

Numerische Lineare Algebra

Oliver Ernst

Professur Numerische Mathematik

Wintersemester 2017/18



Mathematik!
TU Chemnitz

① Einleitung

- 1.1 Lineare Gleichungssysteme
- 1.2 Matrixfunktionen
- 1.3 Modellreduktion
- 1.4 Eigenwertaufgaben

② Krylov-Unterraumverfahren

- 2.1 Projektionen
- 2.2 Orthogonale Projektionsverfahren
- 2.3 Krylov-Unterräume
- 2.4 Basen von Krylov-Räumen

③ Lineare Gleichungssysteme

- 3.1 Lösungsstrategien
- 3.2 Selbstadjungierte Probleme
- 3.3 Das Verfahren der konjugierten Gradienten
- 3.4 Krylov-Verfahren für lineare Ausgleichsprobleme
- 3.5 Vorkonditionierung

④ Matrixfunktionen

- 4.1 Erste Definition mithilfe der Jordanschen Normalform

- 4.2 Hermitesche Polynominterpolation
- 4.3 Alternative Darstellungen von Matrixfunktionen
- 4.4 Resolventenintegrale
- 4.5 Ein Beispiel

5 Krylov-Verfahren für Matrixfunktionen

- 5.1 Schranken für $\|f(\mathbf{A})\|$
- 5.2 Fehlerschranken für Krylov-Verfahren
- 5.3 Die Konvergenz des CG-Verfahrens

6 Das QR-Verfahren für Eigenwertaufgaben

- 6.1 Reduktion auf Hessenberg-Gestalt
- 6.2 Vektoriteration
- 6.3 QR-Iteration

- ① Einleitung
- ② Krylov-Unterraumverfahren
- ③ Lineare Gleichungssysteme
- ④ Matrixfunktionen
- ⑤ Krylov-Verfahren für Matrixfunktionen
- ⑥ Das QR-Verfahren für Eigenwertaufgaben

Das QR-Verfahren für Eigenwertaufgaben

Vorbemerkungen

Nach dem Satz von Abel-Ruffini sind Polynomgleichungen ab Grad 5 nicht durch Wurzelziehen lösbar. Die Nullstellen des Polynoms

$$p(z) = z^n + a_{n-1}z^{n-1} + \dots + a_1z + a_0$$

sind die Eigenwerte seiner **Frobenius-Begleitmatrix**

$$\mathbf{A} = \begin{bmatrix} 0 & & & & -a_0 \\ 1 & 0 & & & -a_1 \\ & \ddots & \ddots & & \vdots \\ & & & 1 & 0 \\ & & & & 1 & -a_{n-1} \end{bmatrix} \in \mathbb{C}^{n \times n}.$$

Ein Verfahren zur Berechnung von Eigenwerten mit endlich vielen Schritten würde somit zu einer „Formel“ für die Nullstellen eines Polynomes führen.

Das in diesem Kapitel betrachtete Verfahren, die **QR-Iteration**, berechnet die **Schur-Zerlegung** einer $n \times n$ Matrix in $O(n^3)$ Operationen.

Das QR-Verfahren für Eigenwertaufgaben

Vorbemerkungen

- „Direkte“ Verfahren zur Berechnung der Eigenwerte einer Matrix $A \in \mathbb{C}^{n \times n}$ beruhen darauf, die Matrix schrittweise in eine Form zu überführen, an der man die Eigenwerte ablesen kann.
- Da Ähnlichkeitstransformationen die Eigenwerte unverändert lassen, kommen diese hierfür in Frage.
- Ähnlichkeitstransformation auf **Diagonalform** ist nur für diagonalisierbare Matrizen möglich.
- **Unitäre** Transformation auf Diagonalform (attraktiver, weil numerisch stabiler) ist im Allgemeinen nur für normale Matrizen möglich.

Satz 6.1 (Schur-Zerlegung)

Jede Matrix $A \in \mathbb{C}^{n \times n}$ läßt sich durch unitäre Ähnlichkeitstransformation in obere Dreiecksgestalt überführen, d. h. es existieren eine unitäre Matrix U sowie eine obere Dreiecksmatrix T mit

$$A = UTU^H \quad \text{bzw.} \quad U^H A U = T \quad (\text{Schur-Form}).$$

Das QR-Verfahren für Eigenwertaufgaben

Vorbemerkungen

Ist eine Schur-Zerlegung $U^H A U = T$ vorhanden und gilt $Tx = \lambda x$, so ist Ux Eigenvektor von A zum Eigenwert λ . Es genügt also, Eigenvektoren von T zu bestimmen.

Ist $\lambda = t_{i,i}$ einfacher Eigenwert von T so gilt $(T - \lambda I)x = 0$, oder

$$0 = \begin{bmatrix} T_{11} - \lambda I & T_{12} & T_{13} \\ 0^T & 0 & T_{23} \\ 0 & 0 & T_{33} - \lambda I \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} (T_{11} - \lambda I)x_1 + T_{12}x_2 + T_{13}x_3 \\ T_{23}x_3 \\ (T_{33} - \lambda I)x_3 \end{bmatrix}$$

Da λ einfach ist, sind $T_{11} - \lambda I$ und $T_{33} - \lambda I$ invertierbar.

Insbesondere folgt aus $(T_{33} - \lambda I)x_3 = 0$ auch $x_3 = 0$ und somit

$$(T_{11} - \lambda I)x_1 = -T_{12}x_2.$$

Setzt man $x_2 = 1$, so ergibt sich

$$x = \begin{bmatrix} -(T_{11} - \lambda I)^{-1} T_{12} \\ 1 \\ 0 \end{bmatrix}.$$

Das QR-Verfahren für Eigenwertaufgaben

Vorbemerkungen

- Das QR-Verfahren besteht prinzipiell aus einer (geschickt gewählten) Folge unitärer Ähnlichkeitstransformationen, die A immer näher an Schur-Form bringen.
- Man kann den Rechenaufwand für diese Transformationen reduzieren, indem man A zunächst (ebenfalls unitär ähnlich) auf obere Hessenberg-Gestalt bringt. Der Aufwand hierfür beträgt $O(n^3)$ Rechenoperationen.
- Für unitäre Ähnlichkeitstransformation angewandt auf Hessenberg-Matrizen beträgt der Aufwand $O(n^2)$ Operationen.
- Im Allgemeinen konvergiert das QR-Verfahren dann in $O(n)$ Schritten, woraus sich ein Gesamtaufwand von $O(n^3)$ ergibt. (Ohne Hessenberg-Reduktion $O(n^4)$.)
- Auch das QR-Verfahren schaffte es in die Liste der **zehn wichtigsten numerischen Algorithmen des 20. Jahrhunderts**.

- 1 Einleitung
- 2 Krylov-Unterraumverfahren
- 3 Lineare Gleichungssysteme
- 4 Matrixfunktionen
- 5 Krylov-Verfahren für Matrixfunktionen
- 6 Das QR-Verfahren für Eigenwertaufgaben
 - 6.1 Reduktion auf Hessenberg-Gestalt
 - 6.2 Vektoriteration
 - 6.3 QR-Iteration

Das QR-Verfahren für Eigenwertaufgaben

Reduktion auf Hessenberg-Gestalt

Eine Matrix $\mathbf{A} = [a_{i,j}] \in \mathbb{C}^{n \times n}$ heißt **obere Hessenberg-Matrix**, falls

$$a_{i,j} = 0 \quad \text{falls } i > j + 1.$$

Im 5×5 -Beispiel:

(\times bezeichnet beliebige Einträge, i.A. $\neq 0$)

$$\begin{bmatrix} \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix}$$

Satz 6.2

Zur jeder Matrix $\mathbf{A} \in \mathbb{C}^{n \times n}$ existiert eine unitäre Matrix $\mathbf{U} \in \mathbb{C}^{n \times n}$ sodass $\mathbf{U}^H \mathbf{A} \mathbf{U} = \mathbf{H}$ obere Hessenberg-Matrix ist.

Die unitäre Transformation auf obere Hessenberg-Gestalt ist in endlich vielen Schritten möglich (s.u.). Der Schritt zur Schur-Form, d.h. die Elimination der verbleibenden unteren Nebendiagonalen mittels unitärer Transformationen, ist jedoch ein iterativer, i.A. unendlicher Prozess.

Das QR-Verfahren für Eigenwertaufgaben

Reduktion auf Hessenberg-Gestalt

Algorithmus 14: Transformation auf Hessenberg-Gestalt.

Gegeben: $A \in \mathbb{C}^{n \times n}$.

- 1 **for** $k = 1$ **to** $n - 2$ **do**
 - 2 $[v, \beta] \leftarrow \text{house}(A(k + 1 : n, k))$
 - 3 $A(k + 1 : n, k : n) \leftarrow (I - \beta v v^H) A(k + 1 : n, k : n)$
 - 4 $A(1 : n, k + 1 : n) \leftarrow A(1 : n, k + 1 : n)(I - \beta v v^H)$
-

Dabei liefert die Funktion $[v, \beta] = \text{house}(x)$ zu $x \in \mathbb{C}^n$ einen Vektor $v \in \mathbb{C}^n$, den sog. **Householder-Vektor**, mit $v_1 = 1$ sowie $\beta \in \mathbb{R}$ sodass

$$P = I - \beta v v^H \text{ unitär} \quad \text{und} \quad P x = \|x\|_2 \frac{x_1}{|x_1|} e_1.$$

Dieser Algorithmus erfordert $10n^3/3$ Flops, $4n^3/3$ zusätzliche Flops falls U explizit benötigt wird.

Das QR-Verfahren für Eigenwertaufgaben

Reduktion auf Hessenberg-Gestalt

Wir zeigen das Vorgehen der Reduktion auf Hessenberg-Gestalt durch Householder-Transformationen anhand einer beliebigen 6×6 -Matrix A auf.

Bezeichnet $\tilde{P}_1 \in \mathbb{C}^{(n-1) \times (n-1)}$ eine Householder-Transformation, welche den Vektor $A(2:n, 1)$ auf ein Vielfaches von $e_1 \in \mathbb{C}^{n-1}$ abbildet, so ergibt

$$P_1^H A = \begin{bmatrix} 1 & \mathbf{0}^T \\ \mathbf{0} & \tilde{P}_1 \end{bmatrix} \begin{bmatrix} \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \end{bmatrix} = \begin{bmatrix} \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \end{bmatrix}$$

Anschließend Multiplikation von rechts mit P_1 lässt die erste Spalte unverändert, sodass wir mit $A_1 := P_1^H A P_1$ eine zu A unitär ähnliche Matrix erhalten mit Nullen unterhalb der ersten Nebendiagonalen in der ersten Spalte.

Das QR-Verfahren für Eigenwertaufgaben

Reduktion auf Hessenberg-Gestalt

Mit der zweiten Spalte verfahren wir analog: bildet die Householder-Matrix $\tilde{P}_2 \in \mathbb{C}^{(n-2) \times (n-2)}$ den Vektor $A_1(3 : n, 2)$ auf ein Vielfaches von $e_1 \in \mathbb{C}^{n-3}$ ab, so wirkt die unitäre Matrix von links multipliziert

$$P_2^H = \begin{bmatrix} I_2 & O \\ O & \tilde{P}_2 \end{bmatrix}$$

nur auf die Zeilen 3 bis n , analog P_3 von rechts multipliziert nur auf Spalten 3 bis n , und wir erhalten

$$A_2 = (P_1 P_2)^H A (P_1 P_2) = \begin{bmatrix} \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \end{bmatrix}$$

Das QR-Verfahren für Eigenwertaufgaben

Reduktion auf Hessenberg-Gestalt

In 2 weiteren Schritten mit immer kleineren Householder-Transformationen erhalten wir

$$\mathbf{A}_2 \xrightarrow{P_3} \mathbf{A}_3 = \begin{bmatrix} \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times & \times \end{bmatrix} \xrightarrow{P_4} \mathbf{A}_4 = \begin{bmatrix} \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & 0 & \times & \times \end{bmatrix}.$$

Die unitäre Transformation auf obere Hessenberg-Gestalt lautet insgesamt

$$\mathbf{A}_4 = \mathbf{U}^H \mathbf{A} \mathbf{U}, \quad \mathbf{U} = \mathbf{P}_1 \mathbf{P}_2 \mathbf{P}_3 \mathbf{P}_4.$$

- 1 Einleitung
- 2 Krylov-Unterraumverfahren
- 3 Lineare Gleichungssysteme
- 4 Matrixfunktionen
- 5 Krylov-Verfahren für Matrixfunktionen
- 6 Das QR-Verfahren für Eigenwertaufgaben
 - 6.1 Reduktion auf Hessenberg-Gestalt
 - 6.2 Vektoriteration
 - 6.3 QR-Iteration

Das QR-Verfahren für Eigenwertaufgaben

Vektoriteration

Der Prototyp aller numerischer Eigenwertverfahren ist die sog. **Vektoriteration** nach von Mises, auch **Potenzmethode** (engl. **power method**) genannt. Es beruht auf der Tatsache, dass für (nahezu) jeden Vektor $q \in \mathbb{C}^n$ die Vektorfolge

$$q, Aq, A^2q, A^3q, \dots$$

asymptotisch in Richtung eines Eigenvektors von A zum betragsgrößten Eigenwert zeigt. In seiner einfachsten Form lautet das Verfahren wie folgt:

Algorithmus 15: Vektoriteration nach von Mises.

Gegeben: $A \in \mathbb{C}^{n \times n}$, $q_0 \in \mathbb{C}^n$.

```
1 for  $k = 1$  to ... do
2    $z_k \leftarrow Aq_{k-1}$ 
3    $q_k \leftarrow z_k / \|z_k\|_2$ 
4    $\mu_k \leftarrow q_k^H Aq_k$ 
```

Wie man sieht, wird, allein schon um Gleitpunktüber-/unterlauf zu vermeiden, der Vektor zusätzlich in jedem Schritt normiert.

Lemma 6.3

Sei $\mathbf{A} \in \mathbb{C}^{n \times n}$ und $\mathbf{u} \in \mathbb{C}^n \setminus \{\mathbf{0}\}$. Der Ausdruck $\|\mathbf{A}\mathbf{u} - \mu\mathbf{u}\|_2$ wird minimiert für

$$\mu = \frac{\mathbf{u}^H \mathbf{A} \mathbf{u}}{\mathbf{u}^H \mathbf{u}} \quad (\text{Rayleigh-Quotient}).$$

Ferner ist $\mathbf{A}\mathbf{u} - \mu\mathbf{u} \perp \mathbf{u}$.

Ist \mathbf{A} diagonalisierbar mit Eigenwerten

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_{n-1}| \geq |\lambda_n|$$

und einer Basis $\{\mathbf{v}_j\}_{j=1}^n$ aus zugehörigen Eigenvektoren, so gilt mit Startvektor

$$\mathbf{q} = \gamma_1 \mathbf{v}_1 + \dots + \gamma_n \mathbf{v}_n,$$

für die Richtung der Iterierten im k -ten Schritt

$$\begin{aligned} \mathbf{A}^k \mathbf{q} &= \lambda_1^k \gamma_1 \mathbf{v}_1 + \dots + \lambda_n^k \gamma_n \mathbf{v}_n \\ &= \lambda_1^k \left(\gamma_1 \mathbf{v}_1 + \left(\frac{\lambda_2}{\lambda_1} \right)^k \gamma_2 \mathbf{v}_2 + \dots + \left(\frac{\lambda_n}{\lambda_1} \right)^k \gamma_n \mathbf{v}_n \right) \\ &\approx \lambda_1^k \gamma_1 \mathbf{v}_1. \end{aligned}$$

Sofern nur $\gamma_1 \neq 0$ klingen die übrigen Komponenten der Iterierten (linear) ab mit mindestens der Rate $|\lambda_2/\lambda_1|$.

Wir betrachten die Matrix (MATLAB-Notation)

$$\mathbf{A} = \text{diag}(100 : -1 : 1) + \frac{1}{3} \text{triu}(\text{ones}(100), 1)$$

mit Eigenwerten

$$\Lambda(\mathbf{A}) = \{1, 2, \dots, 100\}.$$

und wenden die Vektoriteration an mit Startvektoren


- $\mathbf{q}_0 = \text{ones}(100, 1)$ bzw.
- $\mathbf{q}_0 = \sum_{j=1}^{99} \mathbf{v}_j.$

Das QR-Verfahren für Eigenwertaufgaben

Vektoriteration

$\mathbf{q}_0 = \text{ones}(100, 1)$:

$$\|A\mathbf{q}_k - \mu_k \mathbf{q}_k\|_2 \quad \angle(\mathbf{q}_k, \mathbf{v}_{100}) \quad |100 - \mu_k|$$




Das QR-Verfahren für Eigenwertaufgaben

Vektoriteration

$$\mathbf{q}_0 = \mathbf{v}_1 + \cdots + \mathbf{v}_{99} :$$

$\ A\mathbf{q}_k - \mu_k \mathbf{q}_k\ _2$	$\angle(\mathbf{q}_k, \mathbf{v}_{100})$	$ 100 - \mu_k $
	$\angle(\mathbf{q}_k, \mathbf{v}_{99})$	$ 99 - \mu_k $



Das QR-Verfahren für Eigenwertaufgaben

Inverse Iteration

- Ist man an einem anderen als dem dominanten Eigenpaar interessiert, leistet die einfache Vektoriteration nicht das Gewünschte.
- Ist man jedoch bereit, in jedem Schritt ein lineares Gleichungssystem zu lösen, so kann man die Vektoriteration anstatt auf \mathbf{A} auf die Matrix

$$(\mathbf{A} - \sigma \mathbf{I})^{-1}$$

anwenden. Den Parameter σ bezeichnet man dabei als **Shift** („Verschiebung“).

- Der betragsgrößte Eigenwert der geshifteten Matrix ist gegeben durch

$$\frac{1}{\lambda(\sigma) - \sigma} \quad \lambda(\sigma) := \arg \min_{\lambda \in \Lambda(\mathbf{A})} |\lambda - \sigma|.$$

- Durch geeignete Wahl von σ kann man so die Konvergenz der Vektoriteration steuern.

Das QR-Verfahren für Eigenwertaufgaben

Inverse Iteration

Algorithmus 16: Inverse Iteration.

Gegeben: $A \in \mathbb{C}^{n \times n}$, $q_0 \in \mathbb{C}^n$, $\sigma \in \mathbb{C} \setminus \Lambda(A)$.

- 1 **for** $k = 1$ **to** ... **do**
 - 2 $z_k \leftarrow (A - \sigma I)^{-1} q_{k-1}$
 - 3 $q_k \leftarrow z_k / \|z_k\|_2$
 - 4 $\mu_k \leftarrow q_k^H A q_k$
-

- 1 Einleitung
- 2 Krylov-Unterraumverfahren
- 3 Lineare Gleichungssysteme
- 4 Matrixfunktionen
- 5 Krylov-Verfahren für Matrixfunktionen
- 6 Das QR-Verfahren für Eigenwertaufgaben
 - 6.1 Reduktion auf Hessenberg-Gestalt
 - 6.2 Vektoriteration
 - 6.3 QR-Iteration

Das QR-Verfahren für Eigenwertaufgaben

Simultane Iteration

Die Erweiterung der Vektoriteration auf mehrere (orthogonal gehaltene) Vektoren ist als **simultane Iteration** (simultaneous/subspace/orthogonal iteration) bekannt.

Algorithmus 17: Simultane Iteration.

Gegeben: $A \in \mathbb{C}^{n \times n}$, $Q_0 \in \mathbb{C}^{n \times p}$ mit orthonormalen Spalten.

- 1 **for** $k = 1$ **to** \dots **do**
 - 2 $Z_k \leftarrow A Q_{k-1}$
 - 3 QR-Zerlegung $Z_k = Q_k R_k$
-

Satz 6.4

Sei $A \in \mathbb{C}^{n \times n}$ diagonalisierbar mit $A = X \Lambda X^{-1}$, die Beträge der Eigenwerte von A paarweise verschieden und alle Hauptuntermatrizen von X invertierbar. Dann konvergiert bei simultaner Iteration mit $p = n$ und Startvektor $Q_0 = I$ die Folge der Matrizen $A_k := Q_k^H A Q_k$ gegen eine obere Dreiecksmatrix, auf deren Hauptdiagonalen die Eigenwerte von A in Reihenfolge abnehmenden Betrags erscheinen.

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

Algorithmus 18: QR-Iteration.

Gegeben: $A \in \mathbb{C}^{n \times n}$, $A_0 := A$.

- 1 **for** $k = 0$ **to** ... **do**
 - 2 $A_k = Q_k R_k$ (QR-Zerlegung)
 - 3 $A_{k+1} \leftarrow R_k Q_k$.
-

Wegen $A_{k+1} = R_k Q_k = Q_k^H Q_k R_k Q_k = Q_k^H A_k Q_k$ sind A_{k+1} und A_k unitär ähnlich.

Lemma 6.5

Für die durch Algorithmus 18 erzeugte Folge $\{A_k\}$ gilt $A_k = \tilde{Q}_k^H A \tilde{Q}_k$, wobei \tilde{Q}_k die durch simultane Iteration mit Startmatrix $\tilde{Q}_0 = I$ bezeichnet. Somit konvergiert A_k gegen obere Dreiecksform, sofern die Eigenwerte von A paarweise verschiedene Beträge besitzen.

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

Als nächstes beschleunigen wir die Konvergenz der QR-Iteration durch Einbringen von Shifts:

Algorithmus 19: QR-Iteration mit Shifts.

Gegeben: $A \in \mathbb{C}^{n \times n}$, $A_0 := A$.

- 1 **for** $k = 0$ **to** \dots **do**
 - 2 Wähle Shift σ_k nahe an einem Eigenwert von A
 - 3 $A_k - \sigma_k I = Q_k R_k$ (QR-Zerlegung)
 - 4 $A_{k+1} \leftarrow R_k Q_k + \sigma_k I$.
-

Lemma 6.6

A_k und A_{k+1} sind unitär ähnlich.

Bemerkung 6.7

1. Ist \mathbf{R}_k regulär, so gilt auch $\mathbf{A}_{k+1} = \mathbf{R}_k \mathbf{A}_k \mathbf{R}_k^{-1}$.
2. Ist σ_k ein Eigenwert von \mathbf{A}_k , so konvergiert die QR-Iteration in einem Schritt.
3. Ist σ_k kein (exakter) Eigenwert, so sehen wir $[\mathbf{A}_{k+1}]_{n,n}$ dann als konvergiert an, wenn die restlichen Einträge der Zeile $\mathbf{A}_{k+1}(n, 1 : n - 1)$ hinreichend klein geworden sind.
4. Wahl geeigneter Shifts: Konvergenz gegen Schur-Form beginnt bei $\mathbf{A}_k(n, n)$; genauer: $\sigma_k = \mathbf{A}_k(n, n)$ führt zu quadratischer Konvergenz von $\mathbf{A}_k(n, n)$ gegen einen Eigenwert von \mathbf{A} .
Bei **reeller** Matrix \mathbf{A} : Konvergenz gegen komplexen Eigenwert möglich.

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

Besitzt A_k Hessenberg-Gestalt, so kann man den QR-Schritt

$$A_k - \sigma_k I = Q_k R_k, \quad A_{k+1} \leftarrow R_k Q_k + \sigma_k I$$

so durchführen, dass die Hessenberg-Struktur erhalten bleibt, indem man die QR-Zerlegung mit Givens-Rotationen durchführt.

Im folgenden 5×5 -Beispiel wird die obere Dreiecksstruktur nach sukzessiver Multiplikation mit Givens-Rotationen

$$G_{j,j+1}, \quad j = 1, \dots, n-1,$$

erreicht:

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

$$\begin{array}{ccc} \begin{bmatrix} \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix} & \xrightarrow{G_{1,2}} & \begin{bmatrix} \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix} & \xrightarrow{G_{2,3}} & \begin{bmatrix} \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix} \\ \\ \xrightarrow{G_{3,4}} & \begin{bmatrix} \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix} & \xrightarrow{G_{4,5}} & \begin{bmatrix} \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \\ 0 & 0 & 0 & 0 & \times \end{bmatrix} \end{array}$$

Fasst man alle $n - 1$ Givens-Rotationen zusammen als

$$Q^H := G_{n-1,n} G_{n-2,n-1} \cdots G_{1,2},$$

so ergibt sich

$$Q^H A = R, \quad \text{oder} \quad A = QR.$$

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

Die Matrix $Q = G_{1,2}^H \cdots G_{n-1,n}^H$ ist aufgrund des Besetzungsmusters ihrer Faktoren ebenfalls obere Hessenberg-Matrix. (Dies folgt auch aus dem zu $A = QR$ äquivalenten Ausdruck $Q = AR^{-1}$.)

Demzufolge ist mit A_k auch

$$A_{k+1} = R_k Q_k + \sigma_k I$$

obere Hessenberg-Matrix.

Satz 6.8

Beim QR-Schritt mit einfachem Shift bleibt die obere Hessenberg-Struktur erhalten.

Eine effiziente Implementierung des QR-Verfahrens arbeitet mit **impliziten Shifts**, d.h. die QR-Zerlegung der Hessenberg-Matrizen wird implizit als Produkt von elementaren unitären Matrizen konstruiert. Hierzu ist eine Tatsache hilfreich, die als **implizites Q-Theorem** bekannt ist.

Definition 6.9

Eine obere Hessenberg-Matrix $\mathbf{H} = [h_{i,j}]_{i,j=1}^n \in \mathbb{C}^{n \times n}$ heißt **unreduziert** (engl. unreduced), falls

$$h_{k+1,k} \neq 0 \quad \forall k = 1, 2, \dots, n-1.$$

Satz 6.10

Ein Eigenwert $\lambda \in \Lambda(\mathbf{A})$ einer unreduzierten Hessenberg-Matrix $\mathbf{A} \in \mathbb{C}^{n \times n}$ besitzt geometrische Vielfachheit Eins.

Satz 6.11 (Implizites Q-Theorem)

Seien $A \in \mathbb{C}^{n \times n}$ sowie zwei unitäre Matrizen $Q = [q_1, \dots, q_n]$ und $V = [v_1, \dots, v_n]$ gegeben, für welche die Matrizen

$$H = [h_{i,j}] = Q^H A Q \quad \text{und} \quad G = [g_{i,j}] = V^H A V$$

obere Hessenberg-Gestalt besitzen. Ferner sei $k := \min\{j : h_{j+1,j} = 0\}$ bzw. $k = n$ falls H unreduziert. Gilt dann $v_1 = q_1$, so gelten auch

$$v_j = \vartheta_j q_j \quad \text{mit} \quad |\vartheta_j| = 1, \quad |h_{j+1,j}| = |g_{j+1,j}|, \quad j = 2, \dots, k.$$

Falls $k < n$, so ist auch $g_{k+1,k} = 0$.

Interpretation: Sind

$$G = V^H A V \quad \text{und} \quad H = Q^H A Q$$

zwei unreduzierte Hessenberg-Matrizen und besitzen die unitären Matrizen V und Q die gleiche erste Spalte, so sind G und H im Wesentlichen gleich, d.h. es gilt $G = D^{-1} H D$ mit einer Diagonalmatrix $D = \text{diag}(\vartheta_1, \dots, \vartheta_n)$, $|\vartheta_j| = 1$.

Die implizite Berechnung der QR-Schritte $A_{k+1} = Q_k^H A_k Q_k$ geschieht nun wie folgt:

- (1) Berechne die erste Spalte von Q_k (skalares Vielfaches der ersten Spalte von $A_k - \sigma_k I$, ergibt sich also durch Normierung).
- (2) Bestimme restliche Spalten von Q_k so, dass Q_k unitär und A_{k+1} unreduzierte obere Hessenberg-Matrix.

Das implizite Q-Theorem stellt dann sicher, dass wir dann A_{k+1} bis auf Faktoren vom Betrag eins berechnet haben.

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

Wir illustrieren den impliziten QR-Schritt an folgendem 5×5 Beispiel:
 A_0 liege in unreduzierter Hessenberg-Gestalt vor.

$$G_1^H = \begin{bmatrix} c_1 & s_1 & & & \\ -\overline{s_1} & c_1 & & & \\ & & 1 & & \\ & & & 1 & \\ & & & & 1 \end{bmatrix}, \quad G_1^H A G_1 = \begin{bmatrix} \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times \\ + & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix}$$
$$G_2^H = \begin{bmatrix} 1 & & & & \\ & c_2 & s_2 & & \\ & -\overline{s_2} & c_2 & & \\ & & & 1 & \\ & & & & 1 \end{bmatrix}, \quad G_2^H A_1 G_2 = \begin{bmatrix} \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & + & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix}$$

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

$$\mathbf{G}_3^H = \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ & & c_3 & s_3 & \\ & & -\overline{s_3} & c_3 & \\ & & & & 1 \end{bmatrix}, \quad \mathbf{G}_3^H \mathbf{A}_2 \mathbf{G}_3 = \begin{bmatrix} \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & + & \times & \times \end{bmatrix}$$
$$\mathbf{G}_4^H = \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ & & 1 & & \\ & & & c_4 & s_4 \\ & & & -\overline{s_4} & c_4 \end{bmatrix}, \quad \mathbf{G}_4^H \mathbf{A}_3 \mathbf{G}_4 = \begin{bmatrix} \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times \end{bmatrix}$$

Diese sukzessive Wahl der Givens-Rotationen nennt man auch **bulge chasing**, da die von der ersten orthogonalen Ähnlichkeitstransformation erzeugte 'Beule' in der (3,1)-Position schrittweise entlang der zweiten unteren Nebendiagonalen 'gescheucht' wird.

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

Insgesamt besitzt nun $Q^H A Q$ wieder obere Hessenberg-Gestalt, mit

$$Q := G_1 G_2 G_3 G_4 = \begin{bmatrix} c_1 & \times & \times & \times & \times \\ s_1 & \times & \times & \times & \times \\ & s_2 & \times & \times & \times \\ & & s_3 & \times & \times \\ & & & s_4 & \times \end{bmatrix}.$$

- Die erste Spalte von Q lautet $[c_1, s_2, 0, \dots, 0]^T$.
- Nach dem impliziten Q-Theorem bestimmt diese (bis auf Faktoren vom Betrag Eins) die restlichen Spalten von Q .
- Wir wählen nun die erste Spalte von Q als skalares Vielfaches der ersten Spalte von $A - \sigma I$, also $[a_{11} - \sigma, a_{21}, 0, \dots, 0]^T$.
- Damit ist Q bereits der linke Faktor aus der QR-Zerlegung von $A - \sigma I$.

Das QR-Verfahren für Eigenwertaufgaben

QR-Iteration

- Komplexe Arithmetik ist etwa viermal teurer als reelle.
- Daher wäre es von Vorteil, für reelle Matrizen die QR-Iteration auch in reeller Arithmetik durchzuführen.
- Man nutzt dabei die Tatsache aus, dass nichtreelle Eigenwerte reeller Matrizen als konjugiert-komplexe Paare auftreten.
- Der **Doppelshift-Algorithmus von Francis** nutzt gleichzeitig die konjugiert-komplexen Shifts σ und $\bar{\sigma}$:

$$A_0 - \sigma I = Q_1 R_1$$

$$A_1 = R_1 Q_1 + \sigma I, \quad \text{d.h. } A_1 = Q_1^T A_0 Q_1,$$

$$A_1 - \bar{\sigma} I = Q_2 R_2,$$

$$A_2 = R_2 Q_2 + \bar{\sigma} I, \quad \text{d.h. } A_2 = Q_2^T A_1 Q_2 = Q_2^T Q_1^T A_0 Q_1 Q_2.$$

Lemma 6.12

Die orthogonalen Matrizen Q_1 , Q_2 können so gewählt werden, dass sie (und damit A_2) reell sind und die erste Spalte von $Q_1 Q_2$ leicht zu berechnen ist.

Zur Wahl von (einfachen und doppelten) Shifts:

- Beim einfachen Shift hatten für \mathbf{A}_k hatten wir $\sigma = \mathbf{A}_k(n, n)$ gewählt.
- Für einen Doppelshift wählt man σ und $\bar{\sigma}$ als die beiden Eigenwerte des rechten unteren 2-Blocks $\mathbf{A}_k(n-1:n, n-1:n)$.
Dieser Block konvergiert dann entweder gegen eine 2×2 Diagonalmatrix oder gegen eine 2×2 -Matrix deren (konjugiert-komplexe) Eigenwerte auch Eigenwerte von \mathbf{A} sind.
- Eigenwerte werden als konvergiert betrachtet sobald $a_{n,n-1}$ bzw. $a_{n-1,n-2}$ hinreichend klein geworden sind.
- Man kann zeigen: im Allgemeinen konvergieren diese Einträge quadratisch gegen Null. In der Praxis sind nicht mehr als zwei Iterationen pro Eigenwert erforderlich.
- Es sei erwähnt, dass trotz erfolgreichen Einsatzes dieses Verfahrens seit 60 Jahren noch einige Detailfragen bei der Konvergenzanalyse des QR-Verfahrens offen bleiben.

Konvergenz der QR-Iteration:

- Unter realistischen Annahmen kann man zeigen, dass das QR-Verfahren quadratisch konvergiert.
- Für hermitesche Matrizen erhöht sich diese Konvergenzordnung auf kubisch.
- Das hermitesche QR-Verfahren kann auch zur Berechnung der Singulärwertzerlegung eingesetzt werden.