

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

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

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

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

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

$\mathbf{0}, \mathbf{0}_{n \times 1}$... 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

$0, \mathbf{0}_{m \times n} = [0]$... 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 (Ω, \mathcal{A}, P) :

Ω ... základní prostor elementárních jevů

$\mathcal{A} \subseteq 2^\Omega$... σ -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 λ_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 ;

$u_\alpha = F^{-1}(\alpha) \dots$ α -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

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

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

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

Platí

$C_i \sim \chi^2(n_i)$ pro $i = 1, \dots, m$ 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;**

$t_\alpha(k) \dots$ α -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;**

$F_\alpha(n_1, n_2) \dots$ α -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 (Ω, \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.

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

□

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.