

Metoda konjugiranih gradijenata

1 Uvod u problem

Zadani su simetrična i pozitivno definitna kvadratna matrica $\mathbf{A} \in \mathbb{R}^{n \times n}$, realni vektor $\mathbf{b} \in \mathbb{R}^n$ te $c \in \mathbb{R}$. Definirajmo funkciju $f: \mathbb{R}^n \rightarrow \mathbb{R}$ formulom $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} + c$ te promatrajmo sljedeći problem:

$$f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} + c \rightarrow \min_{\mathbf{x} \in \mathbb{R}^n}. \quad (1)$$

Neka je $\mathbf{x}^* = \operatorname{argmin}_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$ rješenje problema (1). Uočimo da je

$$\nabla f(\mathbf{x}) = \mathbf{A} \mathbf{x} - \mathbf{b} \text{ te } \nabla^2 f(\mathbf{x}) = \mathbf{A}.$$

Kako je prema pretpostavci matrica \mathbf{A} pozitivno definitna, te stoga i regularna (vidi Domaću zadaću), vektor \mathbf{x}^* jedinstveno rješenje sustava linearnih jednadžbi

$$\mathbf{A} \mathbf{x} = \mathbf{b}. \quad (2)$$

To znači da je problem minimizacije (1) ekvivalentan problemu rješavanju sustava linearnih jednadžbi (2).

Neka su $\alpha \in \mathbb{R}$ i $\mathbf{p} \in \mathbb{R}^n$. Razvojem izraza $f(\mathbf{x} + \alpha \mathbf{p})$ u Taylorov red u okolini točke \mathbf{x} dobivamo

$$f(\mathbf{x} + \alpha \mathbf{p}) = f(\mathbf{x}) + \alpha \mathbf{p}^T \nabla f(\mathbf{x}) + \frac{1}{2} \alpha^2 \mathbf{p}^T \nabla^2 f(\mathbf{x}) \mathbf{p} = f(\mathbf{x}) + \alpha \mathbf{p}^T (\mathbf{A} \mathbf{x} - \mathbf{b}) + \frac{1}{2} \alpha^2 \mathbf{p}^T \mathbf{A} \mathbf{p}.$$

Minimizacijski problem (1) rješavat ćemo iterativnom metodom. Pretpostavimo u tu svrhu da je \mathbf{x}_j neka aproksimacija rješenja \mathbf{x}^* . Novu aproksimaciju \mathbf{x}_{j+1} tražit ćemo u obliku $\mathbf{x}_{j+1} = \mathbf{x}_j + \alpha_j \mathbf{p}_j$, pri čemu je \mathbf{p}_j vektor smjera, a α_j odgovarajuća duljina koraka. Ako nam je poznat vektor smjera \mathbf{p}_j onda duljinu optimalnu duljinu koraka α_j možemo dobiti rješavanjem problema jednodimenzionalne minimizacije

$$f(\mathbf{x}_j + \alpha \mathbf{p}_j) \rightarrow \min_{\alpha \in \mathbb{R}}.$$

Imamo

$$\begin{aligned} \alpha_j &= \operatorname{argmin}_{\alpha \in \mathbb{R}} f(\mathbf{x}_j + \alpha \mathbf{p}_j) \\ &= \operatorname{argmin}_{\alpha \in \mathbb{R}} \left(f(\mathbf{x}_j) + \alpha \mathbf{p}_j^T (\mathbf{A} \mathbf{x}_j - \mathbf{b}) + \frac{1}{2} \alpha^2 \mathbf{p}_j^T \mathbf{A} \mathbf{p}_j \right). \end{aligned}$$

Funkcija $\alpha \mapsto f(\mathbf{x}_j) + \alpha \mathbf{p}_j^T (\mathbf{A} \mathbf{x}_j - \mathbf{b}) + \frac{1}{2} \alpha^2 \mathbf{p}_j^T \mathbf{A} \mathbf{p}_j$ je realna kvadratna funkcija, koja postiže jedinstveni globalni minimum u točki

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

1.0.1 Gradijentna metoda


Specijalno u gradijentnoj metodi za vektor smjera \mathbf{p}_j uzimamo $\mathbf{p}_j = -\nabla f(\mathbf{x}_j) = -\mathbf{A}\mathbf{x}_j + \mathbf{b}$, odakle je

$$\alpha_j^* = \frac{\|\mathbf{A}\mathbf{x} - \mathbf{b}\|_2^2}{(\mathbf{b} - \mathbf{A}\mathbf{x}_j)^T \mathbf{A}(\mathbf{b} - \mathbf{A}\mathbf{x}_j)} = \frac{\|\mathbf{p}_j\|_2^2}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_j}.$$

Za vektor smjera \mathbf{p}_{j+1} vrijedi

$$\begin{aligned} \mathbf{p}_{j+1} &= -\nabla f(\mathbf{x}_{j+1}) = \mathbf{b} - \mathbf{A}\mathbf{x}_{j+1} \\ &= \mathbf{b} - \mathbf{A}(\mathbf{x}_j + \alpha_j \mathbf{p}_j) \\ &= \mathbf{p}_j - \alpha_j \mathbf{A} \mathbf{p}_j, \end{aligned}$$

odakle je



Slika 1: Vektori smjerova gradijentne metode kroz 17 iteracija

$$\mathbf{p}_{j+1}^T \mathbf{p}_j = \|\mathbf{p}_j\|_2^2 - \alpha_j \mathbf{p}_j^T \mathbf{A} \mathbf{p}_j = 0.$$

To znači da je kod gradijentne metode vektor smjera u koraku $j+1$ ortogonalan s vektorom smjera u koraku j .

Primjer 1. Zadana je funkcija $f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x}$, gdje su

$$\mathbf{A} = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}.$$

Jednostavno se vidi da je $\mathbf{x}^* = \left[\frac{1}{3}, \frac{1}{3}\right]^T$ rješenje sustava linearnih jednadžbi. Pretpostavimo da gradijentnom metodom želimo odrediti točku globalnog minimuma funkcije f . U tu svrhu za početnu aproksimaciju uzimamo $\mathbf{x}_0 = [5, -2]^T$. Gradijentnu metodu izvršavamo sve do je $\|\mathbf{A}\mathbf{x}_j - \mathbf{b}\|_2 \geq \varepsilon$, $j = 0, 1, 2, \dots$. Ako je $\varepsilon = 10^{-4}$ gradijentnom metodom za 17 koraka dobivamo $\mathbf{x}_{17} = [0.333351, 0.333298]^T$. Na Slici 1 prikazani su odgovarajući vektori smjerova gradijentne metode.

2 Metoda konjugiranih gradijenata

Prirodna ideja je definirati vektore smjerova najbržeg silaska i to tako da metoda završi u što manje koraka. Pokazat ćemo da metoda konjugiranih gradijenata ima upravo to svojstvo te da završi u najviše n koraka.

Za simetričnu pozitivno definitnu matricu \mathbf{A} definiramo preslikavanje $s : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$, formulom

$$s(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \mathbf{A} \mathbf{y}. \quad (3)$$

Može se pokazati da je preslikavanje s skalarni produkt kojeg označavamo s $s(\mathbf{x}, \mathbf{y}) =: \langle \mathbf{x}, \mathbf{y} \rangle_{\mathbf{A}}$ (vidi Domaću zadaću) i zovemo \mathbf{A} -skalarni produkt. Pri tome odgovarajuća normu definiramo s $\|\mathbf{x}\|_{\mathbf{A}} := \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$.

Definicija 1. Kažemo da su vektori $\mathbf{p}_0, \dots, \mathbf{p}_{k-1}$ \mathbf{A} -konjugirani ili \mathbf{A} -ortogonalni, ako vrijedi da je $\mathbf{p}_j^T \mathbf{A} \mathbf{p}_i$ za svaki $i, j = 1, \dots, k-1$ te $i \neq j$.

Uočimo da je zbog simetričnosti dovoljno zahtijevati $\mathbf{p}_j^T \mathbf{A} \mathbf{p}_i = 0$ za svaki $0 \leq i < j \leq k-1$. Može se pokazati da je svaki skup $\{\mathbf{p}_j : j = 0, \dots, k-1\}$, \mathbf{A} -konjugiranih vektora linearno nezavisan (vidi Domaću zadaću) te stoga možemo definirati potprostor

$$W_k = \begin{cases} \text{span}\{\mathbf{p}_0, \dots, \mathbf{p}_{k-1}\}, & k \geq 1 \\ \{\mathbf{0}\}, & k = 0 \end{cases},$$

te skup

$$U_k := \begin{cases} \mathbf{x}_0 + W_k = \{\mathbf{z} \in \mathbb{R}^n : \mathbf{z} = \mathbf{x}_0 + \mathbf{w}_k \in W_k\}, & k \geq 1 \\ \{\mathbf{x}_0\}, & k = 0. \end{cases}$$

Propozicija 1. Neka je i fiksni prirodni broj te neka su $\{\mathbf{p}_0, \dots, \mathbf{p}_{i-1}, \mathbf{p}_i\}$ vektori takvi da je

$$\mathbf{p}_i^T \mathbf{A} \mathbf{p}_j = 0, \quad (4)$$

za svaki $j = 0, \dots, i-1$. Prepostavimo da je $\mathbf{x}_0 \in \mathbb{R}^n$ te $\mathbf{x}_j \in \mathbb{R}^n$, $j = 1, \dots, i-1$ niz vektora definiran rekurzivno s

$$\mathbf{x}_{j+1} = \mathbf{x}_j + \alpha_j \mathbf{p}_j,$$

$$\alpha_j = \operatorname{argmin}_{\alpha \in \mathbb{R}} f(\mathbf{x}_j + \alpha \mathbf{p}_j) = -\frac{\mathbf{p}_j^T (\mathbf{A} \mathbf{x}_j - \mathbf{b})}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_j} = -\frac{\mathbf{p}_j^T \mathbf{r}_j}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_j},$$

gdje su $\mathbf{r}_j := \mathbf{A} \mathbf{x}_j - \mathbf{b}$, $j = 0, \dots, i-1$. Tada vrijedi

$$\mathbf{p}_i^T \mathbf{r}_i = \mathbf{p}_i^T (\mathbf{A} \mathbf{y} - \mathbf{b}), \text{ za svaki } \mathbf{y} \in U_i.$$

Dokaz. Uočimo da je

$$\mathbf{x}_i = \mathbf{x}_{i-1} + \alpha_{i-1} \mathbf{p}_{i-1} = \mathbf{x}_{i-2} + \alpha_{i-2} \mathbf{p}_{i-2} + \alpha_{i-1} \mathbf{p}_{i-1} = \dots = \mathbf{x}_0 + \sum_{j=1}^{i-1} \alpha_j \mathbf{p}_j \in U_i.$$

Za proizvoljni $\mathbf{y} \in U_i$ vrijedi da je $\mathbf{x}_i - \mathbf{y} \in W_i$ te stoga zbog svojstva (4) vrijedi $\mathbf{p}_i^T \mathbf{A} (\mathbf{x}_i - \mathbf{y}) = 0$. Konačno slijedi

$$\mathbf{p}_i^T (\mathbf{r}_i - \mathbf{A} \mathbf{y} + \mathbf{b}) = \mathbf{p}_i^T (\mathbf{A} \mathbf{x}_i - \mathbf{b} - \mathbf{A} \mathbf{y} + \mathbf{b}) = \mathbf{p}_i^T \mathbf{A} (\mathbf{x}_i - \mathbf{y}) = 0,$$

odakle slijedi tvrdnja.

U sljedeće teoremu pokazat ćemo da ako za vektore smjerova odaberemo \mathbf{A} -konjugirane vektore, onda jednodimenzionalna minimizacija duž vektora \mathbf{p}_{k-1} (odnosno traženje vektora \mathbf{x}_k) odgovara minimizaciji duž cijelog skupa U_k .

Teorem 1. *Neka je $\mathbf{x}_0 \in \mathbb{R}^n$ te $\mathbf{x}_{j+1} = \mathbf{x}_j + \alpha_j \mathbf{p}_j$, $j = 0, \dots, k-1$, pri čemu su vektori smjerova \mathbf{p}_j , $j = 0, \dots, k-1$ \mathbf{A} -konjugirani te $\alpha_j \in \mathbb{R}$ odgovarajuće duljine koraka. Onda je*

$$\mathbf{x}_j = \operatorname{argmin}_{\mathbf{x} \in U_j} f(\mathbf{x}), \quad j = 1, \dots, k.$$

Dokaz. Tvrdnju dokazujemo metodom matematičke indukcije po k . Ako je $k = 1$, onda je $\mathbf{x}_1 = \mathbf{x}_0 + \alpha_0 \mathbf{p}_0$, gdje je $\alpha_0 = -\frac{\mathbf{p}_0^T \mathbf{r}_0}{\mathbf{p}_0^T \mathbf{A} \mathbf{p}_0}$, točka globalnog minimuma funkcije f na skupu $U_1 = \{\mathbf{x}_0 + \mathbf{w}_1 : \mathbf{w}_1 \in W_1 = \operatorname{span}\{\mathbf{p}_0\}\}$. Pretpostavimo da tvrdnja vrijedi za prirodni broj $k = i$, tj. da je

$$\mathbf{x}_j = \operatorname{argmin}_{\mathbf{y} \in U_j} f(\mathbf{y}),$$

za svaki $j = 1, \dots, i$. Dokažimo da tvrdnja vrijedi za $k = i + 1$ tj. da iz $\mathbf{x}_{i+1} = \mathbf{x}_i + \alpha_i \mathbf{p}_i$ slijedi da je

$$\mathbf{x}_{i+1} = \operatorname{argmin}_{\mathbf{x} \in U_{i+1}} f(\mathbf{x}).$$

Iz definicije skupa U_{i+1} slijedi da se svaki $\mathbf{x} \in U_{i+1}$ može zapisati u obliku $\mathbf{x} = \mathbf{y} + \alpha \mathbf{p}_i$, pri čemu je $\alpha \in \mathbb{R}$ te $\mathbf{y} \in U_i$ te je stoga

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

odakle prema Propoziciji 1 slijedi da je

$$f(\mathbf{x}) = f(\mathbf{y}) + \alpha \mathbf{p}_i^T (\mathbf{A} \mathbf{x}_i - \mathbf{b}) + \frac{1}{2} \alpha^2 \mathbf{p}_i^T \mathbf{A} \mathbf{p}_i.$$

Konačno imamo

$$\min_{\mathbf{x} \in U_{i+1}} f(\mathbf{x}) = \min_{\mathbf{y} \in U_i} f(\mathbf{y}) + \min_{\alpha \in \mathbb{R}} \left(\alpha \mathbf{p}_i^T (\mathbf{A} \mathbf{x}_i - \mathbf{b}) + \frac{1}{2} \alpha^2 \mathbf{p}_i^T \mathbf{A} \mathbf{p}_i \right).$$

Prema pretpostavci indukcije slijedi da je $\operatorname{argmin}_{\mathbf{y} \in U_i} f(\mathbf{y}) = \mathbf{x}_i$. Također slijedi da je

$$\operatorname{argmin}_{\alpha \in \mathbb{R}} \left(\alpha \mathbf{p}_i^T (\mathbf{A} \mathbf{x}_i - \mathbf{b}) + \frac{1}{2} \alpha^2 \mathbf{p}_i^T \mathbf{A} \mathbf{p}_i \right) = -\frac{\mathbf{p}_i^T \mathbf{r}_i}{\mathbf{p}_i^T \mathbf{A} \mathbf{p}_i} = \alpha_i,$$

odakle slijedi tvrdnja.

U sljedećoj Propoziciji pokazat ćemo kako iz vektora reziduala \mathbf{r}_j , $j = 1, \dots, k$, konstruirati \mathbf{A} -konjugirane smjerove.

Propozicija 2. *Neka je $\mathbf{p}_0 = -\mathbf{r}_0$ te*

$$\mathbf{p}_k = -\mathbf{r}_k + \sum_{j=0}^{k-1} \frac{\mathbf{p}_j^T \mathbf{A} \mathbf{r}_k}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_j} \mathbf{p}_j, \quad k = 1, 2, \dots \quad (5)$$

Onda je $\mathbf{p}_j^T \mathbf{A} \mathbf{p}_m = 0$ za svaki $0 \leq m < j \leq k$.

Dokaz. Tvrdnju dokazujemo metodom matematičke indukcije po k . Za $k = 1$ imamo

$$\mathbf{p}_1^T \mathbf{A} \mathbf{p}_0 = \left(-\mathbf{r}_1 + \frac{\mathbf{p}_0^T \mathbf{A} \mathbf{r}_1}{\mathbf{p}_0^T \mathbf{A} \mathbf{p}_0} \mathbf{p}_0 \right)^T \mathbf{A} \mathbf{p}_0 = -\mathbf{r}_1^T \mathbf{A} \mathbf{p}_0 + \mathbf{p}_0^T \mathbf{A} \mathbf{p}_0 \frac{\mathbf{p}_0^T \mathbf{A} \mathbf{r}_1}{\mathbf{p}_0^T \mathbf{A} \mathbf{p}_0} = 0.$$

Pretpostavimo da tvrdnja vrijedi za prirodni broj $k = i$, odnosno da su vektori $\mathbf{p}_0, \dots, \mathbf{p}_i$ A -konjugirani. Dokažimo da tvrdnja vrijedi za za $k = i + 1$ tj. da je $\mathbf{p}_{i+1}^T \mathbf{A} \mathbf{p}_m = 0$ za svaki $m \leq i$. Neka je m prirodni broj koji je manji od i . Onda je

$$\begin{aligned} \mathbf{p}_{i+1}^T \mathbf{A} \mathbf{p}_m &= -\mathbf{r}_{i+1}^T \mathbf{A} \mathbf{p}_m + \sum_{j=0}^i \frac{\mathbf{p}_j^T \mathbf{A} \mathbf{r}_{i+1}}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_j} \mathbf{p}_j^T \mathbf{A} \mathbf{p}_m \\ &= -\mathbf{r}_{i+1}^T \mathbf{A} \mathbf{p}_m + \frac{\mathbf{p}_m^T \mathbf{A} \mathbf{r}_{i+1}}{\mathbf{p}_m^T \mathbf{A} \mathbf{p}_m} \mathbf{p}_m^T \mathbf{A} \mathbf{p}_m = 0. \end{aligned}$$

U sljedećoj propoziciji pokazat ćemo da se konjugirani smjerovi mogu računati jednostavnije.

Propozicija 3. *Pretpostavimo da su $\mathbf{p}_0, \dots, \mathbf{p}_k$ smjerovi dobiveni rekurzivno s (5). Onda je*

- $W_k = \text{span}\{\mathbf{r}_0, \dots, \mathbf{r}_{k-1}\}$
- $\mathbf{r}_m^T \mathbf{r}_j = 0$ za svaki $0 \leq j < m \leq k$
- $\mathbf{p}_k^T \mathbf{r}_j = -\mathbf{r}_k^T \mathbf{r}_k$ za svaki $0 \leq j \leq k$
- Za vektor smjera \mathbf{p}_k vrijedi

$$\mathbf{p}_k = -\mathbf{r}_k + \beta_{k-1} \mathbf{p}_{k-1}, \quad \text{gdje je } \beta_{k-1} = \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_{k-1}^T \mathbf{r}_{k-1}}.$$

- Vrijedi $W_k = \text{span}\{\mathbf{r}_0, \dots, \mathbf{A}^{k-1} \mathbf{r}_0\}$

Dokaz. Dokazat ćemo tvrdnju d). U tu svrhu vektor $\mathbf{p}_k \in W_{k+1}$ zapišimo kao linearnu kombinaciju vektora $\mathbf{r}_0, \dots, \mathbf{r}_k$. Sukladno svojstvu b) vektori $\mathbf{r}_0, \dots, \mathbf{r}_k$ čine ortogonalnu bazu od W_{k+1} . Vrijedi

$$\mathbf{p}_k = \sum_{j=0}^k \alpha_j \mathbf{r}_j,$$

pri čemu se iz uvjeta ortogonalnosti vektora $\mathbf{r}_0, \dots, \mathbf{r}_k$ slijedi da je $\alpha_j = \frac{\mathbf{p}_k^T \mathbf{r}_j}{\mathbf{r}_j^T \mathbf{r}_j}$, $j = 0, \dots, k$.

Prema svojstvu c) vrijedi

$$\begin{aligned} \mathbf{p}_k &= -\sum_{j=0}^k \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_j^T \mathbf{r}_j} \mathbf{r}_j = -\mathbf{r}_k - \sum_{j=0}^{k-1} \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_j^T \mathbf{r}_j} \mathbf{r}_j = -\mathbf{r}_k - \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_{k-1}^T \mathbf{r}_{k-1}} \sum_{j=0}^{k-1} \frac{\mathbf{r}_{k-1}^T \mathbf{r}_{k-1}}{\mathbf{r}_j^T \mathbf{r}_j} \mathbf{r}_j \\ &= -\mathbf{r}_k + \beta_{k-1} \sum_{j=0}^{k-1} \frac{\mathbf{p}_{k-1}^T \mathbf{r}_j}{\mathbf{r}_j^T \mathbf{r}_j} \mathbf{r}_j = -\mathbf{r}_k + \beta_{k-1} \mathbf{p}_{k-1}. \end{aligned} \quad (6)$$

Posljednja jednakost u (6) iz raspisa vektora \mathbf{p}_{k-1} u ortogonalnoj bazi $\{\mathbf{r}_0, \dots, \mathbf{r}_{k-1}\}$.

Na osnovi prethodnih tvrdnji proizlazi sljedeći algoritam.

ALGORITAM - KONJUGIRANI GRADIJENTI

- $\mathbf{r}_0 = \mathbf{A}\mathbf{x}_0 - \mathbf{b}$, $\mathbf{p}_0 = -\mathbf{r}_0$, $k = 0$

- While $\mathbf{r}_k \neq \mathbf{0}$ do

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

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

$$\mathbf{r}_{k+1} = \mathbf{r}_k + \alpha_k \mathbf{A} \mathbf{p}_k$$

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


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

$$k = k + 1$$

- end While

Primjedba 1. Ako je $\mathbf{A} \in \mathbb{R}^{n \times n}$, onda će zbog ortogonalnosti vektora reziduala iterativni postupak završiti u konačno mnogo (najviše n koraka).

Primjer 2. Na Slici 2 prikazana je usporedba iterativnih procesa gradijentnom metodom te metodom konjugiranih gradijenata na minimizaciji funkcije iz Primjera 1.



Slika 2: Usporedba vektora smjerova gradijentne metode (crno) i metode konjugiranih gradijenata (crveno)

2.1 Brzina konvergencije

Može se pokazati da brzina konvergencije metode konjugiranih gradijenata ovisi o broju uvjetovanosti matrice \mathbf{A} , preciznije da vrijedi sljedeća tvrdnja.

Teorem 2. (vidi Quarterioni et al (2000)) Ako je \mathbf{x}^* egzaktno rješenje sustava linearnih jednačini $\mathbf{Ax} = \mathbf{b}$, gdje je $\mathbf{A} \in \mathbb{R}^{n \times n}$ pozitivno definitna matrica te $\mathbf{b} \in \mathbb{R}^n$ te \mathbf{x}_k aproksimacija rješenja dobivena u k -toj iteraciji gradijentne metode. Vrijedi sljedeća ocjena

$$\|\mathbf{x}^* - \mathbf{x}_k\|_{\mathbf{A}} \leq \left(\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right) \|\mathbf{x}^* - \mathbf{x}_0\|_{\mathbf{A}},$$

pri čemu je κ broj uvjetovanosti matrice \mathbf{A} .

Teorem 3. (vidi Luenberger (1993)) Ako je \mathbf{x}^* egzaktno rješenje sustava linearnih jednačini $\mathbf{Ax} = \mathbf{b}$, gdje je $\mathbf{A} \in \mathbb{R}^{n \times n}$ pozitivno definitna matrica te $\mathbf{b} \in \mathbb{R}^n$ te \mathbf{x}_k aproksimacija rješenja dobivena u k -toj iteraciji metode konjugiranih gradijenata. Vrijedi sljedeća ocjena

$$\|\mathbf{x}^* - \mathbf{x}_k\|_{\mathbf{A}} \leq 2 \left(\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^k \|\mathbf{x}^* - \mathbf{x}_0\|_{\mathbf{A}},$$

pri čemu je κ broj uvjetovanosti matrice \mathbf{A} .

Teorem 4. (vidi Quarterioni et al (2000)) Ako je \mathbf{x}^* egzaktno rješenje sustava linearnih jednačini $\mathbf{Ax} = \mathbf{b}$, gdje je $\mathbf{A} \in \mathbb{R}^{n \times n}$ pozitivno definitna matrica te $\mathbf{b} \in \mathbb{R}^n$ te \mathbf{x}_k aproksimacija rješenja dobivena u k -toj iteraciji metode konjugiranih gradijenata. Vrijedi sljedeća ocjena

$$\|\mathbf{x}^* - \mathbf{x}_k\|_{\mathbf{A}} \leq 2 \frac{c^k}{1 + c^{2k}} \|\mathbf{x}^* - \mathbf{x}_0\|_{\mathbf{A}},$$

pri čemu je $c = \frac{\sqrt{\kappa}-1}{\sqrt{\kappa}+1}$ te κ broj uvjetovanosti matrice \mathbf{A} .

3 Proširenje na nelinearne funkcije

Metodu konjugiranih gradijenata moguće je proširiti i na nelinearne funkcije (vidi primjerice Quarterioni et al (2000)). U nastavku navodimo nekoliko modifikacija metode koje su prilagođene za nelinearne funkcije.

ALGORITAM FLETCHER-REEVES METHOD

- 1 $\mathbf{r}_0 = \nabla f(\mathbf{x}_0)$, $\mathbf{p}_0 = -\mathbf{r}_0$

- 2 For $k = 0, 1, \dots, n - 1$ do

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k, \text{ gdje je } \alpha_k = \operatorname{argmin}_{\alpha \in \mathbb{R}} f(\mathbf{x}_k + \alpha \mathbf{p}_k)$$

$$\mathbf{r}_{k+1} = \nabla f(\mathbf{x}_{k+1})$$

$$\mathbf{p}_{k+1} = -\mathbf{r}_k + \beta_k \mathbf{p}_k, \text{ gdje je } \beta_k = \frac{\mathbf{r}_{k+1}^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k}$$

3 $\mathbf{x}_0 = \mathbf{x}_n$ i skoči na korak 1.

ALGORITAM POLAK-RIBIERE METODA

Analogno kao Fletcher-Reeves method, razlika je u β_k :

$$\beta_k = \frac{(\mathbf{r}_{k+1} - \mathbf{r}_k)^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k}.$$

Najčešći izbor u $\beta_k = \max\{0, \frac{(\mathbf{r}_{k+1} - \mathbf{r}_k)^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k}\}$.

HESTENES-STIEFEL METODA Analogno kao Fletcher-Reeves method, razlika je u β_k :

$$\beta_k = \frac{(\mathbf{r}_{k+1} - \mathbf{r}_k)^T \mathbf{r}_{k+1}}{\mathbf{p}_k^T (\mathbf{r}_{k+1} - \mathbf{r}_k)}$$

4 Domaća zadaća

Zadatak 1. Dokažite da je svaka pozitivno definitna matrica $\mathbf{M} \in \mathbb{R}^{n \times n}$ regularna.

Zadatak 2. Neka je $\mathbf{A} \in \mathbb{R}^{n \times n}$ pozitivno definitna i simetrična matrica. Dokažite da je preslikavanje $s : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$ zadano s $s(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \mathbf{A} \mathbf{y}$ skalarni produkt na \mathbb{R}^n .

Zadatak 3. Neka su $\mathbf{A} = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}$, $\mathbf{x}_0 = [0, 0]^T$ i $r = 3$. Prikažite skup

$$K_{\mathbf{A}}(\mathbf{x}_0, r) = \{\mathbf{x} \in \mathbb{R}^2 : \|\mathbf{x} - \mathbf{x}_0\|_{\mathbf{A}} \leq r\}.$$

Zadatak 4. Neka je $\mathbf{A} \in \mathbb{R}^{n \times n}$ te neka je $\{\mathbf{p}_j \in \mathbb{R}^n : j = 0, \dots, k-1\}$ skup \mathbf{A} -konjugiranih vektora. Dokažite da su vektori \mathbf{p}_j , $j = 0, \dots, k-1$ linearno nezavisni.

Zadatak 5. Zadani su pozitivno definitna matrica $\mathbf{A} \in \mathbb{R}^{n \times n}$, vektori $\mathbf{b} \in \mathbb{R}^n$ te $\mathbf{x}_0 \in \mathbb{R}^n$. Definiramo $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k$, $\alpha_k = -\frac{\mathbf{r}_k^T \mathbf{p}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k}$, $\mathbf{r}_k = \mathbf{A} \mathbf{x}_k - \mathbf{b}$, $k = 1, 2, \dots$. Pretpostavimo da su $\mathbf{p}_0, \dots, \mathbf{p}_k$ vektori dobiveni na sljedeći način

$$\mathbf{p}_0 = -\mathbf{r}_0, \quad \mathbf{p}_k = -\mathbf{r}_k + \sum_{j=0}^{k-1} \frac{\mathbf{p}_j^T \mathbf{A} \mathbf{r}_k}{\mathbf{p}_j^T \mathbf{A} \mathbf{p}_j} \mathbf{p}_j, \quad k = 1, 2, \dots$$

Dokažite da vrijedi

- $W_k := \text{span}\{\mathbf{p}_0, \dots, \mathbf{p}_{k-1}\} = \text{span}\{\mathbf{r}_0, \dots, \mathbf{r}_{k-1}\}$
- $\mathbf{r}_m^T \mathbf{r}_j = 0$ za svaki $0 \leq j < m \leq k$
- $\mathbf{p}_k^T \mathbf{r}_j = -\mathbf{r}_k^T \mathbf{r}_k$ za svaki $0 \leq j \leq k$
- $W_k = \text{span}\{\mathbf{r}_0, \dots, \mathbf{A}^{k-1} \mathbf{r}_0\}$

Zadatak 6. Prilagodite metodu konjugiranih gradijenata za minimizaciju nelinearne funkcije, tako da koristite ideju modificirane Wolfove metode jednodimenzionalne minimizacije prema članku ?. Metodu ilustrirajte na primjerima različitih nelinearnih funkcija.

Literatura

A. Quarteroni, R. Sacco, F. Saleri, Numerical Mathematics, Springer-Verlag New York, 2000

D. G. Luenberger, Intro. to Linear & Nonlinear Programming, Addison-Wesley, 1993

Gaohang Yu, Lutai Guan, Zengxin Wei, *Globally convergent Polak–Ribière–Polyak conjugate gradient methods under a modified Wolfe line search*, Applied Mathematics and Computation, **215** (2009), 3082–3090