

10. přednáška : Aplikace pseudoinverze, další rozkazy matic, lineární procesy

Minule jsme definovali pseudoinverzi matici k matici A se sing. vektorům $A = PSQ^*$ jako

$$A^{(-1)} = Q S^{(-1)} P^*$$

a uvedli jsme několik z Matuňových pseudoinverzí matic. Některé z nich z Matuňového dokážeme:

(4) $A^{(-1)}A$ je matice kolmé projice \mathbb{K}^n na $(\ker \varphi)^\perp$ z díky k němu sing. vektorům matici \tilde{A}

$Q = (\text{id})_{E_n, \alpha}$, kde $\alpha = (u_1, u_2, \dots, u_r, u_{r+1}, \dots, u_n)$ je orthonormální báze v \mathbb{K}^n a $u_{r+1}, \dots, u_n \in \ker \varphi$, $\varphi : \mathbb{K}^n \rightarrow \mathbb{K}^r$, $\varphi(x) = Ax$.

Plati' $(\varphi^{(-1)} \varphi)_{E_n, E_n} = A^{(-1)} A$

a také'

$$\begin{aligned} (\varphi^{(-1)} \varphi)_{\alpha, \alpha} &= (\text{id})_{\alpha, E_n} A^{(-1)} A (\text{id})_{E_n, \alpha} \\ &= Q^* (Q S^{(-1)} P^* P S Q^*) Q \\ &= S^{(-1)} S = \left(\begin{array}{c|c} E & O \\ \hline O & O \end{array} \right) \begin{cases} r \\ n-r \end{cases} \end{aligned}$$

Prokaz. $(\varphi^{(-1)} \varphi)(u_i) = u_i \quad \text{na } 1 \leq i \leq r$

$$(\varphi^{(-1)} \varphi)(u_j) = 0 \quad \text{na } r+1 \leq j \leq n$$

Tedy $\varphi^{(-1)} \varphi$ je kolmé projice na $(\ker \varphi)^\perp$.

(5) $A A^{(-1)}$ je matice kolmé projice \mathbb{K}^n na $\text{im } \varphi$.

Düzenleme, $\varphi = (\text{id})_{E_k, B}$ kde $B = (n_1, \dots, n_n, n_{n+1}, \dots, n_k)$
 ki olanačnosti baře, role
 $[n_1, n_2, \dots, n_n] = \text{im } \varphi, \varphi(x) = Ax$.

Plati,

$$(\varphi \varphi^{-1})_{E_k, E_k} = A A^{(-1)}$$

$$\begin{aligned} (\varphi \varphi^{-1})_{B, B} &= (\text{id})_{B, E_k} A A^{(-1)} (\text{id})_{E_k, B} = \\ &= P^* (P S Q^*) (Q S^{-1} P^*) P = \\ &= S S^{-1} = \begin{pmatrix} E & 0 \\ 0 & 0 \end{pmatrix} \begin{cases} n \\ k-n \end{cases} \end{aligned}$$

Plati $\varphi \varphi^{-1}(n_i) = n_i$ pro $1 \leq i \leq n$

$$\varphi \varphi^{-1}(n_j) = 0 \quad \text{pro } n+1 \leq j \leq m.$$

Tedy $\varphi \varphi^{-1}$ je kolmá projekce na $\text{im } \varphi$.

(6) Plati $A A^{(-1)} A = A$.

$$\begin{aligned} A A^{(-1)} A &= P S Q^* Q S^{(-1)} P^* P S Q^* \stackrel{S}{=} \\ &= P S S^{(-1)} S Q^* = P \begin{pmatrix} E & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} Q^* \\ &= P \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} Q^* = P S Q^* = A \end{aligned}$$

$$(7) \quad A^{(-1)} = (A^* A)^{(-1)} A^*$$

$$(A^* A)^{(-1)} A^* = \left((P S Q^*)^* (P S Q) \right)^{(-1)} (P S Q^*)^*$$

$$= (Q S^* P^* P S Q^*)^{-1} (Q S^* P^*) =$$

$$= \left(Q \underbrace{\begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}}_{m \times k} \underbrace{\begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}}_{k \times n} Q^* \right)^{(-1)} \cdot Q \underbrace{\begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}}_{m \times k} P^* =$$

$$= \left(Q \underbrace{\begin{pmatrix} D^2 & 0 \\ 0 & 0 \end{pmatrix}}_{m \times m} Q^* \right)^{(-1)} \cdot Q \underbrace{\begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}}_{m \times k} P^* =$$

$$= Q \underbrace{\begin{pmatrix} D^{-2} & 0 \\ 0 & 0 \end{pmatrix}}_{m \times n} \underbrace{\begin{matrix} Q^* & Q \\ \hline = E & \\ m \times n & \end{matrix}} \underbrace{\begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}}_{m \times k} P^* =$$

$$= Q \underbrace{\begin{pmatrix} D^{-1} & 0 \\ 0 & 0 \end{pmatrix}}_{m \times k} P^* = Q S^{(-1)} P^* = A^{(-1)}$$

Oluşan eşitlik $A^* (A A^*)^{(-1)} = A^{(-1)}$. Daha da
bu denklemdeki $m \neq n$ olabilir.

Aproximace řešení soustav lineárních rovnic

Nechť A je matice $k \times n$. Uvažujme soustavu

$$A x = b, \quad x \in K^n, \quad b \in K^k.$$

Tato soustava má řešení, máme tedy

$$(*) \quad h(A) = h(A|b)$$

Podmínka $(*)$ je ekvivalentní tomu, že

$$b \in \text{im } q, \quad q : K^n \rightarrow K^k, \quad q(x) = Ax$$

V případě, že podmínka $(*)$ není splněna, chceme najít $x \in K^n$ takové, že

$$\|Ax - b\| \text{ je minimální}.$$

Věta: Funkce $f : K^n \rightarrow \mathbb{R}$

$$f(x) = \|Ax - b\|$$

najíždá svého minima v bodech

$$x = A^{(-1)}b + y,$$

kteře $Ay = 0$.

Důkaz: Jistě náme, že $A A^{(-1)} = P$ je matice

kolme' nejdece K^2 na $\text{im } \varphi$ ($\varphi(x) = Ax$).
 Příklad

$$\min_{x \in K^2} \|Ax - b\| = \min_{v \in \text{im } \varphi} \|v - b\| = \|Pb - b\| \\ = \|AA^{(-1)}b - b\|$$

Tedy $v = x = A^{(-1)}b$ maly'ra' funkce f málo
 minima. Stejně' hodnoty ale maly'ra' i ve
 všech $A^{(-1)}b + y$, kde $Ay = 0$.

Příklad: Máme (právě nyní) sestavu
 normic

$$\begin{aligned} x_1 + 2x_2 &= 3 \\ x_1 &= 7 \\ x_2 &= 5 \end{aligned}$$

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 0 \\ 0 & 1 \end{pmatrix} \quad b = \begin{pmatrix} 3 \\ 7 \\ 5 \end{pmatrix} \notin \text{im } \varphi$$

Nedajme (x_1, x_2) tak, aby

$$\|Ax - b\|^2 = (x_1 + 2x_2 - 3)^2 + (x_1 - 7)^2 + (x_2 - 5)^2$$

byla minimální. Použle předchozí výsledky,
 že

$$x = A^{(-1)}b = \begin{pmatrix} 1/6 & 5/6 & -1/3 \\ 1/3 & -1/3 & 1/3 \end{pmatrix} \begin{pmatrix} 3 \\ 7 \\ 5 \end{pmatrix} = \begin{pmatrix} 14/3 \\ 1/3 \\ 1/3 \end{pmatrix}$$

$A^{(-1)}$ je ne maximální minima!

Lineární regrese:

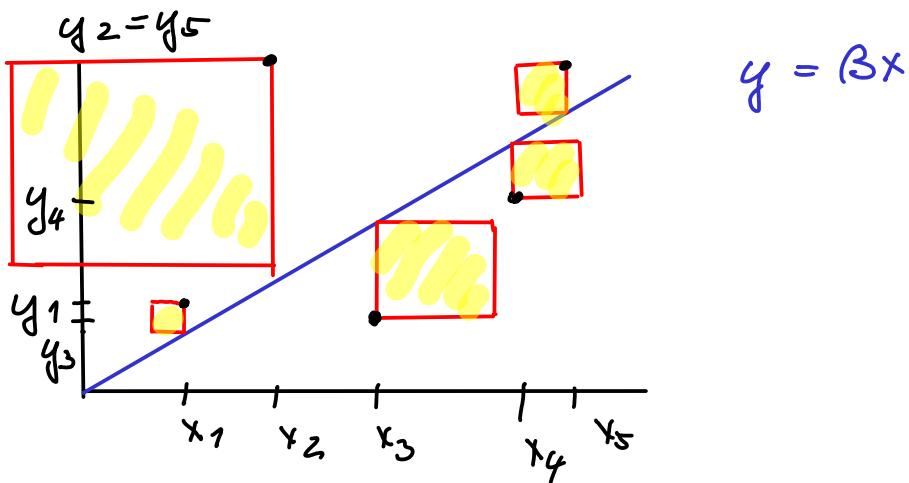
Očekáváme, že existuje vztah mezi x, y je lineární:

$$y = \beta x$$

Naměříme n řádky $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ a chceme najít β tak, že minimální $y = \beta x$ je „blízko“ naměřených bodů (x_i, y_i) . Slово „blízko“ znamená, aby byla suma

$$\sum_{i=1}^n (y_i - \beta x_i)^2$$

„minimální“.



Máme soustavu

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \beta = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \quad \text{a neznačme } \beta \in \mathbb{R}.$$

Nechť $\sum_{i=1}^n x_i^2 \neq 0$.

$$A = \begin{pmatrix} x_1 & & \\ & \ddots & \\ & & x_n \end{pmatrix} \quad b = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$$

$$\|A\beta - b\|^2 = (\beta x_1 - y_1)^2 + (\beta x_2 - y_2)^2 + \dots + (\beta x_n - y_n)^2.$$

Nejlepší approximace je

$$\begin{aligned} \beta &= A^{(-1)} b = (A^* A)^{(-1)} (A^* b) \\ &= \left(\sum_{i=1}^n x_i^2 \right)^{-1} (x_1, x_2, \dots, x_n) \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}. \end{aligned}$$

Další příklad na lineární regresi

Předpovídáme soubor dat $y = \alpha + \beta x$, naměřili jsme $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.

Kleďáme α, β tak, aby měly minimální

$$\sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 \quad \text{tj. minimální.}$$

To nese k vztahům

$$\begin{aligned} \alpha + \beta x_1 &= y_1 \\ \alpha + \beta x_2 &= y_2 \\ &\vdots \\ \alpha + \beta x_n &= y_n \end{aligned}$$

o matice $A = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}$, $b = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$, necháme $\underline{\alpha}$ a $\underline{\beta}$.

Víme, že $\begin{pmatrix} \alpha \\ \beta \end{pmatrix} = A^{-1} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$

$$A^* A = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ x_1 & x_2 & \cdots & x_n \end{pmatrix} \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} = \begin{pmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}$$

$$\det A^* A = n \sum_{i=1}^n x_i - \left(\sum_{i=1}^n x_i \right)^2 = \sum_{1 \leq i < j \leq n} (x_i - x_j)^2$$

Nechť $x_i \neq x_j$ pro všechny $i \neq j$. Pak
 $\det A^* A \neq 0$ a proto je

$$\begin{pmatrix} \alpha \\ \beta \end{pmatrix} = (A^* A)^{-1} (A^* b) = \frac{1}{\sum_{i < j} (x_i - x_j)^2} \begin{pmatrix} \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i & n \end{pmatrix} \begin{pmatrix} \sum_i y_i \\ \sum_i x_i y_i \end{pmatrix}$$

$$= \frac{1}{\sum_{i < j} (x_i - x_j)^2} \begin{pmatrix} (\sum_i x_i^2) (\sum_j y_j) + (\sum_i x_i) (\sum_j x_j y_j) \\ (\sum_i x_i) (\sum_j y_j) + n \sum_{i=1}^n x_i y_i \end{pmatrix}$$

Polární rozklad matice

Motivace: Rovnice komplexní čísla $a+ib \in \mathbb{C}$
 lze psat ve tvaru
 $a+ib = r(\cos \alpha + i \sin \alpha)$,

kde $r \geq 0$. Tento rozklad je jednoznačný,
je-li $a+ib \neq 0$.

Uvažujme lineární zobrazení

$$\varphi : \mathbb{C} \rightarrow \mathbb{C} \quad \varphi(z) = (a+ib) \cdot z$$

Toto zobrazení je složením dvou zobrazení

$$\varphi = \varphi_2 \circ \varphi_1,$$

kde

$$\varphi_1 : \mathbb{C} \rightarrow \mathbb{C} \quad \varphi_1(z) = (\cos \alpha + i \sin \alpha) z$$

je unitární a

$$\varphi_2 : \mathbb{C} \rightarrow \mathbb{C}, \quad \varphi_2(z) = rz, \quad r \geq 0$$

je samoadjungované a posledním semidefiniční.

Samoadjungované $(r)^* = \overline{r} = r$.

Poslední semidefiniční

$$\langle rz, z \rangle = r \|z\|^2 \geq 0.$$

Věta o polárním rozkladu

Je-li A čtvercová matice $n \times n$ nad \mathbb{R} nebo \mathbb{C} ,
pak ji lze rozložit na součin

$$A = R \cdot U,$$

kde R je samoadjungovaná ($R = R^*$)
a poslední semidefiniční ($\langle Rx, x \rangle \geq 0$)
a U je unitární nebo ortogonální.

Nanic platí, že $R^2 = AA^*$ (přímo $R = \sqrt{AA^*}$).

Je-li A invertibilní, jde R a U určeny jednoznačně.

Dílás pomoci sing. rachadu: Nechť $A = PSQ^*$ je sing. rachad matice A . Pak

$$A = \underbrace{PS}_{E} \underbrace{P^*}_{R} \underbrace{Q^*}_{U} = (PS) (P^*) (Q^*)$$

R je samoadjungovaná a posilme semidefiniční:

$$R^* = (PS)^* = PS^* P^* = PSP^*$$

$$\langle Rx, x \rangle = \langle PSP^*x, x \rangle = \langle SP^*x, P^*x \rangle = \langle Sx, x \rangle \geq 0.$$

U je unitární měla ortogonální:

$$UU^* = (PQ^*)(PQ^*)^* = (PQ^*)(Q^*P) = \underbrace{PQ^*}_{E} Q P = E$$

Dále:

$$AA^* = (RU)(RU)^* = R \underbrace{UU^*}_{E} R^* = R \cdot R^* = R^2.$$

jednoznačná je A ovesetlili už výše doloženo.

Příklad: Najde se plánování rachad matice

$$A = \begin{pmatrix} 2 & 1 \\ 2 & 1 \end{pmatrix}$$

A není regulární.

$$A = PSQ^* = P \begin{pmatrix} \frac{1}{\sqrt{10}} & 0 \\ 0 & \frac{1}{\sqrt{10}} \end{pmatrix} Q^*$$

$$A = (PSP^*)(PQ^*) = \begin{pmatrix} \frac{\sqrt{10}}{2} & \frac{\sqrt{10}}{2} \\ \frac{\sqrt{10}}{2} & \frac{\sqrt{10}}{2} \end{pmatrix} \cdot \begin{pmatrix} \frac{3}{\sqrt{10}} & \frac{1}{\sqrt{10}} \\ \frac{1}{\sqrt{10}} & \frac{3}{\sqrt{10}} \end{pmatrix}$$

Lineární procesy

popisují myši nějakého systému, který je v čase n popřád uchlaem

$$x(n) = \begin{pmatrix} x_1(n) \\ x_2(n) \\ \vdots \\ x_m(n) \end{pmatrix} \in \mathbb{R}^m$$

a jde očkovat a čas n do času $n+1$
pomocí matice A trave $m \times m$:

$$x(n+1) = Ax(n).$$

Důležitou roli pro "myšej" toku systému mají vlastní čísla a vlastní vektory matice A .

① Dravec a kořist

Nazavíme dra hrožené dravý, dravce D a kořist K . Označíme $x(n) = \begin{pmatrix} D_n \\ K_n \end{pmatrix}$ jejich počty po n letech. Změna počtu policha takto:

$$\begin{aligned} D_{n+1} &= 0,6 D_n + 0,5 K_n \\ K_{n+1} &= -p D_n + 1,2 K_n \end{aligned}$$

hde $p > 0$ je parametr. malice

$$X(n+1) = \begin{pmatrix} 0,6 & 0,5 \\ -p & 1,2 \end{pmatrix} X(n) = A X(n)$$

Zajišťuje nás myšlenka, že když obou druhové populace v závislosti na parametr p.

Vlastní čísla a reálnou matice A v závislosti na parametr p

$$(A) p = 0,16, \lambda_1 = 1, \lambda_2 = 0,8, u_1 = \begin{pmatrix} 5 \\ 4 \end{pmatrix}, u_2 = \begin{pmatrix} 5 \\ 2 \end{pmatrix}$$

$$(B) p = 0,175, \lambda_1 = 0,95, \lambda_2 = 0,85, u_1 = \begin{pmatrix} 10 \\ 7 \end{pmatrix}, u_2 = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$$

$$(C) p = 0,135, \lambda_1 = 1,05, \lambda_2 = 0,75, u_1 = \begin{pmatrix} 10 \\ 9 \end{pmatrix}, u_2 = \begin{pmatrix} 10 \\ 3 \end{pmatrix}$$

Počáteční stav obou druhů můžeme například jako lineární kombinaci vlastních vektorů

$$X(0) = \begin{pmatrix} D_0 \\ K_0 \end{pmatrix} = a u_1 + b u_2$$

V čase n je stav obou populací

$$\begin{aligned} X(n) &= A^n X(0) = A^n \begin{pmatrix} D_0 \\ K_0 \end{pmatrix} = A^n (a u_1 + b u_2) = \\ &= a A^n u_1 + b A^n u_2 = a \lambda_1^n u_1 + b \lambda_2^n u_2 \end{aligned}$$

Při fiktivním parametry lze znamenat

$$(A) p = 0,16, \lambda_1^n = 1^n = 1, \lambda_2^n = 0,8^n \rightarrow 0,$$

tedy $X_n \rightarrow a u_1 = a \begin{pmatrix} 5 \\ 4 \end{pmatrix}$. Populace

se malízují.

(B) $p = 0,175 \quad \gamma_1^n = 0,85^n \rightarrow 0, \quad \gamma_2^n = 0,85^n \rightarrow 0$
 proto
 $\chi(n) \rightarrow \begin{pmatrix} 0 \\ 0 \end{pmatrix}$. Populace mizí.

(C) $p = 0,135 \quad \gamma_1^n = 1,05^n \rightarrow \infty, \quad \gamma_2^n = 0,75^n \rightarrow 0$
 tedy pro $a \neq 0$ populace roste
 a rychle
 $D_n : K_n$
 se blíží poměru dravců a kořisti ve
 vztahu k věkovému vztahu n_{11} k n_{12} 10:9.

(2) Leslieho populacní model

Máme řízenou dravou populaci v několika skupinami.
 $x_i(n)$ je počet řidenců ve věkové skupině
 i v čase n . Model

$$x(n+1) = A x(n)$$

je dán maticí (tzn. Leslieho maticí)

$$A = \begin{pmatrix} f_1 & f_2 & f_3 & \dots & f_{m-1} & f_m \\ \bar{\tau}_1 & 0 & 0 & \dots & 0 & 0 \\ 0 & \bar{\tau}_2 & 0 & \dots & 0 & 0 \\ 0 & 0 & \bar{\tau}_3 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & & \bar{\tau}_{m-1} & 0 \end{pmatrix}$$

- čísla $f_i \geq 0$ určují pravděpodobnost v i-é kategorie skupiny

$$x_1(n+1) = f_1 x_1(n) + f_2 x_2(n) + \dots + f_m x_m(n)$$

- ε_i je koeficientem přežití z věku i do věku i+1. $\varepsilon_i \in [0, 1]$, $\varepsilon_i = 1 - \text{umrtvost}$

$$x_{i+1}(n+1) = \varepsilon_i x_i(n)$$

(3) Martovský proces

Systém se může nacházet v čase n v m několika stavech:

$$p_i(n)$$

je pravděpodobnost, že se nachází v čase n ve stavu i. Vektor

$$P(n) = \begin{pmatrix} p_1(n) \\ p_2(n) \\ \vdots \\ p_m(n) \end{pmatrix}$$

má vlastnost $\sum_{i=1}^m p_i(n) = 1$ a nazývá se pravděpodobnostní vektor.

V matici A = (a_{ij}) čísla a_{ij} ∈ [0, 1] udávají pravděpodobnost, že se systém ze stavu j dostane do stavu i.

$$p_i(n+1) = a_{i1} p_1(n) + a_{i2} p_2(n) + \dots + a_{im} p_m(n)$$

To máme dle 'lineární' proces

$$P(n+1) = A P(n),$$

Hlavní nazýváme Markovov proces.

Matice A má vlastnosti, které nazýváme
pravděpodobností a vlastnosti
stochastické nebo Markova.

Perronova - Frobeniova teorie

Matice $A = (a_{ij})$ se nazývá positivní, jestliže
 $a_{ij} > 0$ pro všechna $1 \leq i, j \leq n$. Matice A
se nazývá primitivní, jestliže nejakejší
řádová mocnina A^k je positivní.

Věta Perronova - Frobeniova

Nechť A je primitivní matice. Je několik komplexních vlastností těžel matice A které nazýváme nejslavnějšími:

absolutní hodnotou, nazýváme řád dominantní.

Totéž vlastností číslo λ_1 má systém vlastností:

- (1) λ_1 je kladné reálné číslo
- (2) geometrická hodnota vlastnosti číslo λ_1 je 1.
- (3) k λ_1 existuje vlastní vektor ne větší
součásti čemuž kladnými
- (4) Pokud je $\lambda_1 = 1$, systém určený modelem
 $X(n+1) = A X(n)$

se stabilizuje a konverguje k místnímu vlastnímu režimu k π_1 .

- (5) Pokud je $\lambda_1 < 1$, systém se nech stává koncepčně exponenciálně k 0.
- (6) Pokud je A Leslieho matice a $\lambda_1 > 1$, tak populace expanduje a nové typy mísí se do klimatické populace se blíží k novému stávku vlastnímu režimu k vlastnímu číslu π_1 .

LEMMA: Matice má dominantní vlastní číslo i když jde o zlomky. Z každého počátečního stavu konverguje systém k vlastnímu pravděpodobnostnímu režimu na vlastní číslo 1.

S příkladem na Leslieho populacního procesu a na Markovovu procesu se zákonem konvergence.