

## Přednáška 9b: Aplikace pseudoinverze, další rozklady matic, lineární procesy

Minule jsme definovali pseudoinverzi matice  $A$  se ring. rozkladem  $A = P S Q^*$  jako

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

a uvedli jsme větu o Martvalech pseudoinverzi matice. Některé z těchto Martvalů dokažeme:

(4)  $A^{(-1)} A$  je matice kolmé projekce  $K^m$  na  $(\ker \varphi)^\perp$  z důkazu ring. rozkladu níže, kde

$Q = (\text{id})_{E_m, \alpha}$ , kde  $\alpha = (\mu_1, \mu_2, \dots, \mu_r, \mu_{r+1}, \dots, \mu_m)$  je orthonormální báze  $K^m$  a  $\mu_{r+1}, \dots, \mu_m \in \ker \varphi$ ,

$$\varphi: K^m \rightarrow K^k, \quad \varphi(x) = Ax.$$

$$\text{Platí } (\varphi^{(-1)} \varphi)_{E_m, E_m} = A^{(-1)} A$$

a také

$$(\varphi^{(-1)} \varphi)_{\alpha, \alpha} = (\text{id})_{\alpha, E_m} A^{(-1)} A (\text{id})_{E_m, \alpha}$$

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

$$= S^{(-1)} S = \left( \begin{array}{c|c} E & 0 \\ \hline 0 & 0 \end{array} \right) \begin{array}{l} \} r \\ \} m-r \end{array}$$

$\underbrace{\hspace{1cm}}_r \quad \underbrace{\hspace{1cm}}_{m-r}$

$$\text{Přidat } (\varphi^{(-1)} \varphi)(\mu_i) = \mu_i \quad \text{na } 1 \leq i \leq r$$

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

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

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

Připomeňme, že  $P = (\text{id})_{\mathcal{E}_k, \mathcal{B}}$  kde  $\mathcal{B} = (v_1, \dots, v_n, v_{n+1}, \dots, v_k)$   
 je ortonormální báze, kde  
 $[v_1, v_2, \dots, v_n] = \text{im } \varphi$ ,  $\varphi(x) = Ax$ .

Plati

$$(\varphi \varphi^{-1})_{\mathcal{E}_k, \mathcal{E}_k} = A A^{-1}$$

$$\begin{aligned} (\varphi \varphi^{-1})_{\mathcal{B}, \mathcal{B}} &= (\text{id})_{\mathcal{B}, \mathcal{E}_k} A A^{-1} (\text{id})_{\mathcal{E}_k, \mathcal{B}} = \\ &= P^* (P S Q^*) (Q S^{-1} P^*) P = \\ &= S S^{-1} = \begin{pmatrix} E & O \\ \underbrace{O}_{n} & \underbrace{O}_{k-n} \end{pmatrix} \begin{matrix} \} n \\ \} k-n \end{matrix} \end{aligned}$$

Proto  $\varphi \varphi^{-1}(v_i) = v_i$  pro  $1 \leq i \leq n$   
 a

$\varphi \varphi^{-1}(v_j) = 0$  pro  $n+1 \leq j \leq k$ .

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

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

$$\begin{aligned} A A^{-1} A &= P S Q^* Q S^{-1} P^* P S Q^* \stackrel{S}{=} \\ &= P S S^{-1} S Q^* = P \begin{pmatrix} E & O \\ \underbrace{O}_{k \times k} & \underbrace{O}_{k \times n} \end{pmatrix} \begin{pmatrix} D & O \\ \underbrace{O}_{k \times n} & \underbrace{O}_{k \times n} \end{pmatrix} Q^* \\ &= P \begin{pmatrix} D & O \\ \underbrace{O}_{k \times n} & \underbrace{O}_{k \times n} \end{pmatrix} Q^* = P S Q^* = A \end{aligned}$$

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

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

Plati rovnice  $A^* (A A^*)^{(-1)} = A^{(-1)}$ . Důkaz je domácí úloha.

## Aproximace řešení soustav lineárních rovnic

Necht'  $A$  je matice  $k \times n$ . Uvažujme soustavu

$$Ax = b, \quad x \in \mathbb{K}^n, \quad b \in \mathbb{K}^k.$$

Tato soustava má řešení, má-li ady

$$(*) \quad \text{rk}(A) = \text{rk}(A|b)$$

Podmínka (\*) je ekvivalentní tomu, že

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

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

$$\|Ax - b\| \text{ je minimální.}$$

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

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

má v'ra' svéka minima v bodech

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

kde  $Ay = 0$ .

Důkaz: Již víme, že  $AA^{(-)} = P$  je matice

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

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

Tedy  $v$   $x = A^{(-)}b$  naty'ra' funkce  $f$  sveho minima. Stejne' hodnoty ale naty'ra' i ve v'ci  $A^{(-)}b + y$ , kde  $Ay = 0$ .

Pu'klad: Ma'me (p'ir'ic'nou) soustavu rovnice

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

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

Hleda'me  $(x_1, x_2)$  tak, aby

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

byla minima'l'ni'. Podle p'edcho'i' ve'by,

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

$A^{(-)}$  j'me m'ci'kali' minule!


Lineární regrese:

Očekáváme, že závislost veličin  $x, y$  je lineární:

$$y = \beta x$$

Naměříme  $n$  bodů  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  a chceme najít  $\beta$  tak, se přímla  $y = \beta x$  je „blízká“ naměřených bodů  $(x_i, y_i)$ . Slovo „blízká“ znamená obvykle, že suma

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



Máme soustavu

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \beta = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

o neznáme  $\beta \in \mathbb{R}$ .

Nechť  $\sum_{i=1}^n x_i^2 \neq 0$ .

$$A = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

$$b = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$$

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

Najlepší aproximace je

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

Další příklad na lineární regresi

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

Hledáme  $\alpha, \beta$  tak, aby počet čverců

$$\sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 \text{ byl minima'ni'}$$

Ta vede k rovnaně

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

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

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

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

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

Nechť  $x_i \neq x_j$  pre nejaké  $i \neq j$ . Pak  
 $\det A^* A \neq 0$  a podľa  $j^i$

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

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

## Polárni rozklad matice

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



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

Uvažme 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

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

je samoadjungované a pozitivně semi-definitní.

Samoadjungovanost  $(r)^* = \bar{r} = r$ .

Pozitivně semi-definitnost

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

### 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 pozitivně semi-definitní ( $\langle R x, x \rangle \geq 0$ )

a  $U$  je unitární nebo ortogonální.

Manic platí, že  $R^2 = A A^*$  (přičemž  $R = \sqrt{A A^*}$ ).

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

Diškas pomoci sing. razkladu: Nechť  $A = PSQ^*$  je sing. razklad matice  $A$ . Pak

$$A = PSP^* \underbrace{PQ^*}_E = \underbrace{(PSP^*)}_R \underbrace{(PQ^*)}_U$$

$R$  je samoadjungovaná a pozitivně semidefinitivní:

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

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

$U$  je unitární nebo ortogonální:

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

Dále:

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

Jednoznačně je  $A$  invertibilní nelademe dohromady.

Příklad: Najděte vlastní rozklad matice

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

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

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

## Lineární procesy

prvními myšmi nějakého systému, který si v čase  $n$  poprákne reklamou

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

a jeho předchůzci v čase  $n$  do času  $n+1$  pomocí matice  $A$  tvaru  $m \times m$ :

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

Důležitou roli při popisu "myšmi" tohoto systému mají vlastní čísla a vlastní vektorové matice  $A$ .

### ① Dravec a kořist

Uvažujme dva úroveňně dimenzované dravce  $D$  a kořist  $K$ . Označíme  $x(n) = \begin{pmatrix} D_n \\ K_n \end{pmatrix}$  jejich počty po  $n$  letech. Změna počtu poliká takto:

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

kde  $p > 0$  je parametr. Matice

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

Raji má na's my'roj le'ko dvoch druhov populace  
v sa'rislosti na parametre p.

Vlastni' čísla a vektoru matice A v sa'rislosti  
na parametre p

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

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

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

Počítacím' stav obou druhů můžeme napravit  
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

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

Pro jednotlivé parametry to znamená

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

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

se stabilizují.

(B)  $p = 0,175$   $\lambda_1^n = 0,95^n \rightarrow 0$ ,  $\lambda_2^n = 0,85^n \rightarrow 0$   
 proto  $x(n) \rightarrow \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ . Populace mizí.

(C)  $p = 0,135$   $\lambda_1^n = 1,05^n \rightarrow \infty$ ,  $\lambda_2^n = 0,75^n \rightarrow 0$   
 tedy se  $a \neq 0$  populace roste  
 a poměr  $D_n : K_n$

se blíží poměru dravů a kořisti ve  
 vlastním vektoru  $w_1$  tj. 10:9.

## (2) Leslieho populační model

Máme pohlaví drak s  $m$  věkovými skupinami.  
 $x_i(n)$  je počet jedinců ve věkové skupině  
 $i$  v čase  $n$ . Model

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

je dána matricí (tzv. Leslieho matricí)

$$A = \begin{pmatrix} f_1 & f_2 & f_3 & \dots & f_{m-1} & f_m \\ \tau_1 & 0 & 0 & \dots & 0 & 0 \\ 0 & \tau_2 & 0 & \dots & 0 & 0 \\ 0 & 0 & \tau_3 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & \tau_{m-1} & 0 \end{pmatrix}$$

- čísla  $f_i \geq 0$  určují podíl v  $i$ -té větvě

$$X_1(n+1) = f_1 X_1(n) + f_2 X_2(n) + \dots + f_m X_m(n)$$

- $\tau_i$  je koeficient přechodu z větvě  $i$  do větvě  $i+1$ .  $\tau_i \in [0, 1]$ ,  $\tau_i = 1$  - u'utvářeno

$$X_{i+1}(n+1) = \tau_i X_i(n)$$

### (3) Markovův proces

Systém se měří nezávisle v čase  $n$  v  $m$  různých 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  $a_{ij} \in [0, 1]$  udávají pravděpodobnost, že se systém v čase  $n$  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 nám dáva' lineárny' proces

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

ktorý nazývame Markovov proces.

Matice  $A$  má' vlastnosť, sô sačít' prvku' v každé'm slupki je 1 a nazývajú se stochastická' nebo Markovova.

## Perronova - Frobeniova teorie

Matice  $A = (a_{ij})$  se nazývajú pozitívny', keďliže  $a_{ij} > 0$  pre, keďliže  $1 \leq i, j \leq n$ . Matice  $A$  se nazývajú primitívny', keďliže nejaká' její mocnina  $A^k$  je pozitívny'.

## Věta Perronova - Frobeniova

Nechť  $A$  je primitívny' matice. Ze všech komplexních vlastních čísel má právě jedno největší absolutní hodnotu, nazýváme její dominantní. Toto vlastní číslo  $\lambda_1$  má tyto vlastnosti:

- (1)  $\lambda_1$  je kladné reálné číslo
- (2) geometrická násobná vlastního čísla  $\lambda_1$  je 1.
- (3) K  $\lambda_1$  existují vlastní vektory se všemi souřadnicemi kladnými
- (4) Pokud je  $\lambda_1 = 1$ , systém určený modelem  
$$X(n+1) = A X(n)$$

se stabilizuje a konverguje k nárůstce  
kladného reálnu k  $\lambda_1$ .

(5) Pokud je  $\lambda_1 < 1$ , systém se včch  
stříchách konverguje exponenciálně k 0.

(6) Pokud je  $A$  Leslieho matice a  $\lambda_1 > 1$ , pak  
populace expanduje a poměry mezi jedno-  
dílymi populacemi se blíží k poměrům  
střích kladného reálnu k vlastnímu  
číslu  $\lambda_1$ .

Lemma: Markovova matice má, dominantní  
kladné číslo jako řády jedné. Z každého  
počátečního stavu konverguje systém k kladní-  
mu pravděpodobnostnímu reálnu na kladní  
číslu 1.

S příkladem na Leslieho populační proces  
a na Markovův proces se můžete  
seznámit.