

## 5 Iterationsverfahren für lineare Gleichungssysteme

### Klassische Iterationsverfahren

Sei  $A \in \mathbb{R}^{N \times N}$  und  $b \in \mathbb{R}^N$ . Wir wollen nun das LGS  $Ax = b$  iterativ lösen. Dazu betrachten wir die Komponenten  $m = 1, \dots, N$ :

$$\sum_{n=1}^N A[m, n]x[n] = b[m].$$

Wir formen um und erhalten für  $x[m]$ :

$$A[m, m]x[m] = b[m] - \sum_{n \neq m} A[m, n]x[n].$$

Falls  $A[m, m] \neq 0$  erhalten wir also

$$x[m] = \left( b[m] - \sum_{n \neq m} A[m, n]x[n] \right) / A[m, m].$$

Daraus können wir das *Gesamtschritt-Verfahren (Jacobi-Verfahren)* ableiten:

S0) Wähle  $x^0 \in \mathbb{R}^N$ ,  $\varepsilon > 0$ , setze  $k = 0$ .

S1) Falls  $|Ax^k - b|_2 < \varepsilon$  STOP.

S2) Berechne  $x^{k+1}[m] = (b[m] - \sum_{n \neq m} A[m, n]x^k[n]) / A[m, m]$  für  $m = 1, \dots, N$ .

S3) Setze  $k := k + 1$ , gehe zu S1).

Dieses Verfahren kann man mit der Idee abändern, dass bei der Berechnung von  $x_m$  die  $x_n$  für  $n < m$  ja schon bekannt sind. Dementsprechend kann man auch gleich mit diesen Werten weiterrechnen.

Dies führt zum *Einzelschritt-Verfahren (Gauß-Seidel-Verfahren)*:

S0) Wähle  $x^0 \in \mathbb{R}^N$ ,  $\varepsilon > 0$ , setze  $k = 0$ .

S1) Falls  $|Ax^k - b|_2 < \varepsilon$  STOP.

S2) Berechne  $x^{k+1}[m] = \left( b[m] - \sum_{n=1}^{m-1} A[m, n]x^{k+1}[n] - \sum_{n=m+1}^N A[m, n]x^k[n] \right) / A[m, m]$  für  $m = 1, \dots, N$ .

S3) Setze  $k := k + 1$ , gehe zu S1).

Um die Konvergenz von Iterationsverfahren zu untersuchen formulieren wir sie in Matrixform. Beachte, dass für invertierbare Matrizen  $B \in \mathbb{R}^{N, N}$  die Aufgabe  $Ax = b$  äquivalent ist zu  $BAx = Bb$ . Ein solches  $B$  heißt *Vorkonditionierer* von  $A$ , da  $B$  möglichst so gewählt wird, dass  $BA$  eine kleinere Kondition als  $A$  hat. Wir formulieren dies um in eine Fixpunkttaufgabe, also  $x = Bb - BAx + x$  und erhalten so

$$x = (I - BA)x + Bb = x + B(b - Ax).$$

Wir bestimmen nun  $B$  für das Jacobi- und das Gauß-Seidel-Verfahren. Dazu zerlegen wir

$$A = L + D + R$$

mit der strikt unteren Dreiecksmatrix  $L = \text{lower}(A)$ , der Diagonalmatrix  $D = \text{diag}(A)$  und der strikt oberen Dreiecksmatrix  $R = \text{upper}(A)$ . Damit folgt für diese beiden Verfahren:

### Gesamtschrittverfahren

Es gilt:

$$Dx^{k+1} = b - (L + R)x^k = b - (L + D + R)x^k + Dx^k.$$

Somit ist  $D(x^{k+1} - x^k) = b - Ax^k$  und schließlich

$$x^{k+1} = x^k + D^{-1}(b - Ax^k),$$

also  $B_J = D^{-1}$ .

### Einzelrittverfahren

Es gilt

$$Dx^{k+1} = b - Lx^{k+1} - Rx^k,$$

woraus  $(D + L)x^{k+1} = b - Rx^k = b - (L + D + R)x^k + (L + D)x^k = b - Ax^k + (D + L)x^k$  folgt und somit

$$x^{k+1} = x^k + (D + L)^{-1}(b - Ax^k),$$

also  $B_{GS} = (D + L)^{-1}$ .

### (5.1) Satz

Seien  $A, B \in \mathbb{R}^{N \times N}$  mit  $\rho(I - BA) < 1$ .

Dann ist  $A$  invertierbar und für alle  $b \in \mathbb{R}^N, x^0 \in \mathbb{R}^N$  konvergiert die Iteration

$$x^{k+1} = x^k + B(b - Ax^k) \quad k = 0, 1, 2, \dots,$$

so dass gilt

$$\lim_{k \rightarrow \infty} x^k = A^{-1}b. \quad \text{und} \quad A^{-1} = B \sum_{k=0}^{\infty} (I_N - AB)^k.$$

### (5.2) Satz

Sei  $K \in \mathbb{R}^{N \times N}$  und  $\varepsilon > 0$ . Dann existiert eine Norm  $\|\cdot\|$  mit  $\|K\| \leq \rho(K) + \varepsilon$ .

*Beweis.* Aus der linearen Algebra wissen wir, dass eine reguläre Matrix  $U \in \mathbb{C}^{N \times N}$  existiert, sodass

$$U^{-1}KU = \text{diag}(\lambda_1, \dots, \lambda_N) + R$$

mit einer strikt oberen Dreiecksmatrix  $R$ , wobei  $\lambda_n$  ( $n = 1, \dots, N$ ) die Eigenwerte von  $K$  sind. Zu  $\delta = \frac{\varepsilon}{\varepsilon + \|R\|_{\infty}} \in (0, 1]$  definiere  $D = \text{diag}(1, \delta^1, \delta^2, \dots)$ . Damit gilt

$D^{-1} = \text{diag}(1, \delta^{-1}, \delta^{-2}, \dots)$  und

$$\begin{aligned} D^{-1}RD &= (\delta^{n-m}R[m, n])_{m, n=1, \dots, N} \\ &= \begin{pmatrix} 0 & \delta R[1, 2] & \delta^2 R[1, 3] & \dots \\ & 0 & \delta R[2, 3] & \dots \\ 0 & & \ddots & \end{pmatrix} \end{aligned}$$

Somit folgt

$$\|D^{-1}RD\|_\infty \leq \delta \|R\|_\infty = \varepsilon - \varepsilon\delta = \varepsilon \underbrace{(1 - \delta)}_{\in [0,1]} < \varepsilon. \quad (1)$$

Nun definiere die Vektornorm  $|x| = |D^{-1}U^{-1}x|_\infty$  und erhalte

$$\begin{aligned} \|K\| &= \sup_{x \neq 0} \frac{|Kx|}{|x|} = \sup_{x \neq 0} \frac{|D^{-1}U^{-1}Kx|_\infty}{|D^{-1}U^{-1}x|_\infty} \\ &= \sup_{y \neq 0} \frac{|D^{-1}U^{-1}KUDy|_\infty}{|y|_\infty} = \|D^{-1}(\text{diag}(\lambda_n) + R)D\|_\infty \\ &\leq \underbrace{\|\text{diag}(\lambda_n)\|_\infty}_{=\rho(K)} + \|D^{-1}RD\|_\infty \stackrel{(1)}{\leq} \rho(K) + \varepsilon. \end{aligned} \quad \square$$

*Beweis. (Beweis von 5.1)* Zu einer Matrix  $K = I_N - BA$  wähle  $|\cdot|, \|\cdot\|$  wie in 5.2 zu  $\varepsilon = \frac{1-\rho(K)}{2} > 0$ . Es gilt  $\|K\| \leq \rho(K) + \varepsilon = 1 - \frac{\varepsilon}{2} < 1$ . Damit ist  $A$  invertierbar; die Inverse ist mit der Neumannschen Reihe  $A^{-1} = \sum_{k=0}^{\infty} (I_N - BA)^k B$  darstellbar.

Für  $x = A^{-1}b$  gilt dann

$$\begin{aligned} x^{k+1} - x &= x^k + B(b - Ax^k) - x = x^k - x + B(Ax - Ax^k) \\ &= x^k - x + BA(x - x^k) = \underbrace{(I_N - BA)}_{=K}(x^k - x). \end{aligned}$$

Und somit

$$|x^{k+1} - x| \leq \|I_N - BA\| |x^k - x| \leq \|I_N - BA\|^{k+1} |x^0 - x| \longrightarrow 0 \quad (k \rightarrow \infty). \quad \square$$

### Bemerkung

Falls  $\rho(I_N - BA) \geq 1$ , dann existiert  $q \in \mathbb{R}^N$  mit

$$|(I_N - BA)q|_2 = \rho(I_N - BA)|q|_2 \geq |q|_2 \neq 0$$

Wähle  $b = 0, x^0 = q$ , dann konvergiert  $(x^k)$  nicht gegen  $0_N$ .

### (5.3) Satz

Sei  $A = L + D + L^T \in \mathbb{R}^{N \times N}$  symmetrisch und positiv definit. Dann konvergiert das Gauß-Seidel Verfahren mit  $B = (L + D)^{-1}$  in der Energienorm  $|x|_A := \sqrt{x^T A x}$ .

*Beweis.* Sei dazu  $A = L + D + L^T$  mit  $L = \text{lower}(A)$ ,  $D = \text{diag}(A)$  und  $K = I_N - BA$ , wobei  $B = (D + L)^{-1}$ . Zeige nun  $\|K\|_A = \sup_{x \neq 0} \frac{|Kx|_A}{|x|_A} < 1$ , dann gilt  $\rho(K) \leq \|K\|_A < 1$ .

Es gilt

$$\begin{aligned} |Kx|_A^2 &= (x - BAx)^T A (x - BAx) \\ &= x^T (A - ABA - AB^T A + AB^T ABA) x \\ &= x^T A x - x^T A (B^T + B - B^T A B) A x. \end{aligned}$$

Weiter gilt

$$A + D = L + D + D + L^T = B^{-1} + B^{-T},$$

sodass

$$\begin{aligned} B^T + B - B^T A B &= B^T + B - B^T (A + D - D) B \\ &= B^T + B + B^T D B - B^T (B^{-1} + B^{-T}) B \\ &= B^T D B. \end{aligned}$$

Da  $A^T B^T D B A$  positiv definit ist, existiert ein  $\alpha > 0$  mit  $x^T (A^T B^T D B A) x \geq \alpha x^T A x$ . Es gilt also

$$|Kx|_A^2 = |x|_A^2 - x^T (A B^T D B A) x \leq |x|_A^2 - \alpha |x|_A^2 \leq (1 - \alpha) |x|_A^2$$

und somit

$$\|K\|_A = \sup_{x \neq 0_N} \frac{|Kx|_A}{|x|_A} = \sup_{|x|_A=1} |Kx|_A \leq 1 - \alpha < 1. \quad \square$$

### Bemerkung

1. Häufig wird die symmetrische Variante verwendet.
2. Beim  $SOR^1$ -Verfahren ist  $B = \omega(D - \omega L)^{-1}$  mit  $\omega \in (1, 2)$ .

### (5.4) Definition

Sei  $A \in \mathbb{R}^{N \times N}$ . Die Matrix  $A$  heißt stark diagonaldominant, wenn sie diagonaldominant ist ( $|A[n, n]| \geq \sum_{k \neq n} |A[n, k]|$ ,  $n = 1, \dots, N$ ) und wenn für ein  $j \in \{1, \dots, N\}$ ,  $|A[j, j]| > \sum_{k \neq j} |A[j, k]|$  gilt.

### (5.5) Satz

Sei  $A \in \mathbb{R}^{N \times N}$  stark diagonaldominant und irreduzibel. Dann gilt:

- a)  $A$  ist regulär und das Jacobi-Verfahren konvergiert.
- b) Falls  $A[n, n] > 0$ , dann ist  $A$  positiv definit.
- c) Falls  $A[n, n] > 0$ ,  $A[n, k] \leq 0$  ( $n \neq k$ ) ist, dann gilt  $A^{-1}[n, k] \geq 0$ .

### (5.6) Lemma

Wenn  $A$  irreduzibel ist, dann ist der Matrixgraph  $\Gamma = \{(k, n) : A[k, n] \neq 0\}$  zusammenhängend: zu jedem Paar  $n \neq j$  existiert eine Folge  $j = j_0, j_1, \dots, j_R = n$  mit  $A[j_1, j_0] \neq 0, A[j_2, j_1] \neq 0, \dots, A[j_R, j_{R-1}] \neq 0$ .

*Beweis.* (nur skizziert) Ohne Einschränkung sei  $j < n$ .

Definiere  $I = \{k : \text{es ex. ein Weg in } \Gamma \text{ von } j \text{ zu } k\}$ .

Annahme:  $n \notin I$ ; ohne Einschränkung sei  $I = \{1, \dots, K\}$ .

Dann gilt  $A[m, k] = 0$  für  $k \in I, k \leq K, m > K$ .

Es folgt:  $A$  ist irreduzibel mit  $A[K+1 : N, 1 : K] = 0$ . Das ist ein Widerspruch. □

<sup>1</sup>Successive Over-Relaxation, dt. Überrelaxation

*Beweis. (Beweis von 5.5)* Sei  $A$  irreduzibel. Dann gilt  $\sum_{k=1}^N |A[n, k]| > 0$ , mit 5.4 folgt  $|A[n, n]| > 0$  für  $n = 1, \dots, N$ . Somit sind  $B = D^{-1}$ ,  $K = I_N - D^{-1}A$  wohldefiniert. Zu zeigen ist nun  $\rho(K) < 1$ . Sei dazu  $\mu \in \mathbb{C}$  Eigenwert mit Eigenvektor  $w \in \mathbb{C}^N \setminus \{0_N\}$  und  $Kw = \mu w$ ; ohne Einschränkung sei  $|w|_\infty = 1 = |w[n]|$  für ein  $n \in \{1, \dots, N\}$ . Aus  $\mu w = Kw$  folgt

$$\begin{aligned} |\mu| |w[n]| &= \left| \sum_{k=1}^N K[n, k] w[k] \right| \\ &\leq |A[n, n]|^{-1} \sum_{k \neq n} |A[n, k]| \\ &\leq 1 \end{aligned}$$

Annahme:  $|\mu| = 1$ . Zu  $j$  wähle  $j = j_0, j_1, \dots, j_k = n$  mit  $A[j_1, j] \neq 0$ . Es folgen

$$|w[j]| = |\mu w[j]| = |(Kw)[j]| \leq |A[j, j]|^{-1} \sum_{k \neq j} |A[j, k]| \leq 1$$

und

$$\begin{aligned} |w[j_1]| = |\mu w[j_1]| &\leq |A[j_1, j_1]|^{-1} \left| \sum_{k \neq j_1} |A[j_1, k] w[k]| \right| \\ &\leq |A[j_1, j_1]|^{-1} \left| \sum_{k \neq j_1, j} |A[j_1, k]| + |A[j_1, j] w[j]| \right| \\ &< |A[j_1, j_1]|^{-1} \sum_{k \neq j_1} |A[j_1, k]| \\ &\leq 1 \end{aligned}$$

Induktiv folgt  $|w[j_r]| < 1$ , also  $|w[n]| < 1$ ; dies ist ein Widerspruch zur Annahme.

zu a) Aus  $\rho(K) = \rho(I_N - D^{-1}A) < 1$  folgt  $(I_N - K)^{-1} = \sum_{k \geq 0} K^k$ , also  $A^{-1} = K^k D^{-1}$ .

zu b) Mit dem Satz von Gerschgorin und der Diagonaldominanz von  $A$  folgt  $\sigma(A) \subset \{\lambda \in \mathbb{C} : |\lambda - A[n, n]| \leq |A[n, n]|, n = 1, \dots, N\}$ . Da  $A$  invertierbar ist, folgt  $0 \notin \sigma(A)$ ; es ist also  $\operatorname{Re} \sigma(A) > 0$ , somit ist  $A$  positiv definit.

zu c) Aus  $K = I_N - D^{-1}A = D^{-1}(D - A)$  folgt  $K[n, k] \geq 0$ .  
 $A^{-1} = \sum K^k D^{-1}$  zeigt  $A^{-1}[n, k] \geq 0$ .

□

## Krylovraum–Verfahren

Sei  $B \in \mathbb{R}^{N \times N}$  ein Vorkonditionierer zu  $A \in \mathbb{R}^{N, N}$ . Wir betrachten wieder die lineare Iteration

$$x^{k+1} = x^k + B(b - Ax^k) = x^k + Br^k,$$

wobei  $r^k$  das Residuum  $r^k = b - Ax^k$  sei. Für das Residuum folgt die Gleichung

$$r^{k+1} = b - Ax^{k+1} = b - A(x^k + Br^k) = (I_N - AB)r^k,$$

und somit

$$r^k = (I_N - AB)^k r^0.$$

### (5.7) Definition

Zu  $C \in \mathbb{R}^{N \times N}$  und  $d \in \mathbb{R}^N$  heißt  $\mathcal{K}_k(C, d) := \text{span}\{d, Cd, \dots, C^{k-1}d\} \subset \mathbb{R}^N$  der  $k$ -te Krylovraum. Es gilt:

- a)  $\dim \mathcal{K}_k(C, d) \leq k$
- b)  $\mathcal{K}_k(C, d) = \{P(C)d : P \in \mathbb{P}_k\}$
- c)  $x^k - x \in \mathcal{K}_k(BA, x^0 - x)$
- d)  $x^k \in \mathcal{K}_k(AB, r^0)$
- e)  $x^{k+1} \in x^0 + \mathcal{K}_k(BA, Br^0)$

### (5.8) Lemma

Sei  $Ax = b$  und  $x^0 \in \mathbb{R}^N$  Startwert,  $r^0 = b - Ax^0$ ,  $A, B$  regulär. Falls  $\dim \mathcal{K}_k(AB, r^0) < k$  ist, dann gilt

$$x \in x^0 + \mathcal{K}_{k-1}(BA, Br^0)$$

*Beweis.* Seien  $r^0, AB r^0, \dots, (AB)^{k-1} r^0$  linear abhängig. Dann existieren  $\alpha_0, \dots, \alpha_{k-1} \in \mathbb{R}$  mit  $\alpha_0 r^0 + \alpha_1 AB r^0 + \dots + \alpha_{k-1} (AB)^{k-1} r^0 = 0$ . Ohne Einschränkung sei  $\alpha_0 = 1$ . Dann gilt

$$\begin{aligned} b - Ax^0 + \alpha_1 AB r^0 + \dots + \alpha_{k-1} (AB)^{k-1} r^0 &= 0 \\ \implies b &= A \underbrace{(x^0 - \alpha_1 Br^0 - \dots - \alpha_{k-1} (BA)^{k-2} Br^0)}_{=x} \end{aligned} \quad \square$$

Auf folgender Idee basieren die Krylovraum-Verfahren:

- (1) Wähle ein geeignetes Skalarprodukt in  $\mathbb{R}^N$  mit zugehöriger Norm.
- (2) Konstruiere eine Orthonormalbasis  $v^1, \dots, v^k$  von  $\mathcal{K}_k$  bezüglich des gewählten Skalarproduktes.
- (3) Approximiere  $x = A^{-1}b$  mit minimalem Fehler (bzw. minimalem Residuum) in  $x^0 + \mathcal{K}_k$ .

## Gram-Schmidt-Verfahren

Wir suchen eine Orthonormalbasis bzgl. eines Skalarprodukts  $\langle \cdot, \cdot \rangle$  bzw. Norm  $|x| = \sqrt{\langle x, x \rangle}$  des oben definierten Krylovraumes. Dazu bietet sich zunächst das Gram-Schmidt-Verfahren an. Die ersten zwei Schritte des Krylovraumverfahrens lauten also

S0) Wähle  $x^0 \in \mathbb{R}^N$ ,  $\varepsilon > 0$ . Berechne  $r^0 = b - Ax^0$ ,  $z^1 = Br^0$ ,  $h_{10} = |z^1|$  und  $v^1 = \frac{1}{h_{10}}z^1$  (falls  $|h_{10}| > \varepsilon$ ).

Setze  $k = 1$ .

S1) Berechne

$$\begin{aligned}w^k &= BA v^k \\z^{k+1} &= w^k - \sum_{j=1}^k h_{jk} v^j \text{ mit } h_{jk} = \langle v^j, w^k \rangle \\v^{k+1} &= \frac{1}{h_{k+1,k}} z^{k+1} \text{ mit } h_{k+1,k} = |z^{k+1}|.\end{aligned}$$

Dann ist  $v^1, \dots, v^k$  eine Orthonormalbasis des Krylovraumes

$$\mathcal{K}_k(BA, Br^0) = \text{span}\{v^1, \dots, v^k\} = \text{span}\{w^1, \dots, w^k\} = \text{span}\{z^1, \dots, z^k\}$$

Es ist  $|v^k| = 1$  und  $\langle v^2, v^1 \rangle = h_{21} \langle z^2, v^1 \rangle = h_{21} (\langle w^1, v^1 \rangle - h_{11}) = 0$ .

Induktiv folgt  $\langle v^k, v^j \rangle = 0$  für  $j < k$ .

Wir schreiben  $BA v^k = w^k = z^{k+1} + \sum_{j=1}^k h_{jk} v^j = \sum_{j=1}^{k+1} h_{jk} v^j$ , also

$$BAV_k = V_{k+1} H_k$$

mit  $V_k = (v^1 | \dots | v^k) \in \mathbb{R}^{N \times k}$  und  $H_k = (h_{jm}) \in \mathbb{R}^{k+1, k}$ .

Beachte, dass  $H_k$  obere Hessenbergform hat.

### Bemerkung

Falls  $h_{k+1,k} = 0$  ist, dann ist  $w^k = BA v^k \in \text{span}\{v^1, \dots, v^k\}$ .

Es gilt dann  $\mathcal{K}_{k+1}(BA, Br^0) = \mathcal{K}_k(BA, Br^0)$ .

## GMRES-Verfahren

Für das GMRES<sup>2</sup>-Verfahren wähle  $\langle v, w \rangle_V = v^T w$ . Somit gilt  $V_k^T V_k = I_k$ . Dieses Verfahren baut auf folgender Beobachtung auf:

### (5.9) Satz

Es gilt

$$\min_{z \in x^0 + \mathcal{K}_k(BA, Br^0)} |B(b - Az)|_2 = \min_{y \in \mathbb{R}^k} |h_{10}e^1 - H_k y|_2.$$

mit  $e^1 = (1, 0, \dots, 0)^T \in \mathbb{R}^{k+1}$ ,  $h_{10} = |Br^0|_2$ ,  $H_k \in \mathbb{R}^{k+1, k}$ .

*Beweis.* Es gilt

$$\begin{aligned} \min_{z \in x^0 + \mathcal{K}_k(BA, Br^0)} |B(b - Az)|_2 &= \min_{y \in \mathbb{R}^k} |B(b - A(x^0 + V_k y))|_2 \\ &= \min_{y \in \mathbb{R}^k} |Br^0 - BAV_k y|_2 \\ &= \min_{y \in \mathbb{R}^k} |h_{10}v^1 - V_{k+1}H_k y|_2 = \min_{y \in \mathbb{R}^k} |V_{k+1}(h_{10}e^1 - H_k y)|_2 \\ &= \min_{y \in \mathbb{R}^k} |h_{10}e^1 - H_k y|_2 \end{aligned}$$

□

Algorithmus für das GMRES-Verfahren:

S0) Wähle  $x^0 \in \mathbb{R}^N$ ,  $\varepsilon > 0$ . Berechne  $r^0 = b - Ax^0$ ,  $z^1 = Br^0$ ,  $h_{10} = |z^1|_2$  und  $v^1 = \frac{1}{h_{10}}z^1$ .  
Setze  $k = 1$ .

S1) Berechne  $w^k = BAV^k$ ,  $z^{k+1} = w^k - \sum_{j=1}^k h_{jk}v^j$ ,  $h_{jk} = (w^k)^T v^j$ ,  $v^{k+1} = \frac{1}{h_{k+1,k}}z^{k+1}$ ,  $h_{k+1,k} = |z^{k+1}|$ . (D.h.  $BAV_k = V_{k+1}H_k$ .)

S2) Berechne  $y^k \in \mathbb{R}^k$  mit

$$\rho_k = |h_{10}e^1 - H_k y^k|_2 = \min!$$

Dabei ist  $H_k = (h_{jm})_{j=1, \dots, k+1, m=1, \dots, k} \in \mathbb{R}^{k+1, k}$ .

S3) Wenn  $\rho_k < \varepsilon$ , setze

$$x^k = x^0 + \sum_{j=1}^k y_j^k v^j$$

und STOP.

S4) Setze  $k := k + 1$  und gehe zu S1).

### Bemerkung

(1) Das Ausgleichsproblem in S2) ist effizient lösbar: berechne eine QR-Zerlegung von  $H_k \in \mathbb{R}^{(k+1) \times k}$  mit  $k$  Givensrotationen.

(2) Ist  $|B(b - Ax^k)|_2 = |Br^k|_2 = \rho_k$ , dann gilt  $|r^k|_2 \leq \|B^{-1}\|_2 \rho_k$  und es folgt  $|x - x^k| \leq \|(BA)^{-1}\|_2 \rho_k$

<sup>2</sup>generalized minimal residual



(3) Aus  $\rho_k > 0$  folgt  $r^k \neq 0$ , also  $x^k \neq x$ . Somit ist  $\dim \mathcal{K}_k(BA, Br^0) = k$ , es gilt also  $h_{k+1,k} \neq 0$ .

Das GMRES-Verfahren ist wohldefiniert.

(4) Das Gram-Schmidt-Verfahren ist numerisch nicht stabil (beginne nach  $k_{\max}$  wieder bei S0)).

**(5.10) Satz**

Sei  $BA$  positiv definit mit  $z^T(BA)z \geq \alpha z^T z$ ,  $\alpha > 0$ , und sei  $\|BA\|_2 \leq C$ . Dann konvergiert das GMRES-Verfahren, und es gilt

$$|x^k - x|_2 \leq \kappa_2(BA) \sqrt{1 - \frac{\alpha^2}{C^2}}^k |x^0 - x|$$

*Beweis.* Es ist

$$\begin{aligned} Br^k &= B(b - Ax^k) = B(b - A(x^0 + V_k y^k)) \\ &= B(r^0 - AQ_k(BA)Br^0) \quad (Q_k \in \mathbb{P}_{k-1}) \\ &= (I_N - BAQ_k(BA))Br^0 \\ &= P_k(BA)Br^0 \end{aligned}$$

mit  $P_k(t) = 1 - tQ_k(t)$ , d.h.  $P_k \in \mathbb{P}_k$  mit  $P(0) = 1$ . Es gilt

$$\begin{aligned} |Br^k|_2 &= \min_{P \in \mathbb{P}_k, P(0)=1} |P(BA)Br^0|_2 \\ &\leq \left| \left( I_N - \frac{\alpha}{C^2} BA \right)^k Br^0 \right|_2 \\ &\leq \left( \sqrt{1 - \frac{\alpha^2}{C^2}} \right)^k |Br^0|_2, \end{aligned}$$

denn

$$\begin{aligned} \left| \left( I_N - \frac{\alpha}{C^2} BA \right)^k z \right|_2^2 &= z^T z - \frac{\alpha}{C^2} z^T BA z - \frac{\alpha}{C^2} (BAz)^T z + \frac{\alpha^2}{C^2} |BAz|_2^2 \\ &\leq z^T z - 2 \frac{\alpha^2}{C^2} z^T z + \frac{\alpha^2}{C^2} |z|_2^2 \\ &= \left( 1 - \frac{\alpha^2}{C^2} \right) |z|_2^2 \end{aligned}$$

Damit folgt

$$\begin{aligned} |x^k - x|_2 &= |A^{-1} r^k|_2 = |A^{-1} B^{-1} Br^k|_2 \\ &\leq \|A^{-1} B^{-1}\|_2 |Br^k|_2 \\ &\leq \|(BA)^{-1}\|_2 \left( \sqrt{1 - \frac{\alpha^2}{C^2}} \right)^k |Br^0|_2 \\ &\leq \|AB\|_2 |x - x^0|_2 \end{aligned}$$

□

### Bemerkung

1.  $\alpha$  ist der kleinste Eigenwert von  $\frac{1}{2}(BA + A^T B^T)$ .
2. Falls  $A, B$  symmetrisch sind, ist  $\kappa_2(BA) = \frac{c}{\alpha}$ .
3. Falls  $A, B$  symmetrisch und positiv definit sind existiert eine Abschätzung mit  $\sqrt{\kappa_2(BA)}$ .

### Das cg-Verfahren

Seien  $A, B \in \mathbb{R}^{N \times N}$  symmetrisch und positiv definit und wähle als Skalarprodukt das Energieskalarprodukt  $\langle v, w \rangle_A = v^T A w$  mit zugeordneter Energienorm  $|x|_A = \sqrt{\langle x, x \rangle_A}$ . Bestimme  $x^k$  mit dem kleinsten Fehler in der Energienorm; genauer: zum Startwert  $x^0$  berechne  $r^0 = b - Ax^0$ ,  $\mathcal{K}_k(BA, Br^0)$  und eine Orthonormalbasis  $V_k = (v^1 | \dots | v^k)$  mit  $V_k^T A V_k = I_k$ . Berechne  $y^k \in \mathbb{R}^k$  und  $x^k = x^0 + V_k y^k$  mit

$$|x^k - x|_A \leq |x^0 + V_k y - x|_A \quad \forall y \in \mathbb{R}^k$$

#### (5.11) Satz

Für  $y^k = V_k^T r^0$  und  $x^k = x^0 + V_k y^k$  gilt

$$|x^k - x|_A \leq |x^0 + V_k y - x|_A \quad \forall y \in \mathbb{R}^k$$

*Beweis.* Es gilt

$$\begin{aligned} F(y) &= \frac{1}{2} |x^0 - V_k y - x|_A^2 \\ &= \frac{1}{2} (x^0 - V_k y - x)^T A (x^0 - V_k y - x) \\ &= \frac{1}{2} (x^0 - V_k y - x)^T (A V_k y - r^0) \\ &= \frac{1}{2} y^T V_k^T A V_k y - y^T V_k^T r^0 - \frac{1}{2} (x^0 - x)^T r^0 \end{aligned}$$

also impliziert  $F(y^k) = \min!$  dass  $\nabla F(y^k) = 0$  ist und somit  $y^k - V_k^T r^0 = 0$ . □

Das Ziel ist es, einen Algorithmus zu entwerfen, in welchem nicht alle  $k$  Vektoren abgespeichert werden.

Eine erste Version ist gegeben durch:

S0) Wähle  $x^0$ ,  $\varepsilon > 0$ , definiere  $r^0 = b - Ax^0$ ,  $w^0 = z^0 = Br^0$ ,  $h_{10} = |z^0|_A$ ,  $v^1 = \frac{1}{h_{10}} z^0$ . Setze  $k = 1$ .

S1) Falls  $|r^{k-1}| < \varepsilon$ : Stop.

S2) Berechne

$$\begin{aligned} w^{k+1} &= B A v^k \\ z^{k+1} &= w^{k+1} - \sum_{j=1}^k h_{jk} v^j, \quad h_{jk} = (v^j)^T A w^{k+1} \\ v^{k+1} &= \frac{1}{h_{k+1,k}} z^{k+1}, \quad h_{k+1,k} = |z^{k+1}|_A \end{aligned}$$

S3) Berechne

$$\begin{aligned}x^{k+1} &= x^k + \left( (r^0)^T v^{k+1} \right) v^{k+1} \\r^{k+1} &= r^k - (r^0)^T v^{k+1} A v^{k+1}\end{aligned}$$

S4) Setze  $k := k + 1$  und gehe zu S1)

**Beobachtung** Aus  $h_{k+1,k} v^{k+1} = z^{k+1} = B A v^k - \sum_{j=1}^k h_{jk} v^j$  folgt  $V_{k+1} H_k = B A V_k$  mit  $V_k = (v^1 | \dots | v^k)$  und  $H_k[j, n] = h_{jn}$  symmetrischer Hessenbergmatrix, denn es gilt

$$H_k[j, k] = h_{jk} = \langle B A v^k, v^j \rangle_A = \left( B A v^k \right)^T A v^j = (v^k)^T (A B A) v^j = h_{kj}$$

Somit ist  $h_{jk} = 0$  für  $j = 0, \dots, k - 2$  und es gilt

$$z^{k+1} = w^{k+1} - h_{kk} v^k - h_{k-1,k} v^{k-1}$$

Im  $k$ -ten Schritt werden  $v^1, \dots, v^{k-2}$  nicht mehr benötigt.

### (5.12) Lemma

Es gilt  $\langle x^k - x, v^j \rangle_A = 0 = (r^k)^T v^j$  für  $j = 1, \dots, k$ .

*Beweis.* Es gilt

$$\begin{aligned}\langle x^k - x, v^j \rangle &= \langle x^0 + V_k y^k - x, v^j \rangle_A \\&= \langle V_k y^k, v^j \rangle_A - \langle x - x^0, v^j \rangle_A \\&= \sum_{n=1}^k y^k[n] \langle v^n, v^j \rangle_A - (r^0)^T v^j \\&= y^k[j] - (r^0)^T v^j \\&= 0\end{aligned}$$

□

### (5.13) Folgerung

Für  $j < k$  gilt

$$\begin{aligned}\langle B r^0, v^j \rangle_A &= \langle B A (x - x^k), v^j \rangle_A \\&= (x - x^k)^T A B A v^j \\&= \langle x - x^k, B A v^j \rangle_A \\&= 0\end{aligned}$$

Also gilt

$$B r^k = \langle B r^k, v^{k+1} \rangle_A v^{k+1} + \langle B r^k, v^k \rangle_A v^k \quad (2)$$

### (5.14) Lemma

Sei  $d^k = \langle B r^{k-1}, v^k \rangle_A v^k$ , dann gilt

$$\begin{aligned}x^k &= x^{k-1} + \alpha_k d^k \\d^{k+1} &= B r^0 + \frac{\rho_k}{\rho_{k-1}} d^k\end{aligned}$$

mit  $\rho_k = (B r^k)^T r^k$  und  $\alpha_k = \frac{\rho_{k-1}}{|d^k|_A^2}$ .

*Beweis.* Für  $k = 1$  gilt  $d^1 = Br^0$ . Weiter

$$\begin{aligned} (Br^k)^T r^k &= (d^{k+1})^T r^k \\ &= \langle d^{k+1}, x - x^k \rangle_A \\ &= \langle d^{k+1}, x - x^0 \rangle_A \\ &= (d^{k+1})^T r^0 \end{aligned}$$

Also gilt

$$x^k = x^{k-1} + \left( (r^0)^T v^k \right) v^k = x^{k-1} + \frac{(r^0)^T d^k}{|d^k|_A^2} d^k = x^{k-1} + \alpha_k d^k$$

Es gilt

$$Br^k = d^{k+1} + \frac{1}{|d^k|_A^2} \langle Br^k, d^k \rangle_A d^k$$

und schliesslich

$$\alpha_k \langle Br^k, d^k \rangle_A = (Br^k)^T (\alpha_k A d^k) = (Br^k) (r^{k-1} - r^k) = -(B^k)^T r^k = -\rho_k$$

□

Der Algorithmus für das cg-Verfahren lautet somit

S0) Wähle  $x^0, r^0 = b - Ax^0, d^1 = y^0 = Br^0, \rho_0 = (y^0)^T r^0, \varepsilon > 0$ . Setze  $k := 0$ .

S1) Falls  $\sqrt{\rho_k} < \varepsilon$ : Stop

S2) Setze  $k := k + 1$  und berechne

$$\begin{aligned} u^k &= Ad^k \\ \alpha_k &= \frac{\rho_{k+1}}{(u^k)^T d^k} \\ x^k &= x^{k-1} + \alpha_k d^k \\ r^k &= r^{k-1} - \alpha_k u^k \\ y^k &= Br^k \\ \rho_k &= (y^k)^T r^k \\ d^{k+1} &= y^k + \frac{\rho_k}{\rho_{k-1}} d^k \end{aligned}$$

Gehe zu S1)

### (5.15) Satz

Für das cg-Verfahren gilt die Fehlerabschätzung

$$|x^k - x|_A \leq 2 \left( \frac{\sqrt{\kappa(BA)} - 1}{\sqrt{\kappa(BA)} + 1} \right)^k |x^0 - x|_A.$$

**(5.16) Satz (ohne Beweis)**

Es gilt

$$\min_{P \in \mathbb{P}_k, P(0)=1} \max_{t \in [a,b]} |P(t)| \leq \left( \frac{\sqrt{\frac{b}{a}} - 1}{\sqrt{\frac{b}{a}} + 1} \right)^k$$

*Beweis.* (Beweis von 5.15) Es gilt

$$\begin{aligned} |x - x^k|_A &= \min_{y \in \mathbb{R}^k} |x^0 + V_k y - x|_A \\ &= \min_{Q \in \mathbb{P}_{k-1}} |x^0 - Q(BA)Br^0 - x|_A \quad r^0 = A(x - x^0) \\ &= \min_{Q \in \mathbb{P}_{k-1}} |(I_N - Q(BA)BA)(x^0 - x)|_A \quad P(t) = 1 - tQ(t) \\ &= \min_{P \in \mathbb{P}_k, P(0)=1} \underbrace{|P(BA)(x^0 - x)|_A}_{\leq \|P(BA)\|_A |x^0 - x|_A} \end{aligned}$$

Behauptung:  $\|P(BA)\|_A \leq \max_{t \in \sigma(BA)} |P(t)|$

Aus  $A = LL^T$  folgt  $\sigma(BA) = \sigma(BLL^T) = \sigma(L^T BL)$ , also  $\|P(BA)\|_A = \|P(L^T BL)\|_2$ . Somit gilt

$$\|P(BA)\|_A = \|P(L^T BL)\|_2 = \max_{\mu \in \sigma(P(L^T BL))} |\mu| = \max_{\lambda \in \sigma(L^T BL)} |P(\lambda)|$$

□