

# ČASOVÉ ŘADY

VÍTĚZSLAV VESELÝ

## PODPORA VÝUKY NA POČÍTAČOVÉ SÍTI

<http://www.math.muni.cz/~vesely>

Algoritmy pro časové řady v MATLABu:

`d = vesely('cas_rady')` ... připojení a výpis obsahu knihovny

`d` ... výstup=úplná cesta do adresáře knihovny.

### 1. ÚVOD

#### 1.1. Ukázky časových řad.

**Časová řada** = soubor pozorování nějaké veličiny  $\{x_t, t \in T\}$ , kde  $t$  je zpravidla čas a  $T \subseteq \mathbb{R}$ .

**Obr. 1.1:**

Měření proudu procházejícího odporem  $r$  v obvodu se střídavým napětím,

$$v(t) = a \cos(vt + \Theta), \text{ tj. } x_t = \frac{a}{r} \cos(vt + \Theta).$$

**Obr. 1.2 (MATLAB: `getdata('brockwell.dat/uspop.dat')`):**

Růst populace v USA v letech 1790–1980 sledovaný v desetiletých intervalech.

**Obr. 1.3 (MATLAB: `getdata('brockwell.dat/strikes.dat')`):**

Počet stávek v USA v letech 1951–1980.

**Obr. 1.4:** Výsledky Národní a Americké ligy v baseballu v letech 1933–1980.

**Obr. 1.5 (MATLAB: `getdata('brockwell.dat/sunspots.dat')`):**

Počty slunečních skvrn v letech 1770–1869.

**Obr. 1.6 (MATLAB: `getdata('brockwell.dat/deaths.dat')`):**

Počet úmrtí při nehodách v USA v letech 1973–1978.

#### 1.2. Oblasti uplatnění metod analýzy časových řad.

**fyzika, technika:**

- seismický záznam v geofyzice.
- řada nejvyšších denních teplot v meteorologii.
- průběh výstupního signálu určitého elektrického přístroje.
- tenzometrické měření povrchového napětí v provozu namáhané strojní součástky.

**biologie, ekologie:** sledování různých parametrů znečištění ovzduší.

**medicína:** záznam EKG nebo EEG.

**společenské vědy:** změny v počtu a složení obyvatelstva.

**sociologie:** vývoj rozvodovosti.

**EKONOMIE:** Teorie časových řad = jedna z nejdůležitějších kvantitativních metod pro analýzu ekonomických dat, např.:

- analýza poptávky po určitém výrobku
- analýza objemu zemědělské produkce
- analýza počtu cestujících v letecké dopravě
- analýza vývoje kurzu akcií na burze

### 1.3. Cíl analýzy.

#### Porozumění mechanismu, jímž se generují sledované údaje.

Znalost modelu tohoto mechanismu  $\Rightarrow$  znalost algoritmu, jímž můžeme chování tohoto mechanismu simulovat na počítači  $\Rightarrow$  schopnost popsat s jistotou přesností jeho chování:

- mezi časovými okamžiky měření (**interpolace**)
- v budoucnosti (**extrapolace, prognóza**)
- s cílem řídit a optimalizovat činnost určitého systému vhodnou volbou vstupních a počátečních podmínek (**regulace**), např. regulace složitých technologických procesů.

### 1.4. Některé specifické problémy analýzy časových řad.

#### a) Volba okamžiků pozorování:

- jsou přímo **diskrétní svou povahou**, např. úroda obilí za jednotlivé roky.
- vznikají **diskretizací spojité časové řady**, např. teplota v danou denní dobu na daném místě.
- vznikají **akumulací (agregací)** hodnot za určité období, např. denní množství srážek, roční výroba závodu. Místo akumulace se někdy provádí průměrování.

Je-li dána možnost volby, je třeba jí věnovat pozornost:

- **málo bodů**  $\Rightarrow$  unikne charakteristický rys řady.
- **mnoho bodů**  $\Rightarrow$  zvýší se výpočetní náročnost.
- **ekvidistantní diskretizace** zpravidla usnadní numerické zpracování, ale neumožňuje adaptivně měnit hustotu diskretizace v závislosti na lokálním charakteru řady.
- **při agregaci** se mohou porušit vlastnosti původní řady.

#### b) Problémy s kalendářem:

- různá délka kalendářních měsíců.
- 4 nebo 5 víkendů v měsíci.
- různý počet pracovních dnů v měsíci.
- pohyblivé svátky: např. svátek na začátku měsíce sníží prodej potravin za tento měsíc, ale zvýší jej za předchozí v důsledku efektu předzásobení.  
Příklad 'očistění' časové řady např. od proměnlivé délky měsíce:  
zavedeme 'standardní' měsíc o délce 30 dnů a pak údaj třebas o produkci za leden přenásobíme korekčním faktorem  $\frac{30}{31}$ .

#### c) Problémy s nekompatibilitou jednotlivých měření:

Příklad: hodnota nějakého ukazatele se jeden rok týká např. 85 podniků, další rok jen 82 apod.

#### d) Problémy s délkou časových řad:

- zvětšení počtu měření (např. půlením časových intervalů mezi body) nemusí vždy znamenat zvětšení množství informace.
- někdy se mohou objevit protichůdné tendence: metoda zpracování vyžaduje delší řadu, ale na druhé straně řada vzniklá dlouhodobým sledováním může měnit charakteristiky svého modelu v čase  $\Rightarrow$  obtíže s konstrukcí modelu.

### 1.5. Označení a základy matematické statistiky.

$s := v$ , resp.  $v := s \dots$  označení výrazu  $v$  symbolem  $s$ .

#### Číselné obory:

$\mathbb{N} \dots$  množina všech přirozených čísel

$\mathbb{N}_0 = \mathbb{N} \cup \{0\} \dots$  množina všech nezáporných celých čísel

$\mathbb{Z} \dots$  množina všech celých čísel

$\mathbb{R} \dots$  množina všech reálných čísel

$\mathbb{R}^+ \dots$  množina všech nezáporných reálných čísel

$\mathbb{C} \dots$  množina všech komplexních čísel

$(\cdot)^+ : \mathbb{R} \rightarrow \mathbb{R}^+ \dots$  zobrazení definované předpisem  $(x)^+ = \max(0, x)$

$(a, b) \dots$  otevřený interval

$[a, b]$  ... uzavřený interval

$$J(a, b) = \{x \mid \min(a, b) < x < \max(a, b)\}$$

$$J[a, b] = \{x \mid \min(a, b) \leq x \leq \max(a, b)\}.$$

**Vektory:**

$\mathbf{x} = (x_1, \dots, x_n)^T \in \mathbb{C}^n$  ... zpravidla sloupcové

$$\mathbf{x} + \mathbf{h} = (x_1 + h_1, \dots, x_n + h_n)^T, \quad \mathbf{h} \in \mathbb{C}$$

$$\mathbf{t} = (t_1, \dots, t_k)^T \in \mathbb{N}^k, \quad t_i \in \{1, \dots, n\} \quad \text{pro } i = 1, \dots, k, \quad k \leq n \quad \Rightarrow \quad \mathbf{x}_{\mathbf{t}} := (x_{t_1}, \dots, x_{t_k})^T \in \mathbb{C}^k$$

$$1 \leq i \leq n \quad \Rightarrow \quad \mathbf{x}(i) = (x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n)^T$$

$$f(\mathbf{x}) = f(x_1, \dots, x_n), \quad d\mathbf{x} = dx_1 \dots dx_n$$

$\mathbf{0}, \mathbf{0}_{n \times 1}$  ... nulový sloupcový vektor délky  $n$ .

**Matice:**

$A, A_{m \times n} = [a_{ij}] = [A(i, j)]$  ... matice rozměru  $m \times n$

$\mathcal{R}(A) = \{\mathbf{y} \mid \mathbf{y} = A\mathbf{x}\}$  ... obor hodnot operátoru  $A$

$\mathcal{N}(A) = \{\mathbf{x} \mid A\mathbf{x} = \mathbf{0}\}$  ... jádro operátoru  $A$

$A^T = [a_{ji}]$  ... transponovaná matice

$A^* = [\bar{a}_{ji}]$  ... hermitovskysky sdružená matice

$I, I_n = I_{n \times n} = [\delta_{ij}]$  ... jednotková matice řádu  $n$

$|A|$  ... determinant čtvercové matice  $A$

$\mathbf{0}, \mathbf{0}_{m \times n} = [\mathbf{0}]$  ... nulová matice rozměru  $m \times n$

$$\text{diag}(\mathbf{x}) = \begin{bmatrix} x_1 & 0 & \dots & 0 \\ 0 & x_2 & \dots & 0 \\ & & \ddots & \\ 0 & 0 & \dots & x_n \end{bmatrix} \quad \dots \text{diagonální matice}$$

$A(i, :) = (a_{i1}, \dots, a_{in}) =: r_i$  ...  $i$ -tý řádek matice  $A$  ve stylu MATLAB

$A(:, j) = (a_{1j}, \dots, a_{mj})^T =: s_j$  ...  $j$ -tý sloupec matice  $A$  ve stylu MATLAB

$A = [r_1; \dots; r_m] = [s_1, \dots, s_n]$  ... blokový zápis matice  $A$  ve stylu MATLAB

$A > 0$  (resp.  $A \geq 0$ ) ... pozitivně (semi)definitní matice.

**Norma a skalární součin vektorů:**

$\langle \mathbf{x}, \mathbf{y} \rangle = \sum_{i=1}^n x_i \bar{y}_i = \mathbf{y}^* \mathbf{x}$ , speciálně:

$\mathbf{y} = A^* \mathbf{x} \Leftrightarrow y_i = \langle \mathbf{x}, A(:, i) \rangle$  pro  $i = 1, 2, \dots, n$

$\|\mathbf{x}\| = \sqrt{\langle \mathbf{x}, \mathbf{x} \rangle} = \sqrt{\sum_{i=1}^n |x_i|^2}$  ... Euklidovská norma.

**Schwarzova nerovnost:**

$|\langle \mathbf{x}, \mathbf{y} \rangle| \leq \|\mathbf{x}\| \|\mathbf{y}\|$ , kde rovnost nastane právě když vektory  $\mathbf{x}$  a  $\mathbf{y}$  jsou lineárně závislé.

**Pravděpodobnostní prostor  $(\Omega, \mathcal{A}, P)$ :**

$\Omega$  ... základní prostor elementárních jevů

$\mathcal{A} \subseteq 2^\Omega$  ...  $\sigma$ -algebra náhodných jevů

$P$  ... pravděpodobnostní míra na  $\mathcal{A}$

Všechny náhodné veličiny budeme vždy uvažovat nad týmž pravděpodobnostním prostorem. Komplexní náhodnou veličinou budeme rozumět veličinu  $X = X_r + iX_i$ , kde  $X_r$  a  $X_i$  jsou reálné náhodné veličiny představující po řadě reálnou a imaginární část  $X$

$\mathbb{X} = (X_1, \dots, X_n)^T$  ... (komplexní) náhodný vektor tvořený (komplexními) náhod. veličinami  $X_i$ .

**Střední hodnota:**

$\mu = \mu_X = EX$  ... střední hodnota náhodné veličiny  $X$

$\boldsymbol{\mu} = \boldsymbol{\mu}_{\mathbb{X}} = E\mathbb{X} = (EX_1, \dots, EX_n)^T$  ... střední hodnota náhodného vektoru  $\mathbb{X}$ .

**Rozptyl a kovariance náhodných veličin:**

$\sigma^2 = \sigma_X^2 = \text{var}X = E|X - EX|^2 = E|X|^2 - |EX|^2 \geq 0$  ... rozptyl  $X$

$\sigma_{XY} = \text{cov}(X, Y) = E(X - EX)\overline{(Y - EY)} = EX\bar{Y} - (EX)(\overline{EY})$  ... kovariance  $X$  a  $Y$

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

$\text{cov}(\sum_r X_r, \sum_s Y_s) = \sum_r \sum_s \text{cov}(X_r, Y_s)$  a odtud speciálně:

$\text{var}(X + Y) = \text{var}X + \text{cov}(X, Y) + \text{cov}(Y, X) + \text{var}Y = \text{var}X + 2\text{Re} \text{cov}(X, Y) + \text{var}Y$ .

**Varianční a kovarianční matice náhodných vektorů:**

$\Sigma_{\mathbb{X}} = \text{var}\mathbb{X} = [\text{cov}(X_i, X_j)] = E(\mathbb{X} - E\mathbb{X})(\mathbb{X} - E\mathbb{X})^* = E\mathbb{X}\mathbb{X}^* - (E\mathbb{X})(E\mathbb{X})^*$  ... varianční matice  $\mathbb{X}$

$\Sigma_{\mathbb{X}\mathbb{Y}} = \text{cov}(\mathbb{X}, \mathbb{Y}) = [\text{cov}(X_i, Y_j)] = E(\mathbb{X} - E\mathbb{X})(\mathbb{Y} - E\mathbb{Y})^* = E\mathbb{X}\mathbb{Y}^* - (E\mathbb{X})(E\mathbb{Y})^*$  ...

... kovarianční matice  $\mathbb{X}$  a  $\mathbb{Y}$

$\text{cov}(\mathbb{X}, \mathbb{X}) = \text{var}\mathbb{X}$ ,  $\text{cov}(\mathbb{Y}, \mathbb{X}) = \text{cov}(\mathbb{X}, \mathbb{Y})^* \Rightarrow \text{var}\mathbb{X} = (\text{var}\mathbb{X})^* \dots$   
 $\dots$  **varianční matice  $\mathbb{X}$  je hermitovská.**

Pro konstantní komplexní vektory  $\mathbf{a}$  a  $\mathbf{c}$  a matice  $B$  a  $D$  odpovídajících rozměrů platí:

$$\text{cov}(\mathbf{a} + B\mathbb{X}, \mathbf{c} + D\mathbb{Y}) = \text{cov}(B\mathbb{X}, D\mathbb{Y}) = B \text{cov}(\mathbb{X}, \mathbb{Y}) D^*.$$

$$\Downarrow \mathbb{X} = \mathbb{Y}$$

$$\text{var}(\mathbf{a} + B\mathbb{X}) = \text{cov}(\mathbf{a} + B\mathbb{X}, \mathbf{a} + B\mathbb{X}) = \text{cov}(B\mathbb{X}, B\mathbb{X}) = B \text{var}(\mathbb{X}) B^*.$$

$$\Downarrow \mathbf{b}^* = B$$

$0 \leq \text{var}(\mathbf{b}^* \mathbb{X}) = \mathbf{b}^* \text{var}\mathbb{X} \mathbf{b} \Rightarrow \text{var}\mathbb{X} \geq 0 \dots$  **varianční matice je pozitivně semidefinitní.**

$\Sigma_{\mathbb{X}}$  je tedy celkem hermitovská a pozitivně semidefinitní a má proto reálná nezáporná vlastní čísla  $\lambda_i$ .

Zřejmě existuje matice  $\Sigma_{\mathbb{X}}^{\frac{1}{2}}$ , jejíž vlastní čísla jsou  $\lambda_i^{\frac{1}{2}}$  a přitom platí:  $\Sigma_{\mathbb{X}} = \Sigma_{\mathbb{X}}^{\frac{1}{2}} \Sigma_{\mathbb{X}}^{\frac{1}{2}}$ .

Dále platí

$\text{cov}(\sum_r \mathbb{X}_r, \sum_s \mathbb{Y}_s) = \sum_r \sum_s \text{cov}(\mathbb{X}_r, \mathbb{Y}_s)$  a odtud speciálně:

$$\text{var}(\mathbb{X} + \mathbb{Y}) = \text{var}\mathbb{X} + \text{cov}(\mathbb{X}, \mathbb{Y}) + \text{cov}(\mathbb{Y}, \mathbb{X}) + \text{var}\mathbb{Y} = \text{var}\mathbb{X} + 2\text{Re cov}(\mathbb{X}, \mathbb{Y}) + \text{var}\mathbb{Y}.$$

## 1.6. Normální rozdělení a rozdělení z něj odvozená.

### 1. Normální rozdělení:

$X \sim N(\mu, \sigma^2)$ ,  $\mu = EX$ ,  $\sigma^2 = \text{var}X \dots$

$\dots$  reálná náhodná veličina s **normálním (gaussovským) rozdělením;**

$f(x) = (\sqrt{2\pi}\sigma)^{-1} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \dots$  **hustota** náhodné veličiny  $X$ ;

$\Phi(t) := Ee^{itX} = e^{it\mu - \frac{1}{2}\sigma^2 t^2} \dots$  **charakteristická funkce** náhodné veličiny  $X$ ;

$U \sim N(0, 1) \dots$  **standardizované normální rozdělení** náhodné veličiny  $U$ ;

$u_\alpha = F^{-1}(\alpha) \dots$   $\alpha$ -kvantil pro  $U$ , kde  $F(x) = \int_{-\infty}^x f(t) dt$  značí distribuční funkci  $U$ ;

$\mathbb{X} \sim N_n(\boldsymbol{\mu}, V)$ ,  $\boldsymbol{\mu} = E\mathbb{X}$ ,  $V = \text{var}\mathbb{X} \dots$

$\dots$  reálný náhodný vektor s  **$n$ -rozměrným normálním rozdělením;**

$f(\mathbf{x}) = (\sqrt{(2\pi)^n |V|})^{-1} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T V^{-1}(\mathbf{x}-\boldsymbol{\mu})} \dots$   **$n$ -rozměrná hustota** náhodného vektoru  $\mathbb{X}$ ;

$\Phi_n(\mathbf{t}) := Ee^{it^T \mathbb{X}} = e^{it^T \boldsymbol{\mu} - \frac{1}{2} \mathbf{t}^T V \mathbf{t}} \dots$  **charakteristická funkce** náhodného vektoru  $\mathbb{X}$ ;

$\mathbb{U} \sim N_n(\mathbf{0}, I_n) \dots$  **standardizované normální rozdělení** náhodného vektoru  $\mathbb{U}$ .

Platí

$$X \sim N(\mu, \sigma^2) \Rightarrow a + bX \sim N(a + b\mu, b^2\sigma^2) \text{ pro } a, b \in \mathbb{R};$$

$$\mathbb{X} \sim N_n(\boldsymbol{\mu}, V) \Rightarrow \mathbf{a} + B\mathbb{X} \sim N_m(\mathbf{a} + B\boldsymbol{\mu}, BV B^T) \text{ pro } \mathbf{a} \in \mathbb{R}^m \text{ a matici } B = B_{m \times n} \text{ nad } \mathbb{R}.$$

### 2. Rozdělení $\chi^2(n)$ :

Nechť  $U_i \sim N(0, 1)$  pro  $i = 1, \dots, n$  jsou stochasticky nezávislé, pak náhodná veličina

$C = \sum_{i=1}^n U_i^2 \sim \chi^2(n)$  má **Pearsonovo "chí kvadrát" rozdělení o  $n$  stupních volnosti;**

$\chi_\alpha(n) \dots$   $\alpha$ -kvantil pro  $C$ .

Platí

$$C_i \sim \chi^2(n_i) \text{ pro } i = 1, \dots, m \text{ stochasticky nezávislé} \Rightarrow C = \sum_{i=1}^m C_i \sim \chi^2(n_1 + n_2 + \dots + n_m).$$

### 3. Studentovo $t$ rozdělení:

Nechť  $U \sim N(0, 1)$  a  $C \sim \chi^2(k)$  jsou stochasticky nezávislé, pak náhodná veličina

$T = \frac{U}{\sqrt{C/k}} \sim t(k)$  má **Studentovo  $t$  rozdělení o  $k$  stupních volnosti;**

$t_\alpha(k) \dots$   $\alpha$ -kvantil pro  $T$ .

### 4. Fisher-Snedecorovo $F$ rozdělení:

Nechť  $C_1 \sim \chi^2(n_1)$  a  $C_2 \sim \chi^2(n_2)$  jsou stochasticky nezávislé, pak náhodná veličina

$F = \frac{C_1/n_1}{C_2/n_2} \sim F(n_1, n_2)$  má **Fisher-Snedecorovo  $F$  rozdělení s  $n_1$  a  $n_2$  stupni volnosti;**

$F_\alpha(n_1, n_2) \dots$   $\alpha$ -kvantil pro  $F$ .

1.7. **Prostor**  $L_2(\Omega, \mathcal{A}, P)$ .

$L_2(\Omega, \mathcal{A}, P)$  definujeme jako množinu všech (komplexních) náhodných veličin nad týmž pravděpodobnostním prostorem  $(\Omega, \mathcal{A}, P)$ , které mají konečné druhé momenty (resp. rozptyly - viz dále 1.11), tj.  $L_2(\Omega, \mathcal{A}, P) := \{X \mid X \text{ náhodná veličina nad } (\Omega, \mathcal{A}, P), E|X|^2 < \infty\}$ .

Poznamenejme, že do tohoto prostoru zahrnujeme také všechny konstanty z  $\mathbb{C}$ , které považujeme za náhodné veličiny s nulovým rozptylem.

**Věta 1.8.**  $L_2(\Omega, \mathcal{A}, P)$  je **Hilbertův prostor** se skalárním součinem  $\langle X, Y \rangle = EX\bar{Y}$  a normou  $\|X\|_2 = \sqrt{\langle X, X \rangle} = \sqrt{E|X|^2}$ .

*Důkaz.*  $L_2(\Omega, \mathcal{A}, P)$  je obdobou funkcionálního prostoru  $L_2(\mathcal{J})$  tvořeného funkcemi absolutně integrovatelnými v kvadrátu na intervalu  $\mathcal{J} \subseteq \mathbb{R}$ . Totiž  $E|X|^2 = \int_{\Omega} |X(\omega)|^2 dP(\omega)$ , takže namísto s Lebesgueovým integrálem pracujeme s obecnějším pojetím integrálu, kde Lebesgueova míra je nahrazena pravděpodobnostní mírou  $P$ :

- **Skalární součin**  $\langle X, Y \rangle$  **existuje a je konečný** pro každé  $X, Y \in L_2(\Omega, \mathcal{A}, P)$ , jak snadno nahlédneme z nerovnosti

$$4|X\bar{Y}| = (|X| + |\bar{Y}|)^2 - (|X| - |\bar{Y}|)^2 \leq (|X| + |\bar{Y}|)^2 + (|X| - |\bar{Y}|)^2 = 2(|X|^2 + |\bar{Y}|^2),$$

odkud užitím  $|\bar{Y}| = |Y|$  dostáváme

$$|X\bar{Y}| \leq \frac{1}{2}(|X|^2 + |Y|^2),$$

takže

$$|EX\bar{Y}| \leq \int_{\Omega} |X(\omega)\bar{Y}(\omega)| dP(\omega) \leq \frac{1}{2} \left[ \int_{\Omega} |X(\omega)|^2 dP(\omega) + \int_{\Omega} |Y(\omega)|^2 dP(\omega) \right] < \infty.$$

- $L_2(\Omega, \mathcal{A}, P)$  je **vektorovým prostorem**. Je uzavřený na násobení skaláry  $c \in \mathbb{C}$ , neboť  $E|cX|^2 = |c|^2 E|X|^2 < \infty$ . Uzavřenost vzhledem ke sčítání plyne z:

$$|X + Y|^2 \leq (|X| + |Y|)^2 = |X|^2 + 2|XY| + |Y|^2 \Rightarrow E|X + Y|^2 \leq E|X|^2 + 2E|XY| + E|Y|^2 < \infty.$$

- **Ověření, že**  $L_2(\Omega, \mathcal{A}, P)$  **je úplný, neboli Hilbertův prostor**, je složitější, ale provádí se opět zcela analogicky jako v případě funkcionálního prostoru  $L_2(\mathcal{J})$ . Podrobnosti lze nalézt například v monografii [1, §2.10].

□

**Důsledek 1.9** (Schwarzova nerovnost).

$$|EXY|, |EX\bar{Y}| \leq \|X\|_2 \|Y\|_2 = \sqrt{E|X|^2} \sqrt{E|Y|^2}, \quad X, Y \in L_2(\Omega, \mathcal{A}, P).$$

**Důsledek 1.10.**  $X \in L_2(\Omega, \mathcal{A}, P) \Rightarrow EX$  *existuje*.

*Důkaz.*

$$|EX| = |E(1.X)| \leq \underbrace{\sqrt{E|1|^2}}_1 \sqrt{E|X|^2} = \sqrt{E|X|^2} < \infty.$$

□

**Důsledek 1.11.**

$$X, Y \in L_2(\Omega, \mathcal{A}, P) \Rightarrow X - EX, Y - EY \in L_2(\Omega, \mathcal{A}, P)$$

a

$$\langle X - EX, Y - EY \rangle = E(X - EX)\overline{(Y - EY)} = \text{cov}(X, Y)$$

*existuje a splňuje Schwarzovu nerovnost*

$$|\text{cov}(X, Y)| \leq \sqrt{E|X - EX|^2} \sqrt{E|Y - EY|^2} = \sigma_X \sigma_Y.$$

**Důsledek 1.12.**

$$\rho(X, Y) = \begin{cases} \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} & \text{pro } \sigma_X \sigma_Y \neq 0 \\ 0 & \text{pro } \sigma_X \sigma_Y = 0 \end{cases}$$

je tzv. **korelační koeficient náhodných veličin**  $X$  a  $Y$ , pro něžž platí  $|\rho(X, Y)| \leq 1$  a speciálně  $-1 \leq \rho(X, Y) \leq 1$  v případě reálných náhodných veličin  $X$  a  $Y$ .

*Poznámka* . Náhodné veličiny  $X, Y \in L_2(\Omega, \mathcal{A}, P)$  se nazývají **nekorelované**, jestliže  $\rho(X, Y) = 0$ . Vzhledem k 1.11 je nekorelovanost ekvivalentní s  $\text{cov}(X, Y) = 0$ , tj. s **ortogonalitou** centrovaných veličin  $X - EX$  a  $Y - EY$  v  $L_2(\Omega, \mathcal{A}, P)$ .

$\rho(\mathbb{X}, \mathbb{Y}) = [\rho(X_i, Y_j)]_{i,j}$  je tzv. **vzájemná korelační matice náhodných vektorů  $\mathbb{X}$  a  $\mathbb{Y}$** .

$\rho(\mathbb{X}, \mathbb{X}) = [\rho(X_i, X_j)]_{i,j}$  je tzv. **korelační matice náhodného vektoru  $\mathbb{X}$** .

**POZOR!** Nekorelovanost indikuje neexistenci **stochastické závislosti pouze lineárního typu**.

Tedy platí

$X, Y$  stochasticky nezávislé  $\Rightarrow X, Y$  nekorelované, avšak nikoliv naopak:

$X, Y$  nekorelované  $\nRightarrow X, Y$  stochasticky nezávislé.