

Veta 1. Ak A je symetrická kladne definitná matica, tak Gaussova-Seidlova metóda konverguje.

Dôkaz: Pre prípad symetrickej matice dostávame rozklad

$$A = D + L + L^T,$$

kde D je diagonálna matica obsahujúca diagonálne prvky matice A a L a L^T sú zvyšné dolné a horné trojuholníkové časti matice $A - D$. Keďže A je kladne definitná, diagonálna matice D obsahuje len kladné prvky, a teda je tiež kladne definitná (ak by $a_{ii} < 0$, tak $e_i^T A e_i = a_{ii} < 0$, kde $e_i = (0, \dots, 1, \dots, 0)$ je vektor kanonickej bázy).

Na odhad pre konvergenciu použijeme 2-normu, čím zredukujeme problém na odhad veľkosti absolútnej hodnoty vlastných čísel, keďže pre symetrickú maticu A je $\|A\|_2 = |\lambda|_{\max}$. Najskôr zjednodušíme maticu $Q_{GS} = -(D + L)^{-1}L^T$.

$$Q_{GS} = -(D + L)^{-1}L^T = -D^{-\frac{1}{2}}(I + D^{-\frac{1}{2}}LD^{-\frac{1}{2}})^{-1}D^{-\frac{1}{2}}L^TD^{-\frac{1}{2}}D^{\frac{1}{2}}.$$

Označme $L_1 = D^{-\frac{1}{2}}LD^{-\frac{1}{2}}$. Potom

$$Q_{GS} = -D^{-\frac{1}{2}}(I + L_1)^{-1}L_1^TD^{\frac{1}{2}}.$$

Matica $-(I + L_1)^{-1}L_1^T$ je teda podobná s maticou Q_{GS} , a tým pádom má rovnaké vlastné čísla.

Ak x označuje jednotkový vlastný vektor, t.j. $\|x\|_2 = \sqrt{x^*x} = 1$ a $-(I + L_1)^{-1}L_1^T x = \lambda x$ (x môže byť komplexný vektor a λ komplexná vlastná hodnota, $*$ je znamená hermitovské združenie), máme

$$\begin{aligned} -(I + L_1)^{-1}L_1^T x &= \lambda x \\ -L_1^T x &= \lambda(I + L_1)x \end{aligned}$$

a prenásobením posledného vzťahu zľava x^* a úpravou

$$-x^*L_1^T x = \lambda x^*(I + L_1)x = \lambda(I + x^*L_1x).$$

Označme $z = x^*L_1^T x$. Potom platí

$$\begin{aligned} -z &= \lambda(1 + \bar{z}) \\ \lambda &= -\frac{z}{1 + \bar{z}}. \end{aligned}$$

Z toho dostaneme, že

$$|\lambda|^2 = \lambda\bar{\lambda} = \frac{z}{1+\bar{z}} \cdot \frac{\bar{z}}{1+z} = \frac{|z|^2}{1+z+\bar{z}+|z|^2}$$

a navyše

$$\begin{aligned} 1+z+\bar{z} &= 1+x^*L_1^T x + x^*L_1 x = x^*(I+L_1+L_1^T)x \\ &= x^*D^{-\frac{1}{2}}(D+L+L^T)D^{-\frac{1}{2}} \\ &= x^*D^{-\frac{1}{2}}AD^{-\frac{1}{2}}x > 0. \end{aligned}$$

Preto

$$|\lambda|^2 = \frac{|z|^2}{1+z+\bar{z}+|z|^2} < 1,$$

a teda aj $\|Q\|_2 = |\lambda|_{\max} < 1$.

Poznámka: Ak sa na výpočet Jacobiho metódou pozrieme po súradničach uvidíme, že j -ta súradnica riešenia v x^m sa spočíta ako

$$x_j^{(m)} = \frac{1}{a_{jj}}(b_j - \sum_{k \neq j} a_{jk}x_k^{(m-1)}). \quad (1)$$

To ale znamená, že v čase, keď počítame $x_j^{(m)}$ už poznáme $x_l^{(m)}$ pre $l < j$, čo sú súradnice zlepšeného riešenia. Ak tieto nové súradnice použijeme vo výpočte (1), t.j. rozdelíme sumu v zátvorke na $k < j$ a $k > j$ a v $k < j$ nahradíme $x_k^{(m-1)}$ novými súradnicami $x_k^{(m)}$, dostaneme

$$x_j^{(m)} = \frac{1}{a_{jj}} \left(b_j - \sum_{k < j} a_{jk}x_k^{(m)} - \sum_{k > j} a_{jk}x_k^{(m-1)} \right),$$

čo nie je ale nič iné ako Gaussova-Seidelova metóda. Ako si možno všimnúť

v prípade že niektorý prvok diagonálnej matice A je nulový, metódy zlyhajú (delenie prvkom a_{ii}). Tento problém možno obísť výmenou riadkov alebo stĺpcov, avšak za cenu straty konvergencie.

Ak by sme chceli všeobecný prípad $Ax = b$ previesť na symetrický $A^T Ax = A^T b$, môže sa stať, že $A^T A$ je zle podmienená ($c_2(A^T A) = c_2(A)^2$).

Metódy založené na minimalizácii kvadratickej formy

Pri týchto metódach hľadáme riešenie systému $Ax = b$ nepriamo ako minimum nejakej vhodnej definovanej funkcie $F(x)$. Ako príklady takých funkcií môžeme uviesť

$$F_1(x) = (b - Ax)^T(b - Ax),$$

alebo ak $r = b - Ax$ je reziduum a \bar{x} presné riešenie, tak

$$F_2(x) = (\bar{x} - x)^T(\bar{x} - x) = \Delta x^T \Delta x = (A^{-1}r)^T(A^{-1}r).$$

Symetrické, kladne definitné matice

Pre prípad systému $Ax = b$ so symetrickou a kladne definitnou maticou systému A môžeme definovať funkciu F ako

$$F(x) = \Delta x^T A \Delta x = (\bar{x} - x)^T A (\bar{x} - x).$$

Vďaka kladnej definitnosti máme $F(x) \geq 0$ a $F(x) = 0$ práve vtedy keď $x = \bar{x}$.

Ked'že

$$\begin{aligned} F(x) &= (\bar{x} - x)^T A (\bar{x} - x) = \bar{x}^T \underbrace{A \bar{x}}_b - x^T \underbrace{A \bar{x}}_b - \underbrace{\bar{x}^T A x}_{b^T} + x^T A x \\ &= x^T A x - 2b^T x + \bar{x}^T b \end{aligned}$$

a $\bar{x}^T b$ nezávisí od x , stačí minimalizovať funkciu

$$f(x) = x^T A x - 2b^T x$$

Samotný iteračný krok potom prebieha tak, že k už získanému riešeniu pripočítame vhodný $\alpha \in \mathbb{R}$ násobok nejakého vhodne zvoleného vektora v , čiže $x + \alpha v$ bude nové zlepšené odhad riešenia. To vedie k otázke, ako voliť α a v .

Najskôr predpokladajme, že v sme zvolili. Potom α je zrejme vhodné voliť tak, aby $x + \alpha v$ minimalizovalo funkciu f . Po dosadení $x - \alpha v$ dostaneme

$$\begin{aligned} g(\alpha) &= f(x + \alpha v) = (x + \alpha v)^T A (x + \alpha v) - 2b^T (x + \alpha v) = \\ &= \alpha^2 v^T A v + 2\alpha (v^T A x - b^T v) + x^T A x - 2b^T x \\ &= \alpha^2 v^T A v + 2\alpha v^T (Ax - b) + f(x) \\ &= \alpha^2 v^T A v - 2\alpha v^T r + f(x) \end{aligned}$$

čo je kvadratická funkcia premennej α , pričom $v^T A v > 0$, takže minimum g získame pre α splňajúce

$$g'(\alpha) = 2\alpha v^T A v - 2v^T r = 0,$$

teda pre

$$\alpha = \frac{v^T r}{v^T A v}$$

Iteračný proces teda môžeme zapísť ako

$$x^{(k)} = x^{(k-1)} + \alpha_k v^{(k)} = x^{(k-1)} + \frac{v^{(k)T} r^{(k-1)}}{v^{(k)T} A v^{(k)}} v \quad (2)$$

Ostáva už len určiť vektory $v^{(k)}$. Na zlepšovanie riešenia stačí, aby $\alpha_k \neq 0$, čo znamená, že

$$v^{(k)T} r^{(k-1)} \neq 0.$$

Vektory $v^{(k)}$ treba teda voliť tak, aby neboli kolmé na reziduá. Rôznym spôsobom voľby vektorov $v^{(k)}$ potom dostávame rôzne metódy.

Metóda najväčšieho spádu

Prirodzená voľba vektora v je zrejme smer, v ktorom sa funkcia $f(x)$ mení najviac. Keďže veľkosť zmeny meriame deriváciou, vektor v hľadáme tak, aby číslo

$$\lim_{t \rightarrow \infty} \frac{f(x + tv) - f(x)}{t}$$

bolo v absolútnej hodnote čo najväčšie. Počítajme teda:

$$\lim_{t \rightarrow \infty} \frac{f(x + tv) - f(x)}{t} = \left. \frac{df(x + tv)}{dt} \right|_{t=0} = g'(0) = -2v^T r = -2\|v\|_2 \|r\|_2 \cos \varphi.$$

Pri voľbe v tak, aby $\|v\|_2 = 1$ je toto číslo najväčšie pre $\varphi = 0$ (prípadne $\varphi = \pi$, ale v tom prípade α bude mať len opačné znamienko). Zvolíme teda $v = r$, takže v iteráciách $v^{(k)} = r^{(k-1)}$ a

$$x^{(k)} = x^{(k-1)} + \frac{r^{(k-1)T} r^{(k-1)}}{r^{(k-1)T} A r^{(k-1)}} v$$

Samotný algoritmus prebieha sa dá zhrnúť nasledovne

- $x = x^0$

- $r^{(k)} = b - Ax^{(k)}$; $\alpha_{k+1} = \frac{r^{(k)T}r^{(k)}}{r^{(k)T}Ar^{(k)}}$; $x^{(k+1)} = x^{(k)} + \alpha_{k+1}r^{(k)}$.

Pozrime sa teraz na rýchlosť konvergencie tejto metódy. Pomerne jednoducho sa dá ukázať, že

$$\frac{F(x^{(k+1)})}{F(x^{(k)})} = 1 - \frac{(r^{(k)T}r^{(k)})^2}{(r^{(k)T}Ar^{(k)})(r^{(k)T}A^{-1}r^{(k)})}. \quad (3)$$

V predchádzajúcim výraze označme $r = r^{(k)}$ a zapíšme r v báze ortonormálnych vlastných vektorov (x_1, \dots, x_n) , kde $Ax_i = \lambda_i x_i$. Potom $r = \sum_{i=1}^n \beta_i x_i$ a

$$\begin{aligned} (r^T r)^2 &= \left[\left(\sum_{i=1}^n \beta_i x_i^T \right) \left(\sum_{i=1}^n \beta_i x_i \right) \right]^2 = \left(\sum_{i=1}^n \beta_i^2 \right)^2, \\ (r^T Ar)^2 &= \left[\left(\sum_{i=1}^n \beta_i x_i^T \right) \left(\sum_{i=1}^n \beta_i \lambda_i x_i \right) \right]^2 = \sum_{i=1}^n \beta_i^2 \lambda_i, \\ (r^T A^{-1}r)^2 &= \left[\left(\sum_{i=1}^n \beta_i x_i^T \right) \left(\sum_{i=1}^n \beta_i \frac{1}{\lambda_i} x_i \right) \right]^2 = \sum_{i=1}^n \frac{\beta_i^2}{\lambda_i}. \end{aligned}$$

Po dosadení do (3) máme

$$\frac{F(x^{(k+1)})}{F(x^{(k)})} = 1 - \frac{(\sum_{i=1}^n \beta_i^2)^2}{(\sum_{i=1}^n \beta_i^2 \lambda_i) (\sum_{i=1}^n \frac{\beta_i^2}{\lambda_i})} = 1 - \frac{1}{H},$$

kde

$$H = \frac{(\sum_{i=1}^n \beta_i^2 \lambda_i) (\sum_{i=1}^n \frac{\beta_i^2}{\lambda_i})}{(\sum_{i=1}^n \beta_i^2) (\sum_{i=1}^n \beta_i^2)}$$

a pri označení $s = \sum_{i=1}^n \beta_i^2$

$$H = \left(\sum_{i=1}^n \frac{\beta_i^2 \lambda_i}{s} \right) \left(\sum_{i=1}^n \frac{\beta_i^2}{s \lambda_i} \right).$$

Toto číslo je možné odhadnúť použitím Kantorovičovej nerovnosti

Veta 2. Ak x_1, \dots, x_n sú kladné reálne čísla a $\gamma_1, \dots, \gamma_n \geq 0$, také, že $\sum_{i=1}^n \gamma_i = 1$, tak

$$\left(\sum_{i=1}^n \gamma_i x_i \right) \left(\sum_{i=1}^n \gamma_i x_i^{-1} \right) \leq \frac{(x_1 + x_n)^2}{4x_1 x_n}.$$

Z toho dostávame odhad

$$H = \left(\sum_{i=1}^n \frac{\beta_i^2 \lambda_i}{s} \right) \left(\sum_{i=1}^n \frac{\beta_i^2}{s \lambda_i} \right) \leq \frac{(\lambda_1 + \lambda_n)^2}{4\lambda_1 \lambda_n},$$

a potom

$$\frac{F(x^{(k+1)})}{F(x^{(k)})} \leq 1 - \frac{4\lambda_1 \lambda_n}{(\lambda_1 + \lambda_n)^2} = \left[\frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} \right].$$

Dá sa ukázať, že potom

$$\|\Delta x^{(k)}\|_2 \leq \left[\frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} \right]^k \|x^{(0)}\|_2 \sqrt{\frac{\lambda_1}{\lambda_n}}.$$

Takže pokiaľ λ_1 a λ_n sú rádovo blízke, metóda konverguje celkom rýchlo. Pokiaľ ale $\lambda_1 \gg \lambda_n$, čiže pre zle podmienené matice, môže byť konvergencia pomalá.

Poznámky: Rýchlosť algoritmu možno zlepšiť

1. $r^{(k+1)} = b - Ax^{(k+1)} = b - A(x^{(k)} + \alpha_{k+1}r^{(k)}) = (b - Ax^{(k)}) - \alpha_{k+1}Ar^{(k)}$
 $= r^{(k)} - \alpha_{k+1}Ar^{(k)}$, pričom $Ar^{(k)}$ počítame už pri α_{k+1} , čiže nemusíme počítať $Ax^{(k+1)}$.
2. $x^{(k+1)} = x^{(k)} + \omega_{k+1}\alpha_{k+1}x^{(k)}$, kde $\omega_{k+1} = \frac{\alpha_k}{\alpha_{k+1}}$.

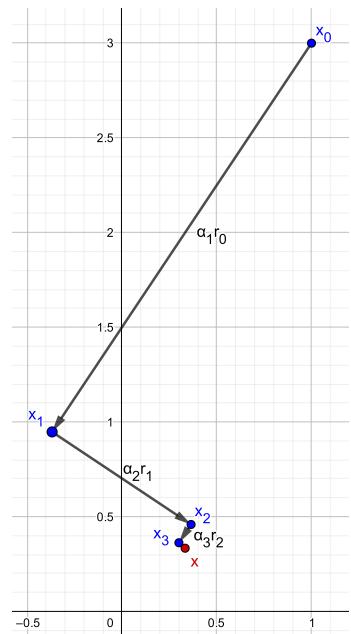
Čo si môžeme všimnúť je, že

$$\begin{aligned} r^{(k)T}r^{(k+1)} &= r^{(k)T}(r^{(k)} - \alpha_{k+1}Ar^{(k)}) = r^{(k)T}r^{(k)} - r^{(k)T}\frac{r^{(k)T}r^{(k)}}{r^{(k)T}Ar^{(k)}}Ar^{(k)} \\ &= r^{(k)T}r^{(k)} - r^{(k)T}r^{(k)}\frac{r^{(k)T}Ar^{(k)}}{r^{(k)T}Ar^{(k)}} = 0. \end{aligned}$$

Takže $r^{(k)T} \perp r^{(k+1)}$.

Nižšie je animácia a obrázok zobrazujúci tri iterácie prezentovanej metódy pre systém

$$\begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$



Obr. 1: Vľavo je animácia postupu výpočtu metódou najväčšieho spádu, vpravo sú zobrazené riešenia získaných z troch iterácií.