombinační tabulka je v podstatě tabulka sdružených a marginálních četností.

Náhodný vektor

X / Y	y_1	y_2	\dots	y_m	Σ
x_1	n_{11}	n_{12}		n_{1m}	$n_{1\bullet}$
x_2	n_{21}	n_{22}		n_{2m}	$n_{2\bullet}$
\vdots					
x_k	n_{k1}	n_{k2}		n_{km}	$n_{k\bullet}$
Σ	$n_{\bullet 1}$	$n_{\bullet 2}$		$n_{\bullet m}$	n

Náhodný vektor

- Test je založen na porovnání empirických (pozorovaných) četností s četnostmi teoretickými.
- V případě nezávislosti platí:

$$n_{ij}^* = \left(\frac{n_{i\bullet}}{n} \cdot \frac{n_{\bullet j}}{n} \right) \cdot n = \frac{n_{i\bullet} \cdot n_{\bullet j}}{n},$$

kde n_{ij}^* je příslušná teoretická četnost.

Náhodný vektor

1. Volba nulové a alternativní hypotézy:

H_0 – Náhodné veličiny (znaky) X a Y v kombinační tabulce jsou nezávislé.

H_1 – Náhodné veličiny (složky náhodného vektoru) X a Y v kombinační tabulce jsou závislé.

Náhodný vektor

2. Volba testového kritéria a jeho nulového rozdělení (za předpokladu platnosti nulové hypotézy):

$$K = \sum_{i=1}^k \sum_{j=1}^m \frac{(n_{ij} - n_{ij}^*)^2}{n_{ij}^*} \rightarrow \chi_{(k-1) \cdot (m-1)}^2 \cdot$$

- S rostoucí hodnotou testové statistiky K roste rozpor naměřených dat s nulovou hypotézou.

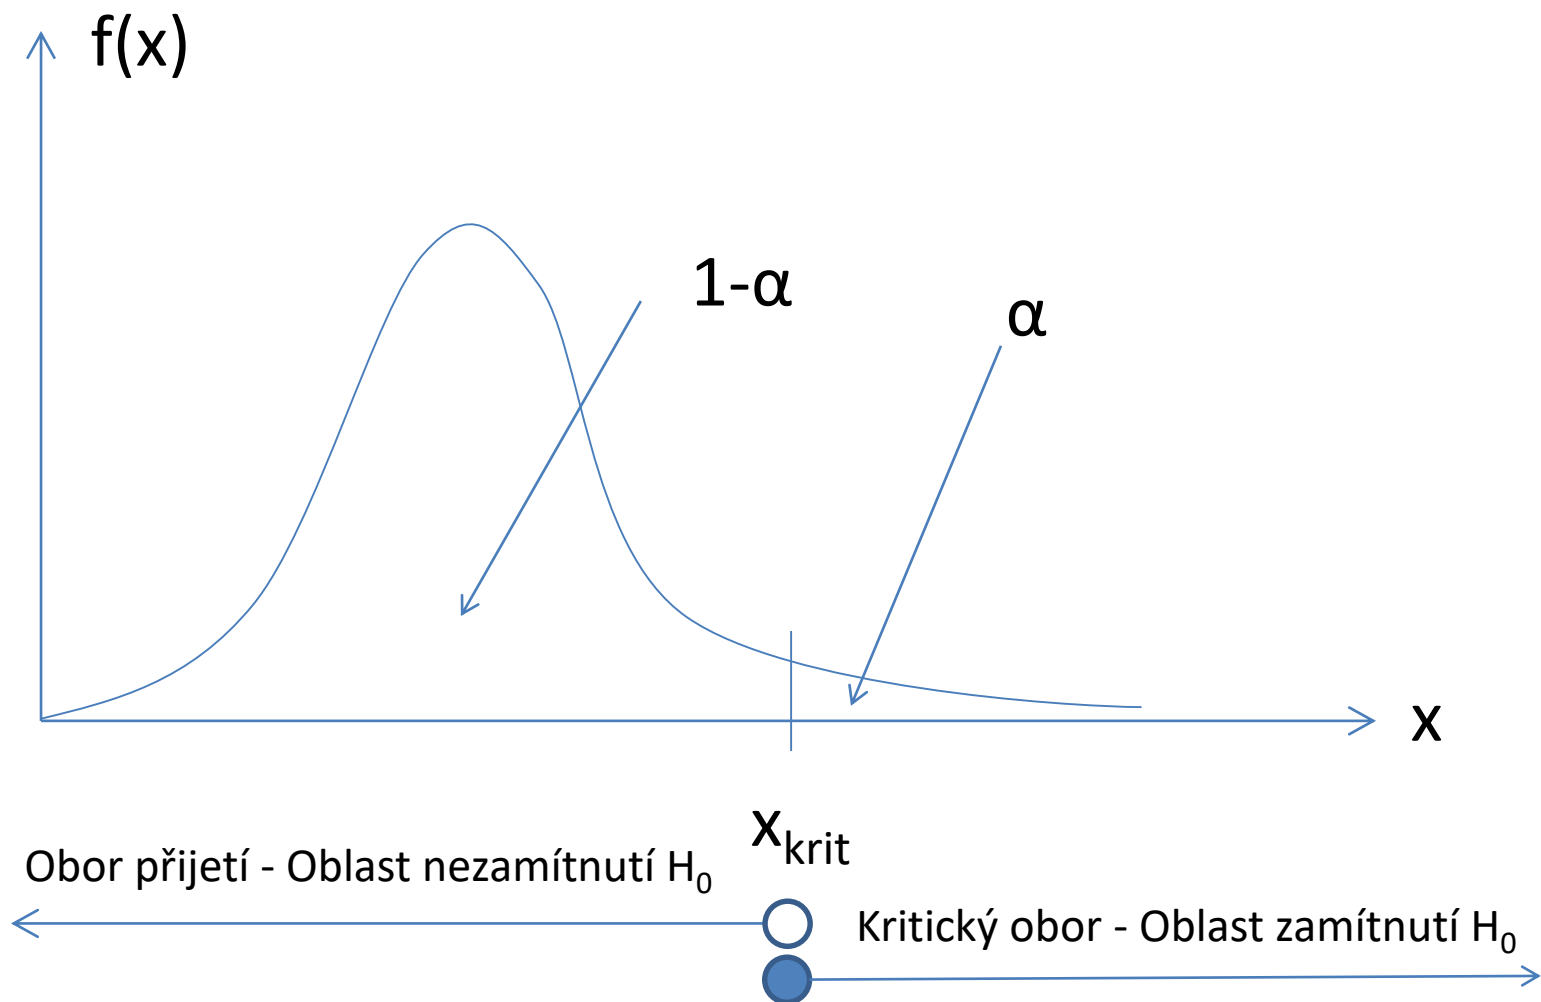
Náhodný vektor

- Předpoklad testu:
 - Žádná teoretická četnost nesmí být menší než 2
 - Alespoň 80% teoretických četností musí být větší než 5.

3. Sestavení oboru přijetí a kritického oboru:

$$x_{krit} = \chi_{(1-\alpha);(k-1)\cdot(m-1)}^2 = CHIINV[\alpha; (k-1)\cdot(m-1)].$$

Náhodný vektor



Náhodný vektor

4. Výpočet pozorované hodnoty testové statistiky x_{obs} (za předpokladu platnosti nulové hypotézy).
5. Formulace závěru testu:
 - $x_{obs} < x_{krit}$ – nezamítáme nulovou hypotézu o nezávislosti náhodných proměnných.
 - $x_{obs} \geq x_{krit}$ – zamítáme nulovou hypotézu ve prospěch alternativní hypotézy.

Náhodný vektor

- V případě, že není splněn předpoklad výše uvedeného testu, lze použít tzv. Yatesovu korekci, která snižuje hodnotu testového kritéria, je tedy obtížnější zamítnout nulovou hypotézu. Testová statistika je v tomto případě ve tvaru:

$$K_{Yates} = \sum_{i=1}^k \sum_{j=1}^m \frac{(n_{ij} - n_{ij}^* - 0,5)^2}{n_{ij}^*} \rightarrow \chi_{(k-1) \cdot (m-1)}^2$$

Náhodný vektor

- Uvedený test pouze slouží k rozhodnutí o tom, zda jsou znaky X a Y závislé či nezávislé, ale již nestanovuje, o jak silnou závislost se jedná.
- Pro stanovení síly závislosti zavádíme různé koeficienty, jež jsou obdobou korelačního koeficientu.

Náhodný vektor

- Zavádíme koeficient kontingence definovaný:

$$CC = \sqrt{\frac{K}{K+n}},$$

kde K je hodnota testového kritéria a n rozsah výběru. Pro čtvercovou kombinační tabulku ($k=m$) nabývá hodnot $\langle 0;1 \rangle$.

Náhodný vektor

- Pro obdélníkovou kombinační tabulku je ovšem maximální hodnota koeficientu kontingence rovna:

$$CC_{\max} = \sqrt{\frac{\min(k, m) - 1}{\min(k, m)}},$$

proto zavádíme korigovaný koeficient kontingence ve tvaru:

$$CC_{cor} = \frac{CC}{CC_{\max}},$$

který je už v intervalu $\langle 0;1 \rangle$.

Náhodný vektor

- Jako další míra síly závislosti se používá Cramerův koeficient definovaný ve tvaru:

$$V = \sqrt{\frac{K}{n \cdot [\min(k, m) - 1]}}$$

jež nabývá hodnot z intervalu $\langle 0;1 \rangle$.