

Iteračné metódy riešenia lineárnych sústav na báze Krylovových podpriestorov

Ing. Gabriel Okša, CSc.

Matematický ústav
Slovenská akadémia vied
Bratislava

Stavebná fakulta STU

Obsah

- 1 Všeobecná projekčná metóda
- 2 Krylovov podpriestor
- 3 Arnoldiho metóda
- 4 Generalized Minimum Residual Method (GMRES)
- 5 Symetrická Lanczosova metóda
- 6 Metóda konjugovaných gradientov (CG)
- 7 Predpodmienenie ('preconditioning') pre CG

Všeobecná projekčná metóda

- **Úloha:** nájsť riešenie sústavy lineárnych rovníc:

$$Ax = b, \quad A \in \mathbb{C}^{n \times n}, \quad x, b \in \mathbb{C}^{n \times 1}$$

- **Všeobecná projekčná metóda** hľadá aproximáciu \tilde{x} z afinného podpriestoru $x_0 + \mathcal{K}$ s dimenziou m (x_0 je ľubovoľný počiatočný odhad), pričom má byť splnená **Petrovova-Galerkinova podmienka**

$$b - A\tilde{x} \perp \mathcal{L},$$

kde \mathcal{L} je ďalší tzv. **testovací** podpriestor s dimenziou m .

- Nech $\tilde{x} = x_0 + \delta$, $\delta \in \mathcal{K}$, a $r_0 \equiv b - Ax_0$ (počiatočné rezíduum). Potom Petrovova-Galerkinova podmienka má tvar:

$$(r_0 - A\delta, w) = 0 \quad \forall w \in \mathcal{L},$$

kde $r_{\text{new}} \equiv r_0 - A\delta$ je nové rezíduum. Toto je základný projekčný krok.

Všeobecná projekčná metóda

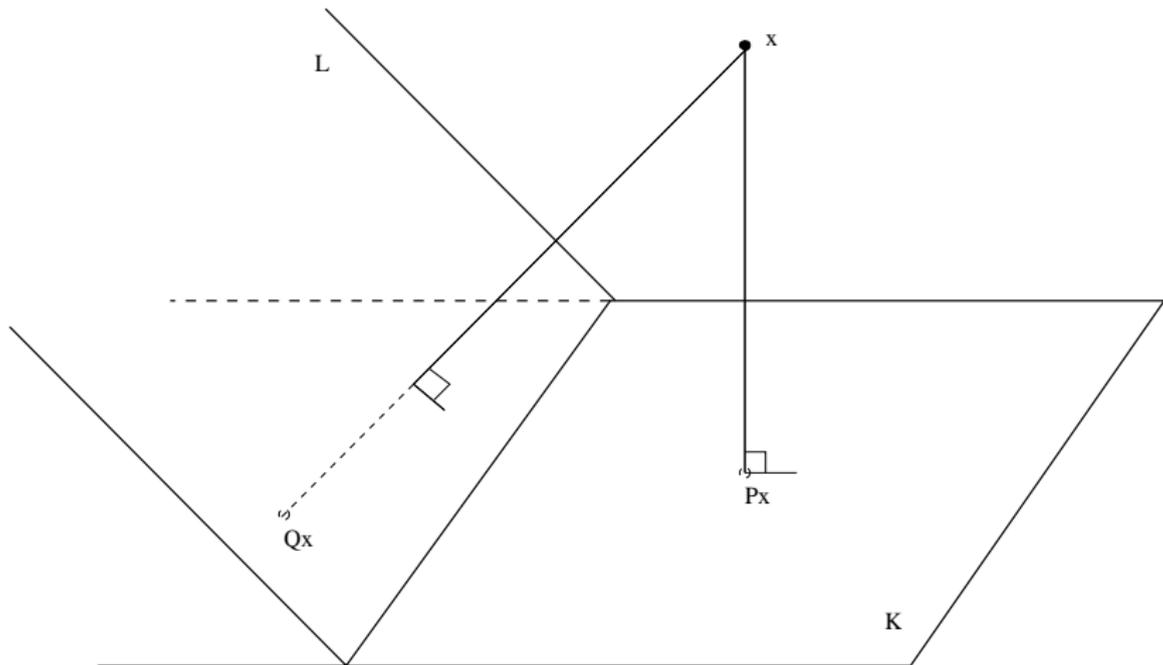
- **Maticová reprezentácia:** Nech $V = [v_1, \dots, v_m]$ je báza \mathcal{K} a $W = [w_1, \dots, w_m]$ je báza \mathcal{L} . Potom $\tilde{x} = x_0 + Vy$ a y je riešenie rovnice $W^T AVy = W^T r_0$.
- Nech A je SPD a $\mathcal{L} = \mathcal{K}$. Potom vektor \tilde{x} je výsledkom ortogonálnej projekcie na \mathcal{K} s počiatočným vektorom x_0 práve vtedy, ak

$$E(\tilde{x}) = \min_{x \in x_0 + \mathcal{K}} E(x), \quad E(x) \equiv (A(x_* - x), x_* - x)^{1/2},$$

kde x_* je riešenie sústavy $Ax = b$.

- Nech A je regulárna a $\mathcal{L} = A\mathcal{K}$. Potom vektor \tilde{x} je výsledkom šikmej projekcie na \mathcal{K} ortogonálne vzhľadom na \mathcal{L} s počiatočným vektorom x_0 práve vtedy, ak

$$R(\tilde{x}) = \min_{x \in x_0 + \mathcal{K}} R(x), \quad R(x) \equiv \|b - Ax\|.$$



Orthogonal projector P and oblique projector Q on subspace K

Figure: Ortoponálny (P) a šikmý (Q) projektor na podpriestor K s využitím podpriestoru L .

Krylovov podpriestor

- **Krylovov podpriestor:**

$\mathcal{K}_m = \mathcal{K}_m(A, r_0) = \text{span}\{r_0, Ar_0, A^2r_0, \dots, A^{m-1}r_0\}$, kde $r_0 \equiv b - Ax_0$.

- **Výber \mathcal{L}_m :** $\mathcal{L}_m = \mathcal{K}_m(A, r_0)$, $\mathcal{L}_m = A\mathcal{K}_m(A, r_0)$, alebo $\mathcal{L}_m = \mathcal{K}_m(A^T, r_0)$.
- Jeden iteračný krok znamená nárast dimenzie \mathcal{K}_m o jednotku.
- Pre všeobecné v je príslušný Krylovov podpriestor: $\mathcal{K}_m(A, v) = \text{span}\{v, Av, A^2v, \dots, A^{m-1}v\}$.
- \mathcal{K}_m je podpriestor vektorov x , ktoré sa dajú vyjadriť v tvare $x = q(A)v$, kde q je polynóm, $\deg(q) \leq m - 1$.

Arnoldiho metóda

Arnoldiho metóda je algoritmus na zostavenie ortonormálnej bázy Krylovovho podpriestoru \mathcal{K}_m ; matica A je všeobecná a regulárna.

1. Vyber vektor v_1 s jednotkovou normou.

2. **for** ($j = 1; j \leq m - 1; j++$) {

3. $w_j = Av_j;$

//modifikovaná Gram-Schmidtova ortogonalizácia

4. **for** ($i = 1; i \leq j; i++$) {

5. $h_{ij} = w_j^T v_i;$

6. $w_j = w_j - h_{ij}v_i;$

7. }

8. $h_{j+1,j} = \|w_j\|;$ **if** ($h_{j+1,j} == 0$) **return;**

9. $v_{j+1} = w_j/h_{j+1,j};$

10. }

Iné varianty ortogonalizácie: klasický GS, iterovaný CGS, IMGS, Householder

Arnoldiho metóda

- Maticová forma Arnoldiho algoritmu:

Ak $V_m = [v_1, v_2, \dots, v_m]$ a $\tilde{H}_m = (h_{ij})$ je $(m+1) \times m$ horná Hessenbergova matica a H_m sa získa z \tilde{H}_m vynechaním jej posledného riadku, potom:

$$AV_m = V_{m+1}\tilde{H}_m = V_m H_m + h_{m+1,m} v_{m+1} e_m^T; \quad V_m^T AV_m = H_m.$$

- **“Lucky breakdown”**: Ak v j -tom kroku Arnoldiho algoritmu $h_{j+1,j} = 0$, potom projekčná metóda na podpriestor \mathcal{K}_j je presná - t.j. našlo sa presné riešenie rovnice $Ax = b$.

Generalized Minimum Residual Method (GMRES)

- GMRES je projekčná metóda s $\mathcal{K} = \mathcal{K}_m(r_0, A)$ a $\mathcal{L} = A\mathcal{K}_m(r_0, A)$, ktorá minimalizuje normu rezídua nad všetkými vektormi z afinného podpriestoru $x_0 + \mathcal{K}_m$ - t.j. minimalizuje funkcionál

$$R(y) = \|b - Ax\| = \|b - A(x_0 + V_my)\|.$$

- Ak $\beta = \|r_0\|$, potom:

$$b - Ax = r_0 - AV_my = \beta v_1 - V_{m+1} \tilde{H}_m y = V_{m+1} (\beta e_1 - \tilde{H}_m y),$$

$$\text{takže } R(y) = \|\beta e_1 - \tilde{H}_m y\|.$$

Algoritmus pre GMRES

1. Zvoľ m , x_0 a vypočítaj: $r_0 = b - Ax_0$, $\beta = \|r_0\|$, $v_1 = r_0/\beta$.
2. Definuj $(m+1) \times m$ maticu $\tilde{H}_m = (h_{ij})$; polož $\tilde{H}_m = 0$.
3. Vypočítaj V_m a \tilde{H}_m pomocou Arnoldiho metódy.
4. Vypočítaj y_m minimalizáciou $\|\beta e_1 - \tilde{H}_m y\|$.
5. Vypočítaj aproximáciu riešenia: $x_m = x_0 + V_m y_m$.

Minimalizácia $\|\beta e_1 - \tilde{H}_m y\|$ (krok č. 4):

I. Vypočítaj QR dekompozíciu: $\tilde{H}_m = Q_{m+1} \begin{pmatrix} R_m \\ 0 \end{pmatrix}$, kde R_m je rádu m , Q_{m+1} je ortogonálna rádu $m+1$.

II. Vypočítaj: $\tilde{g}_m = Q_{m+1}^T(\beta e_1) = \begin{pmatrix} g_m \\ \gamma_{m+1} \end{pmatrix}$.

III. Vypočítaj: $y_m = R_m^{-1} g_m$, $\|r_m\| = \|b - Ax_m\| = |\gamma_{m+1}|$.

Konvergenciu **možno testovať** podľa normy rezídua, t.j. podľa $|\gamma_{m+1}|$.

Symetrická Lanczosova metóda

Arnoldiho procedúra: $H_m = V_m^T A V_m$, H_m je horná Hessenbergova matica. Ak A je **symetrická**, potom H_m je tiež symetrická, a teda je **trojdiagonálna**.

1. Zvoľ m , x_0 a vypočítaj: $r_0 = b - Ax_0$; $\beta_1 = \|r_0\|$; $v_1 = r_0/\beta_1$;
2. **for** ($j = 1$; $j \leq m$; $j++$) {
3. $w_j = Av_j$;
4. **if** ($j \neq 1$) $w_j = w_j - \beta_j v_{j-1}$;
5. $\alpha_j = w_j^T v_j$;
6. $w_j = w_j - \alpha_j v_j$;
7. $\beta_{j+1} = \|w_j\|$;
8. **if** ($\beta_{j+1} \neq 0$) $v_{j+1} = w_j/\beta_{j+1}$;
9. **if** ($\beta_{j+1} == 0$) $j = m$; } //“lucky breakdown”
10. Polož: $T_m = \text{tridiag}(\beta_i, \alpha_i, \beta_{i+1})$ a $V_m = [v_1, \dots, v_m]$.
11. Vypočítaj: $y_m = T_m^{-1}(\beta_1 e_1)$ a $x_m = x_0 + V_m y_m$.
12. Rezíduum: $\|r_m\| = \beta_{m+1} |e_m^T y_m|$ (ako GMRES).

Direct Lanczos - priama forma - 1

- Priama forma:** postupne sa počíta LU dekompozícia symetrickej, trojdiagonálnej matice T_m : $T_m = L_m U_m$, kde L_m je dolná bidiagonálna s jednotkami na diagonále a U_m je horná bidiagonálna matica. Pre $m = 4$:

$$\begin{pmatrix} \alpha_1 & \beta_2 & & \\ \beta_2 & \alpha_2 & \beta_3 & \\ & \beta_3 & \alpha_3 & \beta_4 \\ & & \beta_4 & \alpha_4 \end{pmatrix} = \begin{pmatrix} 1 & & & \\ \lambda_2 & 1 & & \\ & \lambda_3 & 1 & \\ & & \lambda_4 & 1 \end{pmatrix} \times \begin{pmatrix} \eta_1 & \beta_2 & & \\ & \eta_2 & \beta_3 & \\ & & \eta_3 & \beta_4 \\ & & & \eta_4 \end{pmatrix}$$

- Základné vzťahy:
Prvok súčiny $(k, k - 1)$, $k \geq 2$: $\beta_k = \lambda_k \eta_{k-1}$.
Prvok súčiny (k, k) , $k \geq 1$: $\alpha_k = \lambda_k \beta_k + \eta_k$.

D-Lanczos - priama forma - 2

- Približné riešenie:

$$x_m = x_0 + V_m y_m = x_0 + V_m T_m^{-1}(\beta e_1) = x_0 + V_m U_m^{-1} L_m^{-1}(\beta e_1).$$

- Položme $P_m = V_m U_m^{-1}$ a $z_m = L_m^{-1}(\beta e_1)$; potom:

$$x_m = x_0 + P_m z_m.$$

- $P_m U_m = V_m \Rightarrow$ posledný stĺpec: $p_m = \eta_m^{-1}[v_m - \beta_m p_{m-1}]$.

- β_m je z Lanczosovho algoritmu a η_m je z m -tého kroku Gaussovej eliminácie trojdiagonálnej matice:

$$\lambda_m = \beta_m / \eta_{m-1}; \quad \eta_m = \alpha_m - \lambda_m \beta_m.$$

(α_m je diagonálny prvok T_m pred redukciou).

- $L_m z_m = \beta e_1 \Rightarrow z_m = \begin{pmatrix} z_{m-1} \\ \zeta_m \end{pmatrix}, \zeta_m = -\lambda_m \zeta_{m-1}.$

$$\text{Takže: } x_m = x_0 + (P_{m-1}, p_m) \begin{pmatrix} z_{m-1} \\ \zeta_m \end{pmatrix} =$$

$$x_0 + P_{m-1} z_{m-1} + \zeta_m p_m = x_{m-1} + \zeta_m p_m.$$

D-Lanczos - priama forma - 3

1. Zvoľ x_0 , tol.
2. $r_0 = b - Ax_0$; $\beta_1 = \|r_0\|$; $\zeta_1 = \beta_1$; $v_1 = r_0/\beta_1$;
3. $\lambda_1 = 0$; $\rho_0 = 0$; $v_0 = 0$; $m = 0$;
4. **do** {
5. $m = m + 1$;
6. $w = Av_m - \beta_m v_{m-1}$; $\alpha_m = w^T v_m$;
7. **if** ($m > 1$) {
8. $\lambda_m = \beta_m/\eta_{m-1}$;
9. $\zeta_m = -\lambda_m \zeta_{m-1}$; }
10. $\eta_m = \alpha_m - \lambda_m \beta_m$;
11. $\rho_m = \eta_m^{-1} (v_m - \beta_m \rho_{m-1})$;
12. $x_m = x_{m-1} + \zeta_m \rho_m$;
13. $w = w - \alpha_m v_m$;
14. $\beta_{m+1} = \|w\|$; $v_{m+1} = w/\beta_{m+1}$;
15. } **while** ($\|b - Ax_m\| \geq \text{tol}$);

Metóda konjugovaných gradientov (CG) - 1

- Matica A je **symetrická, pozitívne definitná** (SPD) a $\mathcal{K} = \mathcal{L} = \mathcal{K}_m(r_0, A)$.
- Pomocné vektory p_i , produkované D-Lanzcosovým algoritmom, sú A -ortogonálne, t.j. **konjugované**: $(Ap_i, p_j) = 0 \forall i \neq j$.

Dôkaz:

$$P_m^T A P_m = U_m^{-T} V_m^T A V_m U_m^{-1} = U_m^{-T} T_m U_m^{-1} = U_m^{-T} L_m,$$
čo je dolná trojuholníková, symetrická matica \Rightarrow je diagonálna.

- Pretože $r_m = -\beta_{m+1}(\mathbf{e}_m^T \mathbf{y}_m) \mathbf{v}_{m+1}$, reziduálne vektory sú vzájomne ortogonálne: $(r_i, r_j) = 0 \forall i \neq j$.

- Hľadáme: $x_{m+1} = x_m + \omega_m p_m \Rightarrow r_{m+1} = r_m - \omega_m A p_m$.
- Ortogonalita rezíduí:
 $(r_{m+1}, r_m) = 0 \Rightarrow \omega_m = (r_m, r_m) / (A p_m, r_m)$.
- Nový smer: $p_{m+1} = r_{m+1} + \phi_m p_m$,
 takže: $(A p_m, r_m) = (A p_m, p_m - \phi_{m-1} p_{m-1}) = (A p_m, p_m)$,
 čiže: $\omega_m = (r_m, r_m) / (A p_m, p_m)$.
- Konjugovanosť smerov:
 $0 = (A p_m, p_{m+1}) = (A p_m, r_{m+1}) + \phi_m (A p_m, p_m) \Rightarrow$
 $\phi_m = -(A p_m, r_{m+1}) / (A p_m, p_m)$.
- Konečná forma pre ϕ_m :
 $r_{m+1} = r_m - \omega_m A p_m \Rightarrow A p_m = -\omega_m^{-1} (r_{m+1} - r_m) \Rightarrow$
 $\phi_m = (r_{m+1}, r_{m+1} - r_m) / [\omega_m (A p_m, p_m)]$
 $= (r_{m+1}, r_{m+1}) / (r_m, r_m)$.

CG - 3

1. Zvoľ x_0 , tol.
2. $r_0 = b - Ax_0$; $p_0 = r_0$; $\beta = \|r_0\|$; $m = 0$;
3. **do** {
4. $m = m + 1$;
5. $\omega_{m-1} = (r_{m-1}, r_{m-1}) / (Ap_{m-1}, p_{m-1})$;
6. $x_m = x_{m-1} + \omega_{m-1}p_{m-1}$;
7. $r_m = r_{m-1} - \omega_{m-1}Ap_{m-1}$; /* nový gradient */
8. $\phi_{m-1} = (r_m, r_m) / (r_{m-1}, r_{m-1})$;
9. $p_m = r_m + \phi_{m-1}p_{m-1}$; /* nový smerový vektor */
10. } **while** ($\|r_m\|/\beta \geq \text{tol}$);

CG - konvergencia

- Nech x_m je približné riešenie v m -tom kroku CG a nech x_* je presné riešenie. Potom **chyba** približného riešenia je definovaná ako:

$$e_m \equiv x_* - x_m.$$

- Pre SPD maticu A definujeme **číslo podmienenosti** $\kappa(A)$ a **A-normu** ľubovoľného vektora z :

$$\kappa(A) \equiv \frac{\lambda_{\max}(A)}{\lambda_{\min}(A)}, \quad \|z\|_A \equiv (Az, z)^{1/2}.$$

- Potom:

$$\|x_* - x_m\|_A \leq 2 \left[\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right]^m \|x_* - x_0\|_A$$

Pri $\kappa(A) \gg 1$ je konvergencia **veľmi pomalá**.

Tri druhy predpodmienenia

- **Účel:** zvýšiť rýchlosť konvergencie iteračnej metódy tak, že sa rieši náhradný LS, kde nová matica sústavy má **nižšiu hodnotu κ** ako originálna matica.
- Originálny lineárny systém: $Ax = b$.
- **Ľavé predpodmienenie:** M regulárna, $M^{-1}Ax = M^{-1}b$.
- **Pravé predpodmienenie:** M regulárna, $AM^{-1}u = b$, $x = M^{-1}u$.
- **Predpodmienenie štiepením:** A a M sú SPD, $M = LL^T$ (Choleskyho rozklad). Potom nová sústava má tvar:

$$L^{-1}AL^{-T}u = L^{-1}b, \quad x = L^{-T}u.$$

Táto transformácia LS **zachováva symetriu matice sústavy**.

PCG - ľavé predpokladanie (1)

- Nie sú nutné separátne faktory L^{-1} a L^{-T} , aby sa zachovala symetria. SPD matica M definuje tzv. **M -skalárny súčin**: $(x, y)_M \equiv (Mx, y) = (x, My)$.
- $(M^{-1}Ax, y)_M = (Ax, y) = (x, Ay) = (x, M(M^{-1}A)y) = (Mx, M^{-1}Ay) = (x, M^{-1}Ay)_M$,
t.j. matica $M^{-1}A$ je **samoadjungovaná vzhľadom na M -skalárny súčin**.
- Algoritmus CG sa prepíše pre LS $M^{-1}Ax = M^{-1}b$ s novým M -skalárnym súčinom pomocou novej premennej $z_j = M^{-1}r_j = M^{-1}(b - Ax_j)$:
 5. $\omega_{m-1} = (z_{m-1}, z_{m-1})_M / (M^{-1}Ap_{m-1}, p_{m-1})_M$;
 6. $x_m = x_{m-1} + \omega_{m-1}p_{m-1}$;
 7. $r_m = r_{m-1} - \omega_{m-1}Ap_{m-1}$; /* nový gradient */
 - 7A. $z_m = M^{-1}r_m$; /* pomocná premenná */
 8. $\phi_{m-1} = (z_m, z_m)_M / (z_{m-1}, z_{m-1})_M$;
 9. $p_m = z_m + \phi_{m-1}p_{m-1}$;

PCG - ľavé predpokladanie (2)

- Ale: $(z_j, z_j)_M = (r_j, z_j)$ a $(M^{-1}Ap_j, p_j)_M = (Ap_j, p_j)$.
- Potom s počiatočnými hodnotami:
 $r_0 = b - Ax_0$; $z_0 = M^{-1}r_0$; $p_0 = z_0$;
má vnútorný cyklus zľava predpokladaného algoritmu CG tvar:
 5. $\omega_{m-1} = (r_{m-1}, z_{m-1}) / (Ap_{m-1}, p_{m-1})$;
 6. $x_m = x_{m-1} + \omega_{m-1}p_{m-1}$;
 7. $r_m = r_{m-1} - \omega_{m-1}Ap_{m-1}$; /* nový gradient */
 - 7A. $z_m = M^{-1}r_m$; /* pomocná premenná */
 8. $\phi_{m-1} = (r_m, z_m) / (r_{m-1}, z_{m-1})$;
 9. $p_m = z_m + \phi_{m-1}p_{m-1}$;
- **Krok 7A:** ak $M = LL^T$, potom z_m získame v dvoch krokoch:
 $Mz_m = r_m \Leftrightarrow L(L^T z_m) = r_m \Leftrightarrow Lu_m = r_m, L^T z_m = u_m$.
To isté platí aj pre z_0 : $Lu_0 = r_0, L^T z_0 = u_0$.

Neúplná Choleskyho faktorizácia

- A je SPD \Rightarrow Choleskyho faktorizácia: $A = LDL^T$, L je dolná trojuhol. s jednotkami na diagonále a D je diagonálna.
- **Problém:** L je spravidla oveľa menej riedka ako A . Preto sa počíta **neúplná Choleskyho faktorizácia** v tvare:
 $A = \hat{L}\hat{D}\hat{L}^T + W$, $W \neq 0$ (W sa nepočíta).

1. $\hat{d}_{11} = a_{11}$;
2. **for** ($i = 2$; $i \leq n$; $j++$) {
3. **for** ($j = 1$; $j \leq i - 1$; $j++$) {
4. **if** ($a_{ij} == 0$) $\hat{\ell}_{ij} = 0$;
5. **else** $\hat{\ell}_{ij} = \left(a_{ij} - \sum_{k=1}^{j-1} \hat{\ell}_{ik} \hat{d}_{kk} \hat{\ell}_{jk} \right) / \hat{d}_{jj}$; }
6. $\hat{l}_{ij} = 1$; $\hat{d}_{ii} = a_{ii} - \sum_{k=1}^{i-1} \hat{\ell}_{ik}^2 \hat{d}_{kk}$; }

Potom $M = \hat{L}\hat{D}\hat{L}^T$ a krok 7A (pozri predošlú stranu) sa rieši na tri etapy: $\hat{L}u_m = r_m$; $\hat{D}w_m = u_m$; $\hat{L}^T z_m = w_m$.

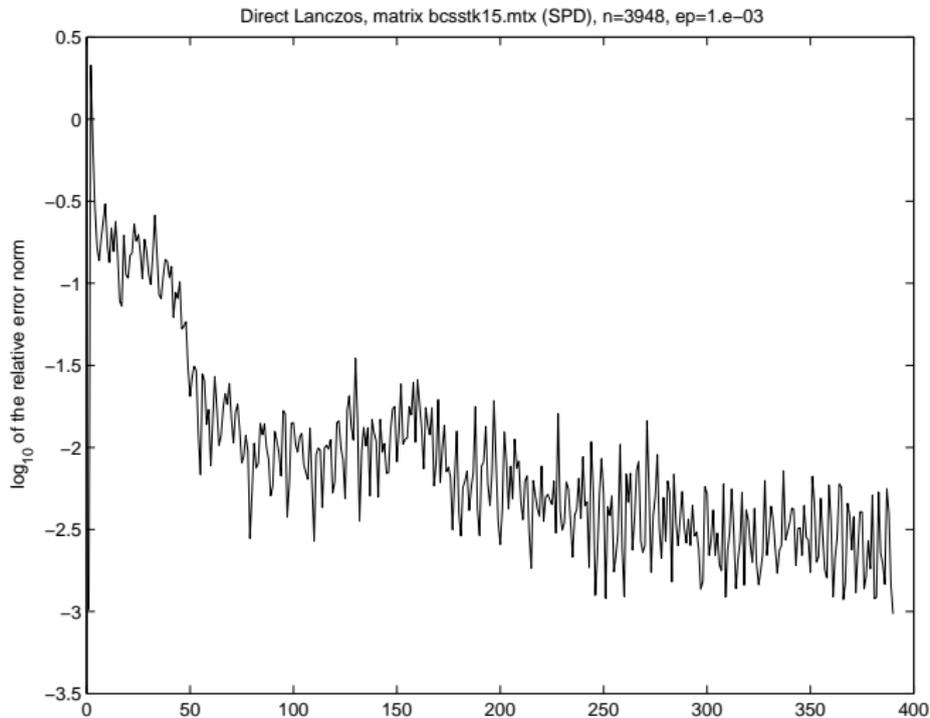


Figure: Priamy Lanczos, $\kappa(A) = 8 * 10^9$, $\text{nnz}(A) = 60882$, relatívna norma chyby. Na konvergenciu bolo potrebných 395 iterácií, ale kvalita riešenia je slabá.

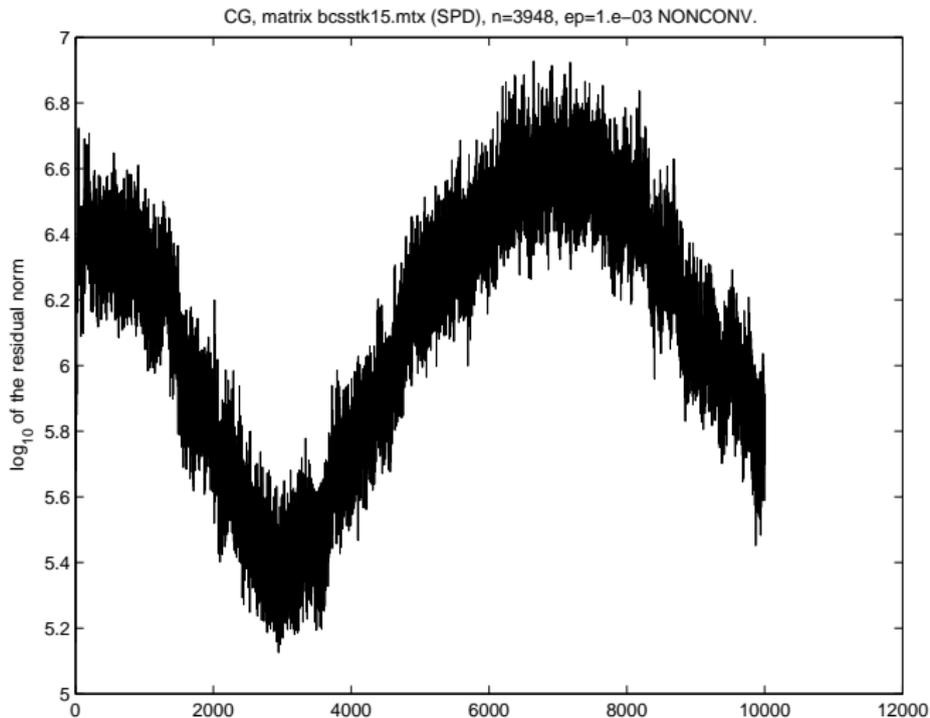


Figure: CG, $\kappa(A) = 8 * 10^9$, $\text{nnz}(A) = 60882$, norma rezídua. Ten istý trend má rezíduum pre priameho Lanczosa.

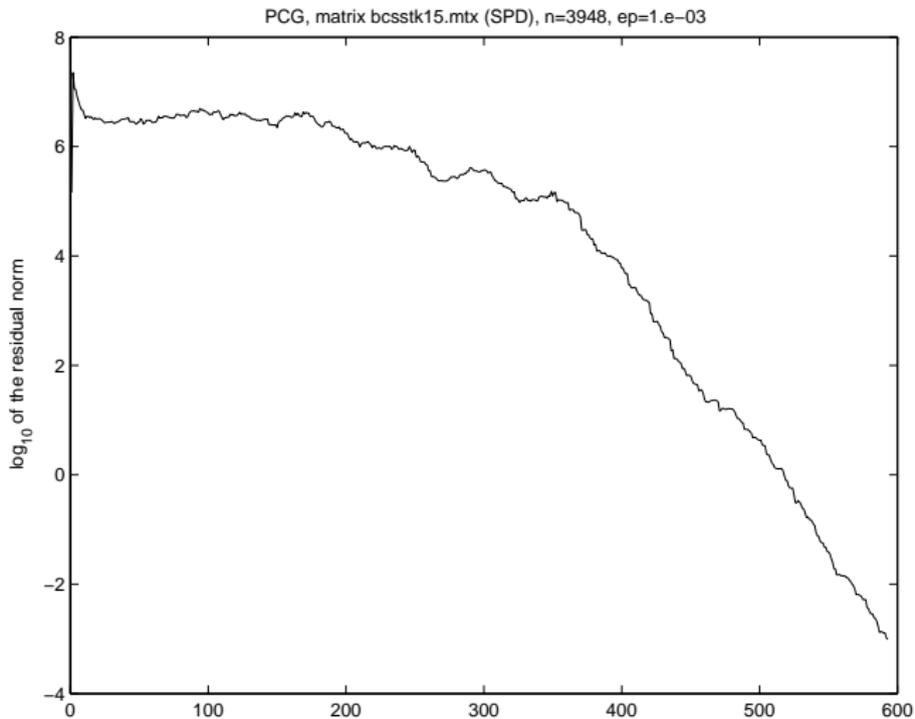


Figure: PCG, $\kappa(A) = 8 * 10^9$, $\text{nnz}(A) = 60882$, norma rezídua. Na konvergenciu bolo potrebných 593 iterácií.