

0

Metoda konjugovaných gradientů

Luděk Kučera
MFF UK

11. ledna 2017

V tomto textu je popsáno, jak metodou konjugovaných gradientů řešit soustavu lineárních rovnic $\mathbf{Ax} = \mathbf{b}$, kde \mathbf{b} je daný vektor a \mathbf{A} je symetrická a pozitivně definitní reálná matice. Jedná se o metodu iterativní: vycházejíce z libovolného bodu \mathbf{x}_0 v příslušném Euklidovském prostoru, budeme postupně procházet (opakováním stále stejného výpočtu) body $\mathbf{x}_1, \mathbf{x}_2, \dots$, až se nakonec dostaneme do bodu, který je řešením soustavy, nebo alespoň tak blízko k němu, že nám daná hodnota bude vyhovovat jako přibližné řešení soustavy.

1 Řešení soustavy lineárních rovnic minimalizací kvadratického funkcionálu

Definujme funkcionál f takto:

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{Ax} - \mathbf{x}^T \mathbf{b} \quad \text{pro každé } \mathbf{x} \in E_n.$$

Lemma 1 *Řešení \mathbf{x}_{sol} soustavy $\mathbf{Ax} = \mathbf{b}$ je jediné minimum funkcionálu f .*

Důkaz: Uvažujme vektor $\mathbf{x} \in E_n$ a řešení \mathbf{x}_{sol} soustavy $\mathbf{Ax} = \mathbf{b}$ (*sol* jako ‘solution’, anglicky ‘řešení’). Položme $\mathbf{e} = \mathbf{x} - \mathbf{x}_{sol}$. Pak

$$\begin{aligned} f(\mathbf{x}) &= f(\mathbf{x}_{sol} + \mathbf{e}) = \frac{1}{2} (\mathbf{x}_{sol} + \mathbf{e})^T \mathbf{A} (\mathbf{x}_{sol} + \mathbf{e}) - (\mathbf{x}_{sol} + \mathbf{e})^T \mathbf{b} = \\ &= \frac{1}{2} (\mathbf{x}_{sol}^T \mathbf{A} \mathbf{x}_{sol} + \mathbf{x}_{sol}^T \mathbf{A} \mathbf{e} + \mathbf{e}^T \mathbf{A} \mathbf{x}_{sol} + \mathbf{e}^T \mathbf{A} \mathbf{e}) - \mathbf{x}_{sol}^T \mathbf{b} - \mathbf{e}^T \mathbf{b} = \\ &= \left(\frac{1}{2} \mathbf{x}_{sol}^T \mathbf{A} \mathbf{x}_{sol} - \mathbf{x}_{sol}^T \mathbf{b} \right) + \mathbf{e}^T \mathbf{A} \mathbf{e} + \mathbf{e}^T (\mathbf{A} \mathbf{x}_{sol} - \mathbf{b}) = f(\mathbf{x}_{sol}) + \mathbf{e}^T \mathbf{A} \mathbf{e}, \end{aligned}$$

protože $\mathbf{x}_{sol}^T \mathbf{A} \mathbf{e} = \mathbf{e}^T \mathbf{A} \mathbf{x}_{sol}$ a proto $\frac{1}{2} (\mathbf{x}_{sol}^T \mathbf{A} \mathbf{e} + \mathbf{e}^T \mathbf{A} \mathbf{x}_{sol}) = \mathbf{e}^T \mathbf{A} \mathbf{x}_{sol}$.

Jelikož je \mathbf{A} pozitivně definitní, je hodnota výrazu $\mathbf{e}^T \mathbf{A} \mathbf{e}$ vždy nezáporná a je rovna nule (své nejmenší možné hodnotě) právě když $\mathbf{e} = \mathbf{0}$, neboli když $\mathbf{x} = \mathbf{x}_{sol}$. ♣

2 Minimalizace funkcionálu v daném směru

Předpokládejme nyní, že se nacházíme v bodě \mathbf{x} a vydáme se z něj ve směru vektoru \mathbf{p} (vpřed nebo i vzad). Navštívíme tedy body $\mathbf{x} + \alpha\mathbf{p}$, kde α je reálné číslo. Naším cílem je určit, kde na této dráze má funkcionál f nejmenší hodnotu. Hodnota funkcionálu f na této dráze je

$$\begin{aligned} f(\mathbf{x} + \alpha\mathbf{p}) &= \frac{1}{2}(\mathbf{x} + \alpha\mathbf{p})^T \mathbf{A}(\mathbf{x} + \alpha\mathbf{p}) - (\mathbf{x} + \alpha\mathbf{p})^T \mathbf{b} = \\ &= \frac{1}{2}\mathbf{x}^T \mathbf{A}\mathbf{x} + \alpha\mathbf{p}^T \mathbf{A}\mathbf{x} + \frac{1}{2}\alpha^2 \mathbf{p}^T \mathbf{A}\mathbf{p} - \mathbf{x}^T \mathbf{b} - \alpha\mathbf{p}^T \mathbf{b} = U + \alpha V + \alpha^2 W, \end{aligned}$$

kde $U = \frac{1}{2}\mathbf{x}^T \mathbf{A}\mathbf{x} - \mathbf{x}^T \mathbf{b}$, $V = \mathbf{p}^T \mathbf{A}\mathbf{x} - \mathbf{p}^T \mathbf{b}$, $W = \frac{1}{2}\mathbf{p}^T \mathbf{A}\mathbf{p}$.

Pro pevné x a p jsou U , V a W konstanty a výraz pro $f(\mathbf{x} + \alpha\mathbf{p})$ je kvadratickou funkcí α . Je známo, že tato funkce má minimum, když se její derivace podle α rovná 0. Ta derivace je obecně rovna $2W\alpha + V$ a tedy minimum nabývá pro $\alpha = -\frac{V}{2W}$, neboli pro

$$\alpha = \frac{\mathbf{p}^T(\mathbf{b} - \mathbf{A}\mathbf{x})}{\mathbf{p}^T \mathbf{A} \mathbf{p}}.$$

Mimimum na dráze tvořené body $\mathbf{x} + \alpha\mathbf{p}$ je v bodě

$$\mathbf{x} + \frac{\mathbf{p}^T(\mathbf{b} - \mathbf{A}\mathbf{x})}{\mathbf{p}^T \mathbf{A} \mathbf{p}} \mathbf{p} \tag{1}$$

3 Směr největšího spádu

Dále si představme, že jsme v bodě \mathbf{x} a chceme se pustit směrem nejprudšího klesání funkcionálu f . Který to je směr?

Vezměme vektor \mathbf{e} délky 1 a vydejme se v jeho směru z bodu \mathbf{x} . Položme $\varphi(\alpha) = f(\mathbf{x} + \alpha\mathbf{e})$. Pro pevné \mathbf{e} je rychlosť změny funkcionálu f v bodě \mathbf{x} při pohybu ve směru \mathbf{e} rovna hodnotě derivace funkce φ podle α v bodě $\alpha = 0$. Propočítějme to:

$$\begin{aligned} \varphi(\alpha) &= f(\mathbf{x} + \alpha\mathbf{e}) = \frac{1}{2}\mathbf{x}^T \mathbf{A}\mathbf{x} + \alpha\mathbf{e}^T \mathbf{A}\mathbf{x} + \alpha^2 \mathbf{e}^T \mathbf{A}\mathbf{e} - \mathbf{x}^T \mathbf{b} - \alpha\mathbf{e}^T \mathbf{b} \\ \frac{\partial \varphi(\alpha)}{\partial \alpha} &= \mathbf{e}^T \mathbf{A}\mathbf{x} + 2\alpha\mathbf{e}^T \mathbf{A}\mathbf{e} - \mathbf{e}^T \mathbf{b} \end{aligned}$$

a tedy hodnota této derivace pro $\alpha = 0$ je

$$\left. \frac{\partial \varphi(\alpha)}{\partial \alpha} \right|_{\alpha=0} = \mathbf{e}^T \mathbf{A}\mathbf{x} - \mathbf{e}^T \mathbf{b} = -\mathbf{e}^T(\mathbf{b} - \mathbf{A}\mathbf{x}).$$

Nyní se zamysleme nad tím, v jakém směru je ta derivace nejmenší, tedy skalární součin $\mathbf{e}^T(\mathbf{b} - \mathbf{A}\mathbf{x})$ největší. Jasně, je to když \mathbf{e} jde ve směru $\mathbf{b} - \mathbf{A}\mathbf{x}$.

4 Metoda největšího spádu

Máme-li tedy nyní řešit rovnici $\mathbf{Ax} = \mathbf{b}$, stačí nalézt minimum funkcionálu $f(x) = \frac{1}{2}\mathbf{x}^T \mathbf{Ax} - \mathbf{x}^T \mathbf{b}$, které můžeme hledat iterativně takto: postavme se do libovolného bodu, který označíme \mathbf{x}_0 . Často se volí $\mathbf{x}_0 = \mathbf{0}$, nemáme-li nějaký dobrý důvod zvolit jiný bod. Vydejme se z tohoto bodu směrem největšího klesání funkcionálu f , tedy ve směru daném vektorem $\mathbf{r}_0 = \mathbf{b} - \mathbf{Ax}_0$. V tomto směru se posuneme tak hluboko (vzhledem k f), jak to jen jde. O kolikanásobek vektoru r se posuneme, je popsáno výše.

Postupem z předchozího odstavce se dostaneme do bodu, který označíme \mathbf{x}_1 a postup stále opakujeme. Jsme-li tedy obecně v bodě \mathbf{x}_i , položíme $\mathbf{r}_i = \mathbf{b} - \mathbf{Ax}_i$ (povšimněte si, že \mathbf{r}_i nám také udává, jak jsme daleko s výpočtem, jak je \mathbf{Ax}_i daleko od vektoru \mathbf{b} , kterému by se nakonec mělo rovnat), vydáme se ve směru r_i , dojdeme v tom směru do místa, ve kterém je funkcionál f nejnižší a to označíme jako \mathbf{x}_{i+1} , atd. Pokračujeme tak dlouho, dokud není \mathbf{r}_i (kterému se říkává *i*-té *residuum*, odtud označení \mathbf{r}_i) rovno nule (nalezeno řešení) nebo alespoň dostatečně malé (nalezeno dostatečně kvalitní přibližné řešení).

Tento metodě říkáme *metoda nejprudšího spádu* (anglicky “steepest descent”).

5 Metoda konjugovaných gradientů

V roce 1952 si Magnus Hestenes a Eduard Stiefel povšimli, že v elipsoidové geometrii pozitivně definitních matic je být výhodnější postupovat trochu jinak a lépe, než metodou nejprudšího spádu: způsobem, kterému se nyní říká metoda *konjugovaných gradientů* (anglicky “conjugate gradients”, odtud i zkratka CG).

Je dobře známo, že je-li \mathbf{A} pozitivně definitní a symetrická reálná matice, pak vzorec $\langle \mathbf{x}, \mathbf{y} \rangle = \mathbf{x}^T \mathbf{Ay}$ má vlastnosti skalárního součinu, tedy $\langle \mathbf{x}, \mathbf{x} \rangle \geq 0$ s rovností pouze pro $\mathbf{x} = \mathbf{0}$, operace je symetrická a $\langle \alpha \mathbf{x}, \mathbf{y} \rangle = \alpha \langle \mathbf{x}, \mathbf{y} \rangle$. Řekneme, že dva vektory \mathbf{x} a \mathbf{y} jsou *konjugované*, pokud platí $\langle \mathbf{x}, \mathbf{y} \rangle = 0$ (tedy jsou na sebe “kolmé” vzhledem ke skalárnímu součinu, určenému maticí \mathbf{A}).

Metoda konjugovaných gradientů postupuje velmi podobně jako metoda nejprudšího spádu, ale budeme se snažit, aby směry, ve kterých se v jednotlivých iteracích pohybujeme (gradienty), byly navzájem konjugované.

Postup začíná v libovolně zvoleném vektoru \mathbf{x}_0 a vytváří posloupnost $\mathbf{x}_0, \mathbf{r}_0, \mathbf{p}_k, \mathbf{x}_1, \mathbf{r}_1, \mathbf{p}_1, \dots$ následujícím způsobem:

Metoda konjugovaných gradientů (neupravená)

Vstupní data:

celé číslo n (dimenze)

symetrická pozitivně definitní matice \mathbf{A} velikosti $n \times n$,

vektor \mathbf{b} dimenze n (pravá strana soustavy),

počáteční vektor \mathbf{x}_0 .

pro $k = 0, 1, 2, \dots \{$

$$\mathbf{r}_k = \mathbf{b} - \mathbf{Ax}_k ; \quad \text{pokud } \mathbf{r}_k = \mathbf{0}, \text{ ukonči výpočet}; \quad (2)$$

$$\mathbf{p}_k = \mathbf{r}_k - \sum_{j=0}^{k-1} \frac{\mathbf{r}_k^T \mathbf{Ap}_j}{\mathbf{p}_j^T \mathbf{Ap}_j} \mathbf{p}_j ; \quad (3)$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \frac{\mathbf{p}_k^T \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{Ap}_k} \mathbf{p}_k ; \quad (4)$$

}

První krok se udělá stejně jako v metodě nejprudšího spádu; vyrazíme směrem \mathbf{p}_0 , který bude roven směru $\mathbf{r}_0 = \mathbf{b} - \mathbf{Ax}_0$. Když se ale dostaneme po k iteracích do bodu \mathbf{x}_k , nebudeme dál postupovat nejprudším spádem přesně ve směru residua $\mathbf{r}_k = \mathbf{b} - \mathbf{Ax}_k$, ale ve směru \mathbf{p}_k , který vznikne tak, že si směr \mathbf{r}_k upravíme tak, aby byl *konjugovaný* ke všem směrům $\mathbf{p}_0, \dots, \mathbf{p}_{k-1}$, ve kterých jsme se pohybovali dříve.

Tento pozměněný směr \mathbf{p}_k (\mathbf{p} od anglického ‘progress’) dostaneme z \mathbf{r}_k podobně jako při Gramm-Schmidtově ortogonalizaci tak, že od residua \mathbf{r}_k odečteme jeho složky v předchozích směrech $\mathbf{p}_0 = \mathbf{r}_0, \mathbf{p}_1, \dots, \mathbf{p}_{k-1}$, ale místo obvyklé kolmosti používáme “kolmost” ve smyslu skalárního součinu definovaného maticí \mathbf{A} , tedy konjugovanost.

Pro každé $j < k$ tedy chceme od vektoru \mathbf{r}_k odečíst takový násobek α_j vektoru \mathbf{p}_j , aby výsledek odečítání byl konjugovaný s \mathbf{p}_j . Pro hodnotu násobku α_j tedy máme následující rovnici: $(\mathbf{r}_k - \alpha_j \mathbf{p}_j)^T \mathbf{Ap}_j = \mathbf{0}$, neboli $\mathbf{r}_k^T \mathbf{Ap}_j = \alpha_j \mathbf{p}_j^T \mathbf{Ap}_j$, z čehož dostáváme

$$\alpha_j = \frac{\mathbf{r}_k^T \mathbf{Ap}_j}{\mathbf{p}_j^T \mathbf{Ap}_j}.$$

To nám tedy dává vzorec (3) pro \mathbf{p}_k , uvedený výše.

Jestliže je takto vzniklé \mathbf{p}_k nenulový vektor, přejdeme z \mathbf{x}_k ve směru daném vektorem \mathbf{p}_k do bodu \mathbf{x}_{k+1} , který minimalizuje funkcionál f na této prímce. Na základě (1) tedy se dostaneme ke vzorci (4) pro x_{k+1} , uvedenému výše.

Pokud by nastal případ, že \mathbf{r}_k je nulový vektor, výpočet se přeruší, protože v takovém případě \mathbf{x}_k je řešení soustavy $\mathbf{Ax} = \mathbf{b}$ a není nutno dále pokračovat.

Potíž při výpočtech by mohla nastat, pokud by se stalo, že $\mathbf{p}_k = \mathbf{0}$, protože hned v následujícím výpočtu \mathbf{x}_{k+1} ve vzorci (4) by došlo k dělení nulou. Za chvíli ale bude dokázáno, že k tomu nikdy nemůže dojít.

Nyní dokážeme tři jednoduchá lemmata, která budou mít řadu velmi důležitých důsledků.

Lemma 2 Pokud je \mathbf{p}_k definováno, pak je lineární kombinací vektorů $\mathbf{r}_0, \dots, \mathbf{r}_k$.

Důkaz: Lemma dokážeme indukcí podle k . Pro $k = 0$ tvrzení platí, protože $\mathbf{p}_0 = \mathbf{r}_0$. A jestliže platí pro $k - 1$, pak z (3) okamžitě plyne, že platí také pro k . ♣

Lemma 3 Pokud je \mathbf{r}_{k+1} definováno, pak

$$\mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k \mathbf{A} \mathbf{p}_k, \quad kde \quad \alpha_k = \frac{\mathbf{p}_k^T \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k}.$$

Důkaz: Na základě (4) je

$$\mathbf{x}_{k+1} - \mathbf{x}_k = \frac{\mathbf{p}_k^T \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k} \mathbf{p}_k,$$

takže

$$\mathbf{r}_{k+1} - \mathbf{r}_k = (\mathbf{b} - \mathbf{A} \mathbf{x}_{k+1}) - (\mathbf{b} - \mathbf{A} \mathbf{x}_k) = -(\mathbf{A} \mathbf{x}_{k+1} - \mathbf{A} \mathbf{x}_k) = -\frac{\mathbf{p}_k^T \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k} \mathbf{A} \mathbf{p}_k.$$

♣

Lemma 4 (Rezidua jsou na sebe kolmá)

Nechť pro nějaké celé nezáporné číslo k platí, že \mathbf{x}_j a \mathbf{r}_j jsou definována a $\mathbf{r}_j \neq \mathbf{0}$ pro všechna $j = 0, 1, \dots, k$ a navíc $\mathbf{r}_i^T \mathbf{r}_j = 0$ pro všechna celá i a j taková, že $0 \leq i < j \leq k$.

Potom $\mathbf{p}_k \neq \mathbf{0}$, také \mathbf{x}_{k+1} a \mathbf{r}_{k+1} jsou řádně definovány a $\mathbf{r}_{k+1}^T \mathbf{r}_j = 0$ pro $j = 0, 1, \dots, k$.

Důkaz: Jelikož jsou rezidua $\mathbf{r}_0, \dots, \mathbf{r}_k$ nenulová a navzájem kolmá, jsou také lineárně nezávislá. Suma v rovnici (3) je lineární kombinací vektorů $\mathbf{p}_0, \dots, \mathbf{p}_{k-1}$ a tedy na základě předchozího lemmatu také lineární kombinací vektorů $\mathbf{r}_0, \dots, \mathbf{r}_{k-1}$. Podle (3) je tedy \mathbf{p}_k netriviální lineární kombinací vektorů $\mathbf{r}_0, \dots, \mathbf{r}_k$. Proto \mathbf{p}_k nemůže být nulový vektor. A je-li $\mathbf{p}_k \neq \mathbf{0}$, pak jsou také definovány vektory \mathbf{x}_{k+1} a \mathbf{r}_{k+1} .

Nakonec spočítejme hodnotu $\mathbf{r}_{k+1}^T \mathbf{r}_j$ pro zvolené celé j v rozmezí $0 \leq j \leq k$:

$$\mathbf{r}_{k+1}^T \mathbf{r}_j = (\mathbf{r}_k - \alpha_k \mathbf{A} \mathbf{p}_k)^T \mathbf{r}_j = \mathbf{r}_k^T \mathbf{r}_j - \alpha_k \mathbf{p}_k^T \mathbf{A} \left(\mathbf{p}_j + \sum_{i=0}^{j-1} \frac{\mathbf{r}_j^T \mathbf{A} \mathbf{p}_i}{\mathbf{p}_i^T \mathbf{A} \mathbf{p}_i} \mathbf{p}_i \right) = \mathbf{r}_k^T \mathbf{r}_j - \alpha_k \mathbf{p}_k^T \mathbf{A} \mathbf{p}_j,$$

kde

$$\alpha_k = \frac{\mathbf{p}_k^T \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k},$$

protože \mathbf{p}_k bylo zvoleno tak, aby platilo $\mathbf{p}_k^T \mathbf{A} \mathbf{p}_i = 0$ pro $i < k$.

Víme nyní, že pro $j < k$

$$\mathbf{p}_j^T \mathbf{r}_k = r_j - \sum_{i=0}^{j-1} \frac{\mathbf{r}_j^T \mathbf{A} \mathbf{p}_i}{\mathbf{p}_i^T \mathbf{A} \mathbf{p}_k} \mathbf{p}_i = \mathbf{r}_j^T \mathbf{r}_k,$$

a

$$\mathbf{p}_k^T \mathbf{r}_k = (\mathbf{r}_k - \sum_{j=0}^{k-1} \frac{\mathbf{r}_k^T \mathbf{A} \mathbf{p}_j}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_k} \mathbf{p}_j)^T \mathbf{r}_k = \mathbf{r}_k^T \mathbf{r}_k.$$

Jestliže nyní $j < k$, pak z předpokladů věty plyne, že $\mathbf{r}_k^T \mathbf{r}_j = 0$ a $\mathbf{p}_k^T \mathbf{A} \mathbf{p}_j = 0$, takže i $\mathbf{r}_{k+1}^T \mathbf{r}_j = 0$. Pokud naopak $j = k$, pak

$$\mathbf{r}_k^T \mathbf{r}_j - \alpha_k \mathbf{p}_k^T \mathbf{A} \mathbf{p}_j = \mathbf{r}_k^T \mathbf{r}_k - \mathbf{p}_k^T \mathbf{r}^k = \mathbf{r}_k^T \mathbf{r}_k - \mathbf{r}_k^T \mathbf{r}^k = 0.$$



Lemma říká, že residua jsou na sebe kolmá v klasickém smyslu (obvyklý skalární součin), nikoli konjugovaná (skalární součin indukovaný maticí \mathbf{A}).

Jední z velmi významných důsledků lemmatu je následující věta (je třeba poznamenat, že platí za předpokladu, že všechny výpočty se provádějí absolutně přesně, bez zaokrouhlovacích chyb):

Věta 1 Metoda konjugovaných gradientů naleze přesné řešení soustavy rovnic $\mathbf{Ax} = \mathbf{b}$ po nejvýše n krocích.

Důkaz: Kdyby se metoda konjugovaných gradientů nezastavila po n krocích, vytvořila by nenulové vektory $\mathbf{r}_0, \mathbf{r}_1, \dots, \mathbf{r}_n$, které by ale podle předchozího lemmatu byly na sebe kolmé, tedy lineárně nezávislé, což však v prostoru dimenze n není možné. ♣

Další velmi užitečné lemma říká, že ve vzorci (3) pro výpočet \mathbf{p}_k jsou všechny sčítance v sumě s výjimkou sčítance pro $j = k - 1$ rovny nule, takže je tento vzorec možno velice zjednodušit:

Lemma 5

$$\begin{aligned} \mathbf{r}_k^T \mathbf{A} \mathbf{p}_j &= 0 \quad \text{pro } j = 0, \dots, k-2 \\ \frac{\mathbf{r}_{k+1}^T \mathbf{A} \mathbf{p}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k} &= \frac{\mathbf{r}_{k+1}^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k} \end{aligned}$$

Důkaz: Na základě lemmatu 30 platí, že

$$\begin{aligned} \mathbf{r}_k^T \mathbf{A} \mathbf{p}_j &= \mathbf{r}_k^T \left(-\frac{1}{\alpha_{j-1}} (\mathbf{r}_j - \mathbf{r}_{j-1}) \right) = 0 \quad \text{pro } j = 0, 1, \dots, k-2 \\ \frac{\mathbf{r}_{k+1}^T \mathbf{A} \mathbf{p}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k} &= \frac{\mathbf{r}_{k+1}^T \mathbf{A} \mathbf{p}_{k-1}}{\alpha_{k-1} \mathbf{p}_{k-1}^T \mathbf{A} \mathbf{p}_{k-1}} = \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_{k-1}^T \mathbf{r}_{k-1}} \end{aligned}$$



Důsledek 1

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k, \quad kde \quad \beta_k = \frac{\mathbf{r}_{k+1}^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k}$$

Důkaz: ♣

Metoda konjugovaných gradientů (s indexy)

Vstupní data:

celé číslo n (dimenze)

symetrická pozitivně definitní matice \mathbf{A} velikosti $n \times n$,

vektor \mathbf{b} dimenze n (pravá strana soustavy),

počáteční vektor \mathbf{x}_0 .

$$\mathbf{r}_0 = \mathbf{b} - \mathbf{Ax}_0 ;$$

$$\mathbf{p}_0 = \mathbf{r}_0 ;$$

pro $k = 0, 1, 2, \dots \{$

$$\mathbf{z}_k = \mathbf{Ap}_k ;$$

$$\alpha_k = \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{z}_k} ;$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k ;$$

$$\mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k \mathbf{z}_k; \quad \text{pokud } \mathbf{r}_k = \mathbf{0}, \text{ ukonči výpočet};$$

$$\beta_k = \frac{\mathbf{r}_{k+1}^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k} ;$$

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k ;$$

}

Metoda konjugovaných gradientů (konečný tvar)

Vstupní data:

celé číslo n (dimenze)

symetrická pozitivně definitní matice \mathbf{A} velikosti $n \times n$,

vektor \mathbf{b} dimenze n (pravá strana soustavy),

počáteční vektor \mathbf{x}_0 .

$$\mathbf{r} = \mathbf{b} - \mathbf{Ax}_0 ;$$

$$lrr = \mathbf{r}^T \mathbf{r};$$

$$\mathbf{p} = \mathbf{r} ;$$

pro $k = 0, 1, 2, \dots \{$

$$\mathbf{z} = \mathbf{Ap} ;$$

$$\alpha = \frac{lrr}{\mathbf{p}^T \mathbf{z}} ;$$

$$\mathbf{x} = \mathbf{x} + \alpha \mathbf{p} ;$$

$$\mathbf{r} = \mathbf{r} - \alpha \mathbf{z}; \quad \text{pokud } \mathbf{r} = \mathbf{0}, \text{ ukonči výpočet};$$

$$rr = \mathbf{r}^T \mathbf{r} ;$$

$$\beta = \frac{rr}{lrr} ;$$

$$lrr = rr$$

$$\mathbf{p} = \mathbf{r} + \beta \mathbf{p} ;$$

}