

# Eigenwerte und Singularwertzerlegung

Magnus Vergin

21.01.2025

# Gliederung

---

1. **Eigenwerte und Singulärwerte**
2. **Beispiel**
3. **Charakteristisches Polynom**
4. **Symmetrische und Hermitesche Matrizen**
5. **Empfindlichkeit und Genauigkeit von Eigenwerten**
6. **QR-Algorithmus**
7. **Literatur**

# Eigenwerte und Singulärwertzerlegung

---

Ein Eigenwert und ein Eigenvektor einer quadratischen Matrix  $\mathbf{A}$  sind ein Skalar  $\lambda$  und ein von Null verschiedener Vektor  $\mathbf{x}$ , sodass gilt:

$$\mathbf{Ax} = \lambda\mathbf{x} \quad (1)$$

Ein Singulärwert und ein Paar von Singulärvektoren einer quadratischen oder rechteckigen Matrix  $\mathbf{A}$  sind ein nicht-negativer Skalar  $\sigma$  sowie zwei von Null verschiedene Vektoren  $\mathbf{u}$  und  $\mathbf{v}$ , sodass gilt:

$$\mathbf{Av} = \sigma\mathbf{u}, \quad \mathbf{A}^H\mathbf{u} = \sigma\mathbf{v} \quad (2)$$

$\mathbf{A}^H$  steht für die Hermitesche Transposition, was die komplex-konjugierte Transposition einer komplexen Matrix bezeichnet

# Eigenwertgleichung

---

Die Eigenwertgleichung für eine quadratische Matrix lässt sich schreiben als:

$$(\mathbf{A} - \lambda \mathbf{I})\mathbf{x} = 0, \quad \mathbf{x} \neq 0 \quad (3)$$

Dies impliziert, dass  $\mathbf{A} - \lambda \mathbf{I}$  singulär ist und daher:

$$\det(\mathbf{A} - \lambda \mathbf{I}) = 0 \quad (4)$$

- Charakteristisches Polynom von  $\mathbf{A}$
- Grad des Polynoms entspricht der Ordnung der Matrix
- $n \times n$ -Matrix hat  $n$  Eigenwerte

# Eigenwertzerlegung

---

- Seien  $\lambda_1, \lambda_2, \dots, \lambda_n$  die Eigenwerte einer Matrix  $\mathbf{A}$
- $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$  die zugehörigen Eigenvektoren.
- $\mathbf{\Lambda}$  als  $n \times n$ -Diagonalmatrix der Eigenwerte  $\lambda_j$  auf der Diagonale
- $\mathbf{X}$  als  $n \times n$ -Matrix, deren  $j$ -te Spalte  $\mathbf{x}_j$  ist
- dann gilt:

$$\mathbf{AX} = \mathbf{X\Lambda}. \quad (5)$$

# Eigenwertzerlegung

---

Wenn Eigenvektoren linear unabhängig sind und  $\mathbf{X}^{-1}$  existiert, dann gilt:

$$\mathbf{A} = \mathbf{X}\mathbf{\Lambda}\mathbf{X}^{-1}. \quad (6)$$

Falls die Eigenvektoren von  $\mathbf{A}$  nicht linear unabhängig sind, existiert eine solche Diagonale Zerlegung nicht.

# Singulärwertzerlegung

---

Gleichung für Singulärwerte und -vektoren lassen sich in Matrixform schreiben als:

$$\mathbf{A}\mathbf{V} = \mathbf{U}\mathbf{\Sigma}, \quad \mathbf{A}^H\mathbf{U} = \mathbf{V}\mathbf{\Sigma}^H \quad (7)$$

- $\mathbf{\Sigma}$ : Diagonalmatrix mit denselben Dimensionen wie  $\mathbf{A}$ , Hauptdiagonale mit Singulärwerten, Rest Nullen
- $\mathbf{U}, \mathbf{V}$ : Matrizen mit normierten Singulärvektoren als Spalten
- $\mathbf{U}^H\mathbf{U} = \mathbf{I}, \quad \mathbf{V}^H\mathbf{V} = \mathbf{I}$
- $\mathbf{U}, \mathbf{V}$  sind orthogonal (reell) oder unitär (komplex)

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H \quad (8)$$

# Bedeutung von Eigen- und Singulärwerten

---

- Eigenwerte sind relevant, wenn eine  $n \times n$ -Matrix  $\mathbf{A}$  als Abbildung eines  $n$ -dimensionalen Raums auf sich selbst betrachtet wird.
- Ziel: Basis finden, sodass die Matrix diagonal wird.
- Singulärwerte sind relevant, wenn eine  $m \times n$ -Matrix  $\mathbf{A}$  eine Abbildung eines  $n$ -dimensionalen Raums in einen  $m$ -dimensionalen Raum darstellt.
- Ziel: Basis im Definitionsbereich finden, um eine möglicherweise andere Basis im Zielbereich zu definieren, sodass die Matrix diagonal wird.

# Vollständige und ökonomische SVD

---

- Falls  $A$  eine  $m \times n$ -Matrix ist und  $m > n$ , dann ist  $U$  in der vollständigen SVD eine große, quadratische  $m \times m$ -Matrix. Die letzten  $m - n$  Spalten von  $U$  sind überflüssig und werden nicht benötigt, um  $A$  zu rekonstruieren.
- Eine alternative Version der SVD, die Speicherplatz spart, ist die sogenannte **ökonomische SVD**.
  - In der ökonomischen Version werden nur die ersten  $n$  Spalten von  $U$  und die ersten  $n$  Zeilen von  $\Sigma$  berechnet.
  - Die Matrix  $V$  bleibt die gleiche  $n \times n$ -Matrix in beiden Zerlegungen.
- Beide Zerlegungen können als  $A = U\Sigma V^H$  geschrieben werden, auch wenn  $U$  und  $\Sigma$  in der ökonomischen Zerlegung Untermatrizen der vollständigen Zerlegung sind.

# Vollständige und ökonomische SVD

---

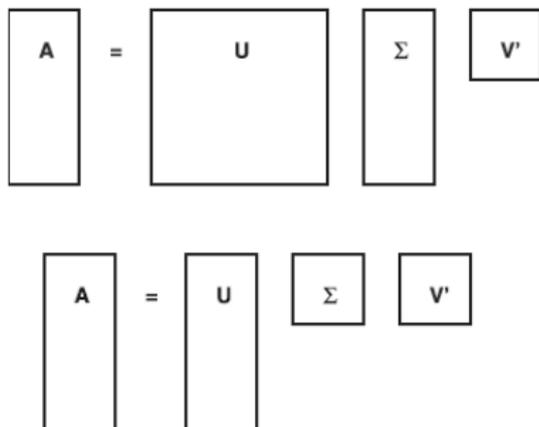


Figure 10.1. Full and economy SVDs.

Figure: 1

# Beispiel

---

Die Matrix  $\mathbf{A}$  lautet:

$$\mathbf{A} = \begin{bmatrix} -149 & -50 & -154 \\ 537 & 180 & 546 \\ -27 & -9 & -25 \end{bmatrix}$$

- Das charakteristische Polynom ist:

$$\det(\mathbf{A} - \lambda \mathbf{I}) = \lambda^3 - 6\lambda^2 + 11\lambda - 6 = (\lambda - 1)(\lambda - 2)(\lambda - 3)$$

- Eigenwerte:  $\lambda_1 = 1$ ,  $\lambda_2 = 2$ ,  $\lambda_3 = 3$

# Beispiel

---

$$[X, \Lambda] = \text{eig}(A)$$

$$\Lambda = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 3 \end{bmatrix}$$

$$\mathbf{X} = \begin{bmatrix} 0.3162 & -0.4041 & -0.1391 \\ -0.9487 & 0.9091 & 0.9740 \\ 0 & -0.2500 & 1.2857 \end{bmatrix}$$

*normalize(X, 1, 'scale', 'first')*

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & 1 \\ -3 & -2.2500 & -7 \\ 0 & -0.2500 & 1.2857 \end{bmatrix}$$

# Beispiel

---

$$\mathbf{\Lambda} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 3 \end{bmatrix}$$

Durch Skalierung der zweiten und dritten Spalte:

$$\mathbf{X} = \begin{bmatrix} 1 & -4 & 7 \\ -3 & 9 & -49 \\ 0 & 1 & 9 \end{bmatrix}$$

$\text{inv}(X)$

$$\mathbf{X}^{-1} = \begin{bmatrix} 130 & 43 & 133 \\ 27 & 9 & 28 \\ -3 & -1 & -3 \end{bmatrix}$$

Diese Matrizen liefern die Eigenwertzerlegung unseres Beispiels:

$$\mathbf{A} = \mathbf{X}\mathbf{\Lambda}\mathbf{X}^{-1}.$$

# Beispiel

---

$$[U,S,V] = \text{svd}(A)$$

$$\mathbf{U} = \begin{bmatrix} -0.2691 & -0.6798 & 0.6822 \\ 0.9620 & -0.1557 & 0.2243 \\ -0.0463 & 0.7167 & 0.6959 \end{bmatrix}$$

$$\mathbf{S} = \begin{bmatrix} 817.7597 & 0 & 0 \\ 0 & 2.4750 & 0 \\ 0 & 0 & 0.0030 \end{bmatrix}$$

$$\mathbf{V} = \begin{bmatrix} 0.6823 & -0.6671 & 0.2990 \\ 0.2287 & -0.1937 & -0.9540 \\ 0.6944 & 0.7193 & 0.0204 \end{bmatrix}$$

# Charakteristisches Polynom

---

Sei  $\mathbf{A}$  eine  $20 \times 20$ -Diagonalmatrix mit  $1, 2, \dots, 20$  auf der Diagonale.

- Eigenwerte von  $\mathbf{A}$  sind die Diagonalelemente.
- $\det(\mathbf{A} - \lambda \mathbf{I})$  ergibt:

$$\begin{aligned} P(\lambda) = & \lambda^{20} - 210\lambda^{19} + 20615\lambda^{18} - 1256850\lambda^{17} + 53327946\lambda^{16} \\ & - 1672280820\lambda^{15} + 40171771630\lambda^{14} - 756111184500\lambda^{13} \\ & + 11310276995381\lambda^{12} - 135585182899530\lambda^{11} \\ & + 1307535010540395\lambda^{10} - 10142299865511450\lambda^9 \\ & + 63030812099294896\lambda^8 - 311333643161390640\lambda^7 \\ & + 1206647803780373360\lambda^6 - 3599979517947607200\lambda^5 \\ & + 8037811822645051776\lambda^4 - 12870931245150988800\lambda^3 \\ & + 13803759753640704000\lambda^2 - 8752948036761600000\lambda \\ & + 2432902008176640000. \end{aligned}$$

# Charakteristisches Polynom

---

- Berechnung eines Polynoms in Potenzform ist anfällig für Rundungsfehler
- Speichern der Koeffizienten als IEEE-Gleitkommazahl verändert fünf Koeffizienten
- Beispielsweise ändern sich die letzten 3 Ziffern bei  $\lambda^4$  von 776 zu 392

# Charakteristisches Polynom

---

Auf 16 signifikante Stellen berechnete Koeffizienten:

1.000000000000000	10.99962843024064
2.000000000000096	12.00054374363591
2.99999999986640	12.99938073455790
4.00000000495944	14.00054798867380
4.99999991473414	14.99962658217055
6.00000084571661	16.00019208303847
6.9999945544845	16.99992773461773
8.00002443256894	18.00001875170604
8.99992001186835	18.99999699774389
10.00019696490537	20.00000022354640

# Symmetrische und Hermitesche Matrizen

---

- Eine reelle Matrix ist symmetrisch, wenn sie gleich ihrer Transponierten ist:

$$\mathbf{A} = \mathbf{A}^T \quad (9)$$

- Eine komplexe Matrix ist Hermitesch, wenn sie gleich ihrer komplex-konjugierten Transponierten ist:

$$\mathbf{A} = \mathbf{A}^H \quad (10)$$

# Eigenwerte und Eigenvektoren

---

- Die Eigenwerte und Eigenvektoren einer reellen symmetrischen Matrix sind reell.
- Die Matrix der Eigenvektoren kann so gewählt werden, dass sie orthogonal ist. Daher lautet die Eigenwertzerlegung für  $A$ , wenn  $A = A^T$ :

$$\mathbf{A} = \mathbf{X}\mathbf{\Lambda}\mathbf{X}^T \quad (11)$$

wobei  $\mathbf{X}^T\mathbf{X} = \mathbf{I}$  und  $\mathbf{\Lambda}$  eine Diagonalmatrix ist.

# Eigenwerte und Eigenvektoren

---

- Die Eigenwerte einer Hermiteschen Matrix sind reell, auch wenn die Eigenvektoren komplex sein können.
- Die Matrix der Eigenvektoren kann so gewählt werden, dass sie unitär ist. Daher lautet die Eigenwertzerlegung für  $A$ , wenn  $A = A^H$ :

$$\mathbf{A} = \mathbf{X}\mathbf{\Lambda}\mathbf{X}^H \quad (12)$$

wobei  $\mathbf{X}^H\mathbf{X} = \mathbf{I}$  und  $\mathbf{\Lambda}$  reell ist.

# Beziehung zwischen Eigen- und Singulärwerten

---

- Für symmetrische und hermitesche Matrizen sind die Eigenwerte und Singulärwerte eng miteinander verknüpft.
- Ein nicht-negativer Eigenwert ( $\lambda \geq 0$ ) ist auch ein Singulärwert:

$$\sigma = \lambda \quad (13)$$

- Die zugehörigen Vektoren sind:

$$\mathbf{u} = \mathbf{v} = \mathbf{x} \quad (14)$$

- Ein negativer Eigenwert ( $\lambda < 0$ ) wird in der Singulärwertzerlegung als dessen Absolutwert dargestellt:

$$\sigma = |\lambda| \quad (15)$$

- Ein zugehöriger Singulärvektor ist das Negative des anderen:

$$\mathbf{u} = -\mathbf{v} = \mathbf{x} \quad (16)$$

# Empfindlichkeit und Genauigkeit von Eigenwerten

---

- Eigenwerte einer Matrix sind empfindlich gegenüber Störungen.
- Angenommen,  $A$  besitzt eine vollständige Menge linear unabhängiger Eigenvektoren, sodass die Eigenwertzerlegung

$$A = X\Lambda X^{-1} \quad (17)$$

existiert. Umgeschrieben:

$$\Lambda = X^{-1}AX \quad (18)$$

- Nun sei  $\delta A$  eine kleine Änderung in  $A$  (z. B. durch Rundungsfehler). Dann ergibt sich:

$$\Lambda + \delta\Lambda = X^{-1}(A + \delta A)X \quad (19)$$

- Daraus folgt:

$$\delta\Lambda = X^{-1}\delta AX \quad (20)$$

# Empfindlichkeit und Genauigkeit von Eigenwerte

---

- Nimmt man die Norm, erhält man:

$$\|\delta\Lambda\| \leq \|X^{-1}\| \|X\| \|\delta A\| = \kappa(X) \|\delta A\| \quad (21)$$

- Dabei ist  $\kappa(X) = \|X^{-1}\| \|X\|$  die Konditionszahl der Eigenvektormatrix.
- Dies führt zu der Schlussfolgerung:  
*Die Empfindlichkeit der Eigenwerte wird durch die Konditionszahl der Eigenvektormatrix  $\kappa(X)$  bestimmt, nicht durch die Kondition der Matrix  $A$  selbst.*

# Beispiel

---

- In MATLAB kann man den Befehl `condest` zur Schätzung der Konditionszahl der Eigenvektormatrix nutzen.
- Für die Eigenvektormatrix  $\mathbf{X}$  der Matrix

$$\mathbf{A} = \begin{bmatrix} -149 & -50 & -154 \\ 537 & 180 & 546 \\ -27 & -9 & -25 \end{bmatrix}$$

gibt der Befehl `condest(X)` das Ergebnis  $1.2002 \times 10^3$ .

- Eine Störung der Matrix  $A$  könnte Störungen der Eigenwerte resultieren, die  $1.2 \times 10^3$  mal so groß sind.
- Die Eigenwerte der Matrix  $A$  sind schlecht konditioniert.

# Empfindlichkeit eines Eigenwerts und Eigenwert-Konditionszahl

---

- Durch detaillierte Analyse kann die Empfindlichkeit eines einzelnen Eigenwerts betrachtet werden.
- Die Eigenwert-Konditionszahl für einen spezifischen Eigenwert  $\lambda$  ist definiert als:

$$\kappa(\lambda, A) = \frac{\|y\| \|x\|}{|y^H x|} \quad (22)$$

- Dabei gilt:
  - $y$ : Linker Eigenvektor zu  $\lambda$ ,
  - $x$ : Rechter Eigenvektor zu  $\lambda$ ,
  - $y^H x$ : Das Skalarprodukt der beiden Vektoren.

# Empfindlichkeit eines Eigenwerts und Eigenwert-Konditionszahl

---

- Wenn  $y^H x = 1$  (durch Normierung), dann lautet die Konditionszahl:

$$\kappa(\lambda, A) = \|y\| \|x\| \quad (23)$$

- Da  $x \leq X$  und  $y \leq X^{-1}$ , gilt:

$$\kappa(\lambda, A) \leq \kappa(X) \quad (24)$$

# Konditionszahl des Eigenwerts in MATLAB

---

- In MATLAB kann man mit dem Befehl `condeig` die Konditionszahl des Eigenwerts berechnen.
- Wenn wir bei unserem Beispiel der Matrix **A** bleiben, ergibt das für die Eigenwerte  $\lambda = [1.0000, 2.0000, 3.0000]$ :

$$\kappa = [603.6390, 395.2366, 219.2920]$$

- Die Ergebnisse lassen darauf schließen, dass  $\lambda_1 = 1$  etwas fehleranfälliger ist als  $\lambda_2 = 2$  und  $\lambda_3 = 3$ .

# Eigenschaften symmetrischer und hermitescher Matrizen

---

- Wenn  $A$  reell und symmetrisch, oder komplex und hermitesch ist, dann sind der linke und rechte Eigenvektor derselbe.
- Also gilt für symmetrische und hermitesche Matrizen:

$$\kappa(\lambda, A) = 1 \quad (25)$$

- Eigenwerte symmetrischer und hermitescher Matrizen sind wohl konditioniert.
- Störungen der Matrix führen zu Störungen der Eigenwerte in der gleichen Größenordnung.

# Mehrfache Eigenwerte und ihre Auswirkungen

---

- Wenn  $\lambda_k$  ein mehrfacher Eigenwert ist, müssen die Eigenvektoren nicht linear unabhängig sein.
- Das charakteristische Polynom  $p(\lambda)$  lässt sich schreiben als:

$$p(\lambda) = \det(A - \lambda I) = (\lambda - \lambda_k)^m q(\lambda) \quad (26)$$

- Dabei ist  $m$  die Multiplizität von  $\lambda_k$  und  $q(\lambda)$  ein Polynom vom Grad  $n - m$ .

# Mehrfache Eigenwerte und ihre Auswirkungen

---

- Eine Störung der Matrix der Größenordnung  $\delta$  führt zu einer Änderung des charakteristischen Polynoms  $p(\lambda) = 0$  zu:

$$p(\lambda) = O(\delta) \tag{27}$$

- Daher gilt:

$$(\lambda - \lambda_k)^m = \frac{q(\lambda)}{O(\delta)} \tag{28}$$

- Die Eigenwerte ändern sich wie folgt:

$$\lambda = \lambda_k + O(\delta^{1/m}) \tag{29}$$

# Beispiel

---

- Die Matrix  $A$  sieht folgendermaßen aus:

$$A = \begin{pmatrix} 2 & 1 & 0 & 0 & \cdots & 0 \\ 0 & 2 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 2 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & 1 \\ \delta & 0 & 0 & 0 & \cdots & 2 \end{pmatrix}$$

- Das charakteristische Polynom lautet:

$$(\lambda - 2)^{16} = \delta \tag{30}$$

# Beispiel

---

- Wenn  $\delta = 0$ , dann gibt es einen Eigenwert der Multiplizität 16 bei  $\lambda = 2$ .
- Wenn  $\delta$  der Größenordnung eines Rundungsfehlers entspricht, also  $\delta \approx 10^{-16}$ , dann liegen die Eigenwerte auf einem Kreis in der komplexen Ebene:

$$\text{Mittelpunkt} = 2, \quad \text{Radius} = (10^{-16})^{1/16} = 0.1$$

- Eine Störung durch einen Rundungsfehler ändert die Eigenwerte auf 16 verschiedene Werte, z.B.:

$$\lambda = 1.9, 2.1, 2.0924 + 0.0383i$$

# Empfindlichkeit und Genauigkeit von Singulärwerte

---

- Die Empfindlichkeit von Singulärwerten ist wesentlich einfacher zu charakterisieren.
- Das Singulärwertproblem ist immer wohl konditioniert.
- Die Störungsanalyse führt zu:

$$\Sigma + \delta\Sigma = U^H(A + \delta A)V \quad (31)$$

- Da  $U$  und  $V$  orthogonal oder unitär sind, gilt:

$$\|\delta\Sigma\| = \|\delta A\| \quad (32)$$

- Störungen beliebiger Größe in einer Matrix bewirken Störungen derselben Größe in ihren Singulärwerten.

# Empfindlichkeit und Genauigkeit von Singulärwerte

---

- Störungen und Genauigkeit werden relativ zur Norm der Matrix gemessen, die durch den größten Singulärwert  $\sigma_1$  gegeben ist:

$$\|A\|_2 = \sigma_1 \quad (33)$$

- Wenn die Singulärwerte sich über mehrere Größenordnungen erstrecken, können die kleineren Singulärwerte nicht die volle relative Genauigkeit erreichen.
- Insbesondere gilt:
  - Wenn die Matrix singulär ist, sind einige der  $\sigma_i$  genau null.
  - Die berechneten Werte dieser  $\sigma_i$  liegen typischerweise in der Größenordnung von  $\varepsilon\|A\|$ , wobei  $\varepsilon$  der Gleitkomma-Genauigkeitsparameter ist.

# QR-Algorithmus

---

- Der QR-Algorithmus basiert auf der wiederholten Anwendung der QR-Faktorisierung.
- Jede Matrix  $A$  kann in das Produkt einer orthogonalen Matrix  $Q$  und einer oberen Dreiecksmatrix  $R$  zerlegt werden:

$$A = QR \tag{34}$$

# QR-Algorithmus - Beispiel

---

$n = \text{size}(A,1)$ ,  $I = \text{eye}(n,n)$

$s = A(n,n)$ ;  $[Q,R] = \text{qr}(A - s*I)$ ;  $A = R*Q + s*I$

$$\mathbf{A} = \begin{bmatrix} -149 & -50 & -154 \\ 537 & 180 & 546 \\ -27 & -9 & -25 \end{bmatrix}$$

Nach der ersten Iteration:

$$\begin{pmatrix} 28.8263 & -259.8671 & 773.9292 \\ 1.0353 & -8.6686 & 33.1759 \\ -0.5973 & 5.5786 & -14.1578 \end{pmatrix}$$

# QR-Algorithmus - Beispiel

---

Nach fünf weiteren Iterationen:

$$\begin{pmatrix} 2.7137 & -10.5427 & -814.0932 \\ -0.0767 & 1.4719 & -76.5847 \\ 0.0006 & -0.0039 & 1.8144 \end{pmatrix}$$

Nach fünf weiteren Iterationen:

$$\begin{pmatrix} 3.0716 & -7.6952 & 802.1201 \\ 0.0193 & 0.9284 & 158.9556 \\ 0.0000 & 0.0000 & 2.0000 \end{pmatrix}$$

# Optimierungen des QR-Algorithmus

---

- Der QR-Algorithmus wird in der Praxis nicht in dieser einfachen Form verwendet. Er enthält folgende Optimierungen:
- **Reduktion zur Hessenberg-Form:**
  - Bevor der Algorithmus beginnt, wird  $A$  auf Hessenberg-Form reduziert, wobei alle Elemente unterhalb der ersten Subdiagonale null sind.
  - Dies beschleunigt die Berechnung erheblich.

# Verbesserte Shift-Strategien im QR-Algorithmus

---

- Moderne Varianten des QR-Algorithmus verwenden weiterentwickelte Shift-Strategien, die je nach Typ der Matrix variieren:
- **Symmetrische Matrizen:**
  - Eine tridiagonale Reduktion ermöglicht eine effiziente Berechnung
  - QR-Algorithmus konvergiert immer
  - keine Beispiele bekannt, die trotz Rundungsfehlern dazu führen, dass Implimentierung in Matlab fehlschlägt

# SVD-Variante des QR-Algorithmus

---

- Für die Berechnung der Singulärwerte wird der Algorithmus so angepasst, dass er eine bidiagonale Form erhält, die die Singulärwerte bewahrt.
- dieselbe garantierte Konvergenzeigenschaft wie die symmetrische Eigenwertiteration

# Literatur

---

- Moler, C. B., Numerical Computing with Matlab, SIAM, 2004.
- Voß, H., Grundlagen der numerischen Mathematik, Technische Universität hamburg-Harburg, 2004
- Taboga, Marco (2021). "Linear independence of eigenvectors", Lectures on matrix algebra. <https://www.statlect.com/matrix-algebra/linear-independence-of-eigenvectors>.