

Tomáš Oberhuber

Faculty of Nuclear Sciences and Physical Engineering
Czech Technical University in Prague

Video na Youtube

Částečný problém vlastních čísel

Vlastní vektor

Mocninná
metoda

Redukční
metoda

Shrnutí a
otázky

- výpočet kompletního spektra je velmi náročná úloha
- často nám stačí nalézt třeba jen jedno, v absolutní hodnotě největší vlastní číslo
- mluvíme pak o částečném problému vlastních čísel
- pro tento účel se používá hlavně **mocninná metoda**

Částečný problém vlastních čísel

Vlastní vektor

Mocnná
metoda

Redukční
metoda

Shrnutí a
otázky

Poznámka

V této části budeme používat zjednodušené pojmy:

- *největší vlastní číslo* \equiv v absolutní hodnotě největší vlastní číslo
- *největší vlastní vektor* \equiv libovolný vlastní vektor příslušející k v absolutní hodnotě největšímu vlastnímu číslu

Mějme matici \mathbb{A}

$$\mathbb{A} = \begin{pmatrix} 3 & \\ & 2 \end{pmatrix}.$$

Pak

$$\vec{x}^{(k)} = \mathbb{A}^k \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 3^k & \\ & 2^k \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 3^k \\ 2^k \end{pmatrix}$$

a

$$\lim_{k \rightarrow \infty} \frac{1}{3^k} \vec{x}^{(k)} = \lim_{k \rightarrow \infty} \frac{1}{3^k} \begin{pmatrix} 3^k \\ 2^k \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \end{pmatrix},$$

což je vlastní vektor příslušející k vlastnímu číslu 3.

Vlastní vektor

Mocninná
metoda

Redukční
metoda

Shrnutí a
otázky

- bude-li matice \mathbb{A} obecná a ne diagonální, byl by výpočet \mathbb{A}^k velmi náročný
- navíc nás zajímá její aplikace jen na jeden vektor $\vec{x}^{(0)} = (1, 1)^T$
- výpočet k -té mocniny nahradíme následující vektorovou posloupností

$$\vec{x}^{(k+1)} = \mathbb{A}\vec{x}^{(k)}$$

- pak platí, že

$$\vec{x}^{(k)} = \mathbb{A}^k \vec{x}^{(0)}$$

Vlastní vektor

Mocnná
metodaRedukční
metodaShrnutí a
otázky

- obecně pak pro $\vec{x}^{(0)} = (x_1, x_2)^T$ dostáváme

$$\vec{x}^{(k)} = \mathbb{A}^k \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 3^k & \\ & 2^k \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 3^k x_1 \\ 2^k x_2 \end{pmatrix}$$

$$\lim_{k \rightarrow \infty} \frac{1}{3^k} \vec{x}^{(k)} = \lim_{k \rightarrow \infty} \frac{1}{3^k} \begin{pmatrix} 3^k x_1 \\ 2^k x_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ 0 \end{pmatrix},$$

- je-li $x_1 \neq 0$, opět dostáváme největší vlastní vektor

Vlastní vektor

Mocninná
metoda

Redukční
metoda

Shrnutí a
otázky

- vidíme tedy, že je důležité, aby **první složka** vektoru $\vec{x}^{(0)} = (x_1, x_2)^T$ byla **nenulová**, jinak by limitní vektor byl **nulový**
- jinými slovy $\vec{x}^{(0)}$ musí mít nenulový průmět do směru největšího vlastního vektoru

Vlastní vektor

Mocninná
metoda

Redukční
metoda

Shrnutí a
otázky

- dělením číslem 3^k jsme dělali proto, aby vzniklá posloupnost $\vec{x}^{(k)}$ konvergovala
- jinak bychom dostali posloupnost vektorů, které se sice stáčí do směru největšího vlastního vektoru, ale jejich velikost roste do nekonečna
- teoreticky by to možná nemuselo vadit, ale v aritmetice s konečnou přesností by snadno došlo k přetečení maximálního nebo minimálního exponentu
- obecněji můžeme provádět dělení největší složkou výsledného vektoru
- dostáváme tak tzv. *mocninnou metodu*

- tato metoda konstruuje následující posloupnosti:

$$\begin{aligned}\vec{y}^{(k+1)} &= \mathbb{A}\vec{x}^{(k)}, \\ l_{k+1} &= \operatorname{argmax}_{i=1,\dots,n} |y_i^{(k+1)}|, \\ \rho_{k+1} &= y_{l_{k+1}}^{(k+1)}, \\ \vec{x}^{(k+1)} &= \frac{1}{\rho_{k+1}} \vec{y}^{(k+1)}.\end{aligned}$$

- za vhodných předpokladů $\vec{x}^{(k)}$ konverguje k největšímu vlastnímu vektoru a ρ_k k největšímu vlastnímu číslu

Example 1

- buď opět

$$A = \begin{pmatrix} 3 & \\ & 2 \end{pmatrix}, \vec{x}^{(0)} = (1, 1)^T.$$

- pak

k	$\vec{y}^{(k+1)}$	l_{k+1}	ρ_{k+1}	$\vec{x}^{(k+1)}$
0	$(3, 2)^T$	1	3	$(1, \frac{2}{3})^T$
1	$(3, \frac{4}{3})^T$	1	3	$(1, \frac{4}{9})^T$
2	$(3, \frac{8}{9})^T$	1	3	$(1, \frac{8}{27})^T$
3	$(3, \frac{16}{27})^T$	1	3	$(1, \frac{16}{81})^T$
\vdots	\vdots	\vdots	\vdots	\vdots
i	$(3, \frac{2^{i+1}}{3^i})^T$	1	3	$(1, (\frac{2}{3})^{i+1})^T$

Example 2

- nyní změníme $\vec{x}^{(0)}$

$$A = \begin{pmatrix} 3 & \\ & 2 \end{pmatrix}, \vec{x}^{(0)} = (0, 1)^T.$$

- pak

k	$\vec{y}^{(k+1)}$	l_{k+1}	ρ_{k+1}	$\vec{x}^{(k+1)}$
0	$(0, 2)^T$	2	2	$(0, 1)^T$
1	$(0, 2)^T$	2	2	$(0, 1)^T$
\vdots	\vdots	\vdots	\vdots	\vdots
i	$(0, 2)^T$	2	2	$(0, 1)^T$

- metoda generuje konstantní posloupnost nejmenšího vlastního čísla a příslušného vlastního vektoru
- stalo se to proto, že za počáteční vektor $\vec{x}^{(0)}$ jsme zvolili jiný než největší vlastní vektor
- pokud by A byla větší matice a my zvolili za $\vec{x}^{(0)}$ jiný vlastní vektor, stalo by se to samé
- ve výsledku tak dostáváme nějaký vlastní vektor podle volby $\vec{x}^{(0)}$, ale nevíme jaký
- to ale není to, co chceme - nás zajímá největší vlastní číslo a příslušný vlastní vektor
- problém nastává, když $\vec{x}^{(0)}$ má **nulový průmět do směru "největšího vlastního vektoru"** a metoda tedy nemá šanci ho v daném směru protahovat

Example 3

- uvažme tento příklad

$$A = \begin{pmatrix} 3 & \\ & 2 \end{pmatrix}, \vec{x}^{(0)} = (\epsilon, 1)^T.$$

- pak

k	$\vec{y}^{(k+1)}$	l_{k+1}	ρ_{k+1}	$\vec{x}^{(k+1)}$
0	$(3\epsilon, 2)^T$	2	2	$(\frac{3}{2}\epsilon, 1)^T$
1	$(\frac{9}{2}\epsilon, 2)^T$	2	2	$(\frac{9}{4}\epsilon, 1)^T$
\vdots	\vdots	\vdots	\vdots	\vdots
$i-1$	$(\frac{3^i}{2^{i-1}}\epsilon, 2)^T$	2	2	$(\frac{3^i}{2^i}\epsilon, 1)^T$
i	$(\frac{3^{i+1}}{2^i}\epsilon, 2)^T$	1	$\frac{3^{i+1}}{2^i}\epsilon$	$(1, \frac{2^i}{3^{i+1}}\epsilon)^T$
$i+1$	$(3, \frac{2^{i+1}}{3^{i+1}}\epsilon)^T$	1	3	$(1, \frac{2^{i+1}}{3^{i+2}}\epsilon)^T$
\vdots	\vdots	\vdots	\vdots	\vdots

- zde i je takové, že $\frac{3^{i+1}}{2^i}\epsilon > 2$

- vidíme, že stačí, aby průmět $\vec{x}^{(0)}$ do směru největšího vlastního vektoru byl i **velice malý**
- toto v praxi **u reálných úloh zajistí zaokrouhlovací chyby**
- navíc, pokud budeme $\vec{x}^{(0)}$ volit náhodně, pak je nulová pravděpodobnost trefit vektor s nulovým průmětem do největšího vlastního vektoru

- buď \mathbb{A} hermitovská, tj. $\mathbb{A} = \mathbb{U}\mathbb{D}\mathbb{U}^*$, kde

$$\mathbb{D} = \mathit{diag}\{\lambda_1, \dots, \lambda_n\}$$

a platí $|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|$

- platí

$$\mathbb{A}\mathbb{U} = \mathbb{U}\mathbb{D} = (\lambda_1 \vec{u}^{(1)}, \dots, \lambda_n \vec{u}^{(n)})$$

- tedy $\vec{u}^{(1)}, \dots, \vec{u}^{(n)}$ jsou ON vlastní vektory
- dále

$$\mathbb{A}^k \vec{x} = \mathbb{U}\mathbb{D}^k \mathbb{U}^* \vec{x} = \mathbb{U}\mathbb{D}^k \vec{v},$$

kde $\vec{v} = \mathbb{U}^* \vec{x}$.

- \vec{v} je tedy vektor \vec{x} transformovaný do báze vlastních vektorů matice \mathbb{A} tj. $\vec{u}^{(1)}, \dots, \vec{u}^{(n)}$
- aby metoda dobře fungovala, je opět potřeba, aby průmět do největšího vlastního vektoru $\vec{u}^{(1)}$ byl nenulový a tedy $v_1 \neq 0$

- pak bude platit

$$\lim_{k \rightarrow \infty} \frac{1}{\lambda_1^k} \mathbf{A}^k \vec{x} = \lim_{k \rightarrow \infty} \mathbb{U} \begin{pmatrix} \frac{\lambda_1^k}{\lambda_1^k} & & & \\ & \frac{\lambda_2^k}{\lambda_1^k} & & \\ & & \ddots & \\ & & & \frac{\lambda_n^k}{\lambda_1^k} \end{pmatrix} \vec{v} =$$

$$= \mathbb{U} \begin{pmatrix} 1 & & & \\ & 0 & & \\ & & \ddots & \\ & & & 0 \end{pmatrix} \vec{v} = \mathbb{U} \begin{pmatrix} v_1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} = v_1 \vec{u}^{(1)}$$

- dělení λ_1 místo ρ_k jsme zde dělali pro zjednodušení příkladu

- v příkladu 3 jsme ukázali, že pokud se l_k nemění, ρ_k dává odhad největšího vlastního čísla
- pokud by se posloupnost l_k neustalovala, lze odhad vlastního čísla získat z odhadu vlastního vektoru
- je-li $\vec{x}^{(k)}$ odhad vlastního vektoru, pak platí

$$\mathbb{A}\vec{x}^{(k)} = \vec{y}^{(k+1)} \approx \lambda_1 \vec{x}^{(k)},$$

a tedy

$$\begin{aligned} y_1^{(k+1)} &= c_1 x_1^{(k)} \\ y_2^{(k+1)} &= c_2 x_2^{(k)} \\ &\vdots \\ y_n^{(k+1)} &= c_n x_n^{(k)} \end{aligned}$$

- každé z čísel c_1, \dots, c_n je aproximace λ_1 , můžeme si vybrat jedno z nich nebo třeba průměrnou hodnotu

Shrnutí mocninné metody pro diagonální nebo hermitovské matice:

- metoda **exponenciálně** zesiluje efekt jednotlivých vlastních čísel a vektorů
- tento efekt se zobrazuje skrze vektor $\vec{x}^{(0)}$
- aby metoda správně našla největší vlastní vektor musí být průmět $\vec{x}^{(0)}$ do směru největšího vlastního vektoru nenulový
- v takovém případě ani nemůže nastat dělení nulou, to by nastalo jen v případě, že $\vec{x}^{(0)} = 0$

Mocninná metoda stejným způsobem funguje i pro obecnější třídu matic, jak si následně ukážeme.

Theorem 4

Vektor $\vec{x}^{(k)}$ z mocninné metody lze vyjádřit takto

$$\vec{x}^{(k)} = \frac{1}{\rho_1 \rho_2 \cdots \rho_k} \mathbb{A}^k \vec{x}^{(0)}.$$

Důkaz.

[Video na Youtube](#)



Remark 5

Pokud $\rho_k \rightarrow \lambda_1$, pak platí

$$\rho_1 \rho_2 \cdots \rho_k \approx \lambda_1^k.$$

Theorem 6

Nechť matice $\mathbb{A} \in \mathbb{C}^{n,n}$ má jedno v absolutní hodnotě největší vlastní číslo λ jednonásobné nebo vícenásobné se stejnou algebraickou i geometrickou násobností a $\vec{t}^{(1)}, \dots, \vec{t}^{(r)}$ jsou příslušné vlastní vektory. Nechť matice \mathbb{T} převádí \mathbb{A} do Jordanova tvaru, tj.

$$\mathbb{A} = \mathbb{T}^{-1} \mathbb{J}_{\mathbb{A}} \mathbb{T}$$

tak, že λ se vyskytuje na prvních r řádcích $\mathbb{J}_{\mathbb{A}}$. Pak pro libovolné $\vec{x}^{(0)}$ takové, že alespoň jedna z prvních r složek vektoru $\mathbb{T}\vec{x}^{(0)}$ je nenulová, platí, že v mocninné metodě konverguje posloupnost ρ_k k vlastnímu číslu λ a posloupnost $\vec{x}^{(k)}$ k příslušnému vlastnímu vektoru.

Důkaz.

[Video na Youtube](#)

Theorem 7

Nechť matice $\mathbb{A} \in \mathbb{C}^{n,n}$ má dvě v absolutní hodnotě největší vlastní čísla $\lambda_1, -\lambda_1$ s opačným znaménkem. Necht' $\vec{t}^{(1)}, \vec{t}^{(2)}$ jsou příslušné vlastní vektory. Necht' matice \mathbb{T} převádí \mathbb{A} do Jordanova tvaru, tj.

$$\mathbb{A} = \mathbb{T}^{-1} \mathbb{J}_{\mathbb{A}} \mathbb{T}$$

tak, že $\pm\lambda$ se vyskytuje na prvních dvou řádcích $\mathbb{J}_{\mathbb{A}}$. Pak pro libovolné $\vec{x}^{(0)}$ takové, že alespoň jedna z prvních dvou složek vektoru $\mathbb{T}\vec{x}^{(0)}$ je nenulová, platí, že v mocninné metodě konverguje posloupnost $\sqrt{\rho_{2k}\rho_{2k+1}}$ k absolutní hodnotě největších vlastních čísel a posloupnost $\mathbb{A}\vec{x}^{(2k)} + \lambda_1\vec{x}^{(2k)}$ k vlastnímu vektoru příslušejícímu k vlastnímu číslu λ_1 a posloupnost $\mathbb{A}\vec{x}^{(2k)} - \lambda_1\vec{x}^{(2k)}$ k vlastnímu vektoru příslušejícímu k vlastnímu číslu $-\lambda_1$.

- mocninná metoda je implementována v programu `power-method`
 - `--input-file` – vstupní soubor s maticí
 - `--eigenvalue largest/smallest` – jaké vlastní číslo hledáme
 - `--initial-value v` – nastavení vektoru $\vec{x}^{(0)}$
 - `--max-iterations n` – maximální možný počet provedených iterací
 - `--convergence-residue r` – hodnota kritéria pro zastavení výpočtu
 - `--verbose n`
 - nastavuje úroveň vypisovaných informací v průběhu výpočtu

Remark 8

K napočítání samotného vlastního vektoru stačí konstruovat tzv. Krylovovu posloupnost $\vec{x}^{(0)}, \mathbb{A}\vec{x}^{(0)}, \mathbb{A}^2\vec{x}^{(0)}, \dots$ a dělení číslem ρ_k není nutné, je dobré jen pro lepší numerickou stabilitu.

Remark 9

Rychlost konvergence závisí na poměru $\frac{\lambda_i}{\lambda_1}$. Konvergenci můžeme urychlit vhodným posunem spektra o číslo λ^ úpravou původní matice na matici $\mathbb{A} - \lambda^*\mathbb{I}$. Tím můžeme zmenšit podíl $\frac{\lambda_i - \lambda^*}{\lambda_1 - \lambda^*}$. K ρ pak musíme přičíst λ^* .*

Remark 10

Pokud chceme najít v absolutní hodnotě nejmenší vlastní číslo matice \mathbb{A} , můžeme použít mocninnou metodu na matici \mathbb{A}^{-1} . Nejmenší vlastní číslo pak bude $\frac{1}{\rho}$. Pokud chceme najít vlastní číslo matice \mathbb{A} , které je nejbližší zvolenému číslu λ' budeme hledat největší vlastní číslo matice

$$(\mathbb{A} - \lambda' \mathbb{I})^{-1}.$$

Hledané číslo pak získáme jako $\frac{1}{\rho} + \lambda'$.

Remark 11

V případě z předchozí poznámky napočítáváme

$$\vec{y}^{(k+1)} = \mathbb{A}^{-1} \vec{x}^{(k)}.$$

Abychom se vyhnuli výpočtu inverze matice \mathbb{A} , převedeme vztah na

$$\mathbb{A} \vec{y}^{(k+1)} = \vec{x}^{(k)},$$

a řešíme soustavu lineárních rovnic. S výhodou lze využít iterativní metody neboť:

- pro k malé je zbytečné řešit lineární soustavu s vysokou přesností a stačí proto počítat menší počet iterací*
- pro k velké se po sobě jdoucí vektory $\vec{y}^{(k)}$ a $\vec{y}^{(k+1)}$ příliš neliší a $\vec{y}^{(k)}$ je dobrým odhadem řešení pro soustavu s neznámým vektorem $\vec{y}^{(k+1)}$*

Tento trik, jak se zbavit výpočtu inverze matice, jež pouze aplikujeme na jeden nebo několik vektorů, se v numerice používá velmi často.

- tato metoda slouží k odseparování již nalezených vlastních čísel, pokud chceme např. napočítat více než jedno v absolutní hodnotě největší vlastní číslo
- nehodí se ale pro výpočet kompletního spektra, kvůli rychlé ztrátě přesnosti

Remark 12

Bud' tedy $A \in \mathbb{C}^{n,n}$ a $\lambda_1 \in \sigma(A)$ a \vec{x} k němu příslušný vlastní vektor. Odvodíme metodu pro výpočet matice $B \in \mathbb{C}^{n-1,n-1}$, která má všechna vlastní čísla stejná jako A až na λ_1 , u kterého se sníží násobnost.

- matici \mathbb{A} převedeme do báze, tvořené vektory $\vec{x}, \vec{e}_2, \dots, \vec{e}_n$
- v této bázi bude matice vypadat takto

$$\mathbb{P}^{-1} \mathbb{A} \mathbb{P} = \begin{pmatrix} \lambda_1 & \vec{q}^t \\ \vec{\theta} & \mathbb{B} \end{pmatrix},$$

kde \mathbb{P} je matice přechodu mezi bázemi.

Tvar matice \mathbb{P} je zřejmý, její sloupce tvoří bazické vektory

$$\mathbb{P} = \begin{pmatrix} x_1 & & & & \\ & 1 & & & \\ & & \ddots & & \\ & & & \ddots & \\ & & & & 1 \end{pmatrix}$$

Inverzní matici k matici \mathbb{P} je taková, která první řádek podělí x_1 a vynuluje všechny prvky pod diagonálou v prvním sloupci. Takovou matici ale snadno najdeme, známe ji z GEM.

$$\mathbb{P}^{-1} = \begin{pmatrix} \frac{1}{x_1} & & & & \\ -\frac{x_2}{x_1} & 1 & & & \\ \vdots & & \ddots & & \\ -\frac{x_n}{x_1} & & & \ddots & 1 \end{pmatrix}$$

Roznásobením snadno získáme tvar matice \mathbb{B}

$$\mathbb{B} = \begin{pmatrix} a_{22} - \frac{x_2}{x_1} a_{12} & a_{23} - \frac{x_2}{x_1} a_{13} & \dots & a_{2n} - \frac{x_2}{x_1} a_{1n} \\ a_{32} - \frac{x_3}{x_1} a_{12} & a_{33} - \frac{x_3}{x_1} a_{13} & \dots & a_{3n} - \frac{x_3}{x_1} a_{1n} \\ \vdots & \vdots & & \vdots \\ a_{n2} - \frac{x_n}{x_1} a_{12} & a_{n3} - \frac{x_n}{x_1} a_{13} & \dots & a_{nn} - \frac{x_n}{x_1} a_{1n} \end{pmatrix}.$$

Její tvar lze také snadno odvodit, pokud si uvědomíme, že pravý dolní čtverec matice $\mathbb{A}\mathbb{P}$ o rozměrech $(n-1) \times (n-1)$ odpovídá přesně prvkům matice \mathbb{A} . Při násobení maticí \mathbb{P}^{-1} zleva pak v tomto čtverci od každého řádku i odečítáme $\frac{x_i}{x_1}$ násobek prvního řádku matice \mathbb{A} . To je právě význam matice \mathbb{P}^{-1} .

Podobně lze odvodit, že

$$\vec{q}^T = \frac{1}{x_1} (a_{12}, a_{13}, \dots, a_{1n})$$

Nyní známe matici \mathbb{B} a můžeme najít některé její vlastní číslo λ_2 . Buď $\vec{z} = (z_2, \dots, z_n)^T$ k němu příslušný vlastní vektor. Jak najít odpovídající vlastní vektor matice \mathbb{A} ?

Redukční metoda

Logicky jako lineární kombinaci bazických vektorů daných sloupci matice \mathbb{P} . K tomu ale musíme dopočítat složku z_1 .
Musí platit

$$\begin{aligned} \begin{pmatrix} \lambda_1 & \vec{q}^T \\ \vec{\theta} & \mathbb{B} \end{pmatrix} \begin{pmatrix} z_1 \\ \vec{z} \end{pmatrix} &= \begin{pmatrix} \lambda_1 z_1 + \vec{q}^T \vec{z} \\ \mathbb{B} \vec{z} \end{pmatrix} = \begin{pmatrix} \lambda_1 z_1 + \vec{q}^T \vec{z} \\ \lambda_2 \vec{z} \end{pmatrix} \\ &= \begin{pmatrix} \lambda_2 z_1 \\ \lambda_2 \vec{z} \end{pmatrix} \end{aligned}$$

a tedy

$$\lambda_1 z_1 + \vec{q}^T \vec{z} = \lambda_2 z_1 \Rightarrow z_1 = \frac{\vec{q}^T \vec{z}}{\lambda_2 - \lambda_1}.$$

- pokud by bylo $\lambda_1 = \lambda_2$, pak platí $\mathbb{B}\vec{z} = \lambda_1\vec{z}$ a musí být

$$\begin{pmatrix} \lambda_1 & \vec{q}^T \\ \vec{\theta} & \mathbb{B} \end{pmatrix} \begin{pmatrix} z_1 \\ \vec{z} \end{pmatrix} = \begin{pmatrix} \lambda_1 z_1 + \vec{q}^T \vec{z} \\ \mathbb{B}\vec{z} \end{pmatrix} = \begin{pmatrix} \lambda_1 z_1 \\ \lambda_1 \vec{z} \end{pmatrix}$$

- tj. musí být $\vec{q}^T \vec{z} = 0$ a z_1 lze volit libovolně.

Vlastní vektor matice \mathbb{A} je pak dán jako

$$\vec{y} = \mathbb{P} \begin{pmatrix} z_1 \\ \vec{z} \end{pmatrix} = z_1 \vec{x} + \begin{pmatrix} 0 \\ \vec{z} \end{pmatrix}.$$

Vlastní vektor

Mocninná
metoda

Redukční
metoda

Shrnutí a
otázky

- částečný problém vlastních čísel
 - **mocninná metoda**
 - jak v praxi zaručit její podmínky konvergence?
 - jak napočítat nejmenší vlastní číslo?
 - redukční metoda