

Metody numeryczne

Uzupełnienie: Prewarunkowana metoda gradientów sprzężonych

P. F. Góra

https://zfs.fais.uj.edu.pl/pawel_gora

2025

“Prewarunkowana” (*preconditioned*) metoda gradientów sprzężonych

Założmy, że rozwiązujemy równanie

$$\mathbf{Ax} = \mathbf{b}, \quad (1)$$

przy czym macierz \mathbf{A} jest symetryczna, dodatnio określona i rzadka. Sugeruje to użycie (algebraicznej) metody gradientów sprzężonych. Jeśli jednak macierz \mathbf{A} jest źle uwarunkowana, zbieżność może być bardzo wolna.

Spróbujmy przyspieszyć zbieżność odpowiednio modyfikując równanie (1) i algorytm gradientów sprzężonych, jednak tak, aby

- nie zmienić rozwiązania,
- macierz zmodyfikowanego układu pozostała symetryczna i dodatnio określona, aby można było zastosować metodę gradientów sprzężonych,

- macierz zmodyfikowanego układu pozostała rzadka, aby jeden krok iteracji był numerycznie tani,
- macierz zmodyfikowanego układu miała niski współczynnik uwarunkowania.

Czy to się w ogóle da zrobić? **Okazuje się, że tak!**

Postępujemy następująco: Niech $\mathbf{C} \in \mathbb{R}^{N \times N}$ będzie odwracalną macierzą symetryczną, rzeczywistą, dodatnio określoną. Wówczas $\widetilde{\mathbf{A}} = \mathbf{C}^{-1}\mathbf{A}\mathbf{C}^{-1}$ też jest symetryczna, rzeczywista, dodatnio określona.

$$\mathbf{C}^{-1}\mathbf{A}\underbrace{\mathbf{C}^{-1}\mathbf{C}}_{\mathbb{I}}\mathbf{x} = \mathbf{C}^{-1}\mathbf{b}, \quad (2a)$$

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

gdzie $\widetilde{\mathbf{x}} = \mathbf{C}\mathbf{x}$, $\widetilde{\mathbf{b}} = \mathbf{C}^{-1}\mathbf{b}$. Do równania (2b) stosujemy teraz metodę gradientów sprzężonych.

W każdym kroku iteracji musimy obliczyć (tylde, bo odnosi się to do “tyldowanego” układu (2b))

$$\alpha_k = \frac{\tilde{\mathbf{r}}_k^T \tilde{\mathbf{r}}_k}{\tilde{\mathbf{p}}_k^T \tilde{\mathbf{A}} \tilde{\mathbf{p}}_k} = \frac{\tilde{\mathbf{r}}_k^T \tilde{\mathbf{r}}_k}{\tilde{\mathbf{p}}_k^T \mathbf{C}^{-1} \mathbf{A} \mathbf{C}^{-1} \tilde{\mathbf{p}}_k}, \quad (3a)$$

$$\tilde{\mathbf{r}}_{k+1} = \tilde{\mathbf{r}}_k - \alpha_k \tilde{\mathbf{A}} \tilde{\mathbf{p}}_k = \tilde{\mathbf{r}}_k - \alpha_k \mathbf{C}^{-1} \mathbf{A} \mathbf{C}^{-1} \tilde{\mathbf{p}}_k, \quad (3b)$$

$$\beta_k = \frac{\tilde{\mathbf{r}}_{k+1}^T \tilde{\mathbf{r}}_{k+1}}{\tilde{\mathbf{r}}_k^T \tilde{\mathbf{r}}_k}, \quad (3c)$$

$$\tilde{\mathbf{p}}_{k+1} = \tilde{\mathbf{r}}_{k+1} + \beta_k \tilde{\mathbf{p}}_k, \quad (3d)$$

$$\tilde{\mathbf{x}}_{k+1} = \tilde{\mathbf{x}}_k + \alpha_k \tilde{\mathbf{p}}_k. \quad (3e)$$

Równania (3) zawierają jawne odniesienia do macierzy \mathbf{C}^{-1} , co nie jest zbyt wygodne. Łatwo się przekonać, iż za pomocą prostych przekształceń macierz tę można „usunąć”, tak, iż pozostaje tylko jedno jej nietrywialne wystąpienie. Zdefiniujmy mianowicie

$$\tilde{\mathbf{r}}_k = \mathbf{C}^{-1}\mathbf{r}_k, \quad \tilde{\mathbf{p}}_k = \mathbf{C}\mathbf{p}_k, \quad \tilde{\mathbf{x}}_k = \mathbf{C}\mathbf{x}_k. \quad (4)$$

W tej sytuacji $\tilde{\mathbf{r}}_k^T \tilde{\mathbf{r}}_k = (\mathbf{C}^{-1}\mathbf{r}_k)^T \mathbf{C}^{-1}\mathbf{r}_k = \mathbf{r}_k^T (\mathbf{C}^{-1})^T \mathbf{C}^{-1}\mathbf{r}_k = \mathbf{r}_k^T \mathbf{C}^{-1}\mathbf{C}^{-1}\mathbf{r}_k = \mathbf{r}_k^T (\mathbf{C}^{-1})^2 \mathbf{r}_k$ etc.

Wówczas równania (3) przechodzą w

$$\alpha_k = \frac{\mathbf{r}_k^T (\mathbf{C}^{-1})^2 \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k}, \quad (5a)$$

$$\mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k \mathbf{A} \mathbf{p}_k, \quad (5b)$$

$$\beta_k = \frac{\mathbf{r}_{k+1}^T (\mathbf{C}^{-1})^2 \mathbf{r}_{k+1}}{\mathbf{r}_k^T (\mathbf{C}^{-1})^2 \mathbf{r}_k}, \quad (5c)$$

$$\mathbf{p}_{k+1} = (\mathbf{C}^{-1})^2 \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k, \quad (5d)$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k. \quad (5e)$$

W powyższych równaniach rola macierzy C sprowadza się do obliczenia — *jeden raz w każdym kroku iteracji* — wyrażenia $(C^{-1})^2 r_k$, co, jak wiadomo, robi się rozwiązując odpowiedni układ równań. Zdefiniujmy

$$M = C^2. \quad (6)$$

Macierz M należy rzecz jasna dobrać tak, aby równanie $Mz = r$ można było szybko rozwiązać.

Ostatecznie otrzymujemy następujący algorytm:

$$\mathbf{r}_1 = \mathbf{b} - \mathbf{A}\mathbf{x}_1$$

$$\text{rozwiąż } \mathbf{M}\mathbf{z}_1 = \mathbf{r}_1$$

$$\mathbf{p}_1 = \mathbf{z}_1$$

$$\text{while } \|\mathbf{r}_k\| > \varepsilon$$

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

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

$$\text{rozwiąż } \mathbf{M}\mathbf{z}_{k+1} = \mathbf{r}_{k+1}$$

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

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

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

end

(7)

Incomplete Cholesky preconditioner

Niech rozkład QR macierzy C ma postać $C = QH^T$, gdzie Q jest macierzą ortogonalną, H^T jest macierzą trójkątną górną. Zauważmy, że

$$M = C^2 = C^T C = (QH^T)^T QH^T = HQ^T QH^T = HH^T, \quad (8)$$

a więc macierz H jest czynnikiem Cholesky'ego macierzy M . Niech rozkład Cholesky'ego macierzy A ma postać $A = GG^T$. *Przypuśćmy, iż $H \simeq G$.*

Wówczas

$$\begin{aligned}\tilde{\mathbf{A}} &= \mathbf{C}^{-1} \mathbf{A} \mathbf{C}^{-1} = (\mathbf{C}^T)^{-1} \mathbf{A} \mathbf{C}^{-1} = \left((\mathbf{Q} \mathbf{H}^T)^T \right)^{-1} \mathbf{A} (\mathbf{Q} \mathbf{H}^T)^{-1} = \\ &= (\mathbf{H} \mathbf{Q}^T)^{-1} \mathbf{A} (\mathbf{H}^T)^{-1} \mathbf{Q}^T = \mathbf{Q} \underbrace{\mathbf{H}^{-1} \mathbf{G}}_{\simeq \mathbb{I}} \underbrace{\mathbf{G}^T (\mathbf{H}^T)^{-1}}_{\simeq \mathbb{I}} \mathbf{Q}^T \simeq \mathbf{Q} \mathbf{Q}^T = \mathbb{I}.\end{aligned}\tag{9}$$

Ponieważ $\tilde{\mathbf{A}} \simeq \mathbb{I}$, współczynnik uwarunkowania tej macierzy powinien być bliski jedności.

W tym momencie mamy spełnione następujące warunki zadane na stronie 2:

- Macierz $\widetilde{\mathbf{A}}$ jest symetryczna i dodatnio określona;
- Rozwiązania się nie zmieniły, gdyż algorytm (7) jest *formalnie* równoważny algorytmowi gradientów sprzężonych;
- Mamy nadzieję (☺), że macierz $\widetilde{\mathbf{A}}$ jest dobrze uwarunkowana, gdyż $\widetilde{\mathbf{A}} \simeq \mathbf{I}$.

Pozostaje tylko zagwarantowanie, że jeżeli \mathbf{A} jest rzadka, to także czynnik Cholesky'ego macierzy $\mathbf{M} = \mathbf{H}\mathbf{H}^T$ jest rzadki.

Niepełny rozkład Cholesky'ego — algorytm w wersji *GAXPY*

```
for    $k = 1:N$   
       $H_{kk} = A_{kk}$   
      for    $j = 1:k-1$   
             $H_{kk} = H_{kk} - H_{kj}^2$   
      end  
       $H_{kk} = \sqrt{H_{kk}}$   
      for    $l = k+1:N$   
             $H_{lk} = A_{lk}$   
            if    $A_{lk} \neq 0$   
                  for    $j = 1:k-1$   
                         $H_{lk} = H_{lk} - H_{lj}H_{kj}$   
                  end  
                   $H_{lk} = H_{lk}/H_{kk}$   
            endif  
      end  
end
```

Uwagi

- Ponieważ A jest rzadka, powyższy algorytm na obliczanie przybliżonego czynnika Cholesky'ego wykonuje się szybko. Wykonuje się go *tylko raz*.
- Równanie $Mz = r$ rozwiązuje się szybko, gdyż znamy czynnik Cholesky'ego $M = HH^T$.
- Obliczone H jest rzadkie, a zatem równanie $Mz = r$ rozwiązuje się szczególnie szybko.
- Mamy nadzieję, że macierz \tilde{A} ma współczynnik uwarunkowania bliski jedności, a zatem nie potrzeba wielu iteracji (7).

Przykład — macierz pasmowa z pustymi diagonalami

Rozważmy macierz o następującej strukturze:

$$\mathbf{A} = \begin{bmatrix} a_1 & 0 & b_3 & 0 & c_5 & 0 & 0 & 0 & 0 & 0 & \dots \\ 0 & a_2 & 0 & b_4 & 0 & c_6 & 0 & 0 & 0 & 0 & \dots \\ b_3 & 0 & a_3 & 0 & b_5 & 0 & c_7 & 0 & 0 & 0 & \dots \\ 0 & b_4 & 0 & a_4 & 0 & b_6 & 0 & c_8 & 0 & 0 & \dots \\ c_5 & 0 & b_5 & 0 & a_5 & 0 & b_7 & 0 & c_9 & 0 & \dots \\ 0 & c_6 & 0 & b_6 & 0 & a_6 & 0 & b_8 & 0 & c_{10} & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix} \quad (10)$$

Macierz ta jest symetryczna, zakładamy też, że jest dodatnio określona.

Niepełny czynnik Cholesky'ego macierzy (10) ma postać

$$\mathbf{H} = \begin{bmatrix} p_1 & & & & & & \\ 0 & p_2 & & & & & \\ q_3 & 0 & p_3 & & & & \\ 0 & q_4 & 0 & p_4 & & & \\ r_5 & 0 & q_5 & 0 & p_5 & & \\ 0 & r_6 & 0 & q_6 & 0 & p_6 & \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix} \quad (11)$$

(W *pełnym* czynniku Cholesky'ego macierzy (10) zera leżące w (11) *po- między* diagonalą “*p*” a diagonalną “*r*” znikłyby — w ogólności mogłyby tam znajdować się jakieś niezerowe liczby.)

Zgodnie z podanym algorytmem, elementy ciągów $\{p_k\}$, $\{q_k\}$, $\{r_k\}$ wyliczamy z następujących wzorów:

$$\begin{array}{ll}
 p_1 = \sqrt{a_1}, & p_2 = \sqrt{a_2}, \\
 q_3 = b_3/p_1, & q_4 = b_4/p_2, \\
 r_5 = c_5/p_1, & r_6 = c_6/p_2, \\
 p_3 = \sqrt{a_3 - q_3^2}, & p_4 = \sqrt{a_4 - q_4^2}, \\
 q_5 = (b_5 - r_5q_3)/p_3, & q_6 = (b_6 - r_6q_4)/p_4, \\
 r_7 = c_7/p_3, & r_8 = c_7/p_4, \\
 p_5 = \sqrt{a_5 - q_5^2 - r_5^2}, & p_6 = \sqrt{a_6 - q_5^2 - r_6^2}, \\
 q_7 = (b_7 - r_7q_5)/p_5, & q_8 = (b_8 - r_8q_6)/p_6, \\
 r_9 = c_9/p_5, & r_{10} = c_{10}/p_6, \\
 p_7 = \sqrt{a_7 - q_7^2 - r_7^2}, & p_8 = \sqrt{a_8 - q_8^2 - r_8^2}, \\
 q_9 = (b_9 - r_9q_7)/p_7, & q_{10} = (b_{10} - r_{10}q_8)/p_8, \\
 r_{11} = c_{11}/p_7, & r_{12} = c_{12}/p_8, \\
 \dots & \dots
 \end{array}$$

Macierze niesymetryczne

Jeżeli w równaniu

$$\mathbf{Ax} = \mathbf{b} \quad (12)$$

macierz \mathbf{A} nie jest symetryczna i dodatnio określona, sytuacja się komplikuje. Zakładając, że $\det \mathbf{A} \neq 0$, równanie (12) możemy “zsymetryzować” na dwa sposoby.

CGNR:

$$\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}, \quad (13)$$

lub CGNE:

$$\mathbf{AA}^T \mathbf{y} = \mathbf{b}, \quad (14a)$$

$$\mathbf{x} = \mathbf{A}^T \mathbf{y}. \quad (14b)$$

Do dwu powyższych równań formalnie rzecz biorąc *można* używać metody gradientów sprzężonych. Trzeba jednak pamiętać, że nawet jeśli macierz \mathbf{A} jest rzadka, macierze $\mathbf{A}^T \mathbf{A}$, $\mathbf{A} \mathbf{A}^T$ nie muszą być rzadkie, a co gorsza, ich współczynnik uwarunkowania jest kwadratem współczynnika uwarunkowania macierzy wyjściowej.

Alternatywnie, zamiast “symetryzować” macierz, można zmodyfikować algorytm, tak aby zamiast dwu, generował on *cztery* ciągi wektorów. Należy jednak pamiętać, że dla wielu typów macierzy taki algorytm bywa bardzo wolno zbieżny, a niekiedy nawet dochodzi do kompletnej stagnacji przed uzyskaniem rozwiązania:

Metoda gradientów bi-sprzężonych (*Bi-Conjugate Gradients, Bi-CG*)

$$\begin{aligned} & \mathbf{r}_1 = \mathbf{b} - \mathbf{A}\mathbf{x}_1, \mathbf{p}_1 = \mathbf{r}_1, \bar{\mathbf{r}}_1 \neq 0 \text{ dowolny}, \bar{\mathbf{p}}_1 = \bar{\mathbf{r}}_1 \\ \mathbf{while} \quad & \|\mathbf{r}_k\| > \varepsilon \\ & \alpha_k = \frac{\bar{\mathbf{r}}_k^T \mathbf{r}_k}{\bar{\mathbf{p}}_k^T \mathbf{A}\mathbf{p}_k} \\ & \mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k \mathbf{A}\mathbf{p}_k \\ & \bar{\mathbf{r}}_{k+1} = \bar{\mathbf{r}}_k - \alpha_k \mathbf{A}^T \bar{\mathbf{p}}_k \\ & \beta_k = \frac{\bar{\mathbf{r}}_{k+1}^T \mathbf{r}_{k+1}}{\bar{\mathbf{r}}_k^T \mathbf{r}_k} \\ & \mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k \\ & \bar{\mathbf{p}}_{k+1} = \bar{\mathbf{r}}_{k+1} + \beta_k \bar{\mathbf{p}}_k \\ & \mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k \\ \mathbf{end} \end{aligned} \tag{15}$$

Wektory wygenerowane w algorytmie (15) spełniają następujące relacje:

$$\bar{\mathbf{r}}_i^T \mathbf{r}_j = \mathbf{r}_i^T \bar{\mathbf{r}}_j = 0, \quad i > j, \quad (16a)$$

$$\bar{\mathbf{r}}_i^T \mathbf{p}_j = \mathbf{r}_i^T \bar{\mathbf{p}}_j = 0, \quad i > j, \quad (16b)$$

$$\bar{\mathbf{p}}_i^T \mathbf{A} \mathbf{p}_j = \mathbf{p}_i^T \mathbf{A}^T \bar{\mathbf{p}}_j = 0, \quad i > j. \quad (16c)$$

Jeżeli w algorytmie (15) weźmiemy $\bar{\mathbf{r}}_1 = \mathbf{A} \mathbf{r}_1$, we wszystkich krokach zachodzić będzie $\bar{\mathbf{r}}_k = \mathbf{A} \mathbf{r}_k$ oraz $\bar{\mathbf{p}}_k = \mathbf{A} \mathbf{p}_k$. Jest to wersja przydatna dla rozwiązywania układów równań z macierzami symetrycznymi, ale nieokreślonymi dodatnio. Jest to przy okazji szczególny wariant algorytmu GMRES (*generalised minimum residual*), formalnie odpowiadającego minimalizacji funkcjonału

$$\Phi(\mathbf{x}) = \frac{1}{2} \|\mathbf{A} \mathbf{x} - \mathbf{b}\|^2. \quad (17)$$