

# Computergestützte Mathematik zur Linearen Algebra

## **Singulärwertzerlegung**

**Achim Schädle**

Übungsleiter: Lennart Jansen

Tutoren: Marina Fischer, Kerstin Ignatzy, Narin Konar  
Pascal Kuhn, Nils Sänger, Tran Dinh

8. Januar 2015

# Symmetrische Matrizen

**Erinnerung:** Für  $A \in \mathbb{R}^{n,n}$  symmetrisch, dann gilt

- alle Eigenwerte von  $A$  sind reell
- es gibt eine Orthonormalbasis  $\{q_1, \dots, q_n\}$  von Eigenvektoren von  $A$ :

$$Q^T A Q = D = \text{diag}(\lambda_1, \dots, \lambda_n)$$

wobei  $Q = [q_1 \mid \dots \mid q_n]$  orthogonal ( $Q^T Q = Q Q^T = I$ )

- Es gilt:  $\text{Rang}(A) = p$  genau dann, wenn genau  $p$  Eigenwerte  $\lambda_j$  von Null verschieden sind.

# Eigenschaften von $A^T A$

**Lemma.** Es sei  $A \in \mathbb{R}^{m,n}$ ,  $m \geq n$ .

- 1  $A^T A$  ist symmetrisch und positiv semidefinit.
- 2  $A^T A$  ist genau dann positiv definit, wenn  $\text{kern}(A) = \{0\}$ .
- 3 In jedem Fall gilt

$$\text{kern}(A^T A) = \text{kern}(A)$$

$$\text{bild}(A^T A) = \text{bild}(A^T) = \text{kern}(A)^\perp$$

# Beweis

- $A^T A$  symmetrisch ist offensichtlich. Ferner ist

$$x^T A^T A x = (Ax)^T (Ax) = \|Ax\|^2 \geq 0 \quad \text{für alle } x,$$

d.h.  $A^T A$  positiv semidefinit und  $\text{kern}(A^T A) \subset \text{kern}(A)$ . Wegen  $\text{kern}(A) \subset \text{kern}(A^T A)$  folgt  $\text{kern}(A^T A) = \text{kern}(A)$ .

- $\text{bild}(A^T A) \subset \text{bild}(A^T)$  ist klar, Gleichheit folgt aus

$$\begin{aligned} \dim \text{bild}(A^T A) &= n - \dim \text{kern}(A^T A) = n - \dim \text{kern}(A) \\ &= \text{rang}(A) = \dim \text{bild}(A) = \dim \text{bild}(A^T). \end{aligned}$$

- Seien  $z \in \text{bild}(A^T)$  und  $x \in \text{kern}(A)$  beliebig, dann gibt es  $y \in \mathbb{R}^m$  mit  $z = A^T y$  und  $x^T z = x^T A^T y = (Ax)^T y = 0$ .

# Singulärwertzerlegung

Es sei  $A \in \mathbb{R}^{m,n}$ ,  $m \geq n$  mit  $\text{Rang}(A) = p$ .  $\lambda_1, \dots, \lambda_n$  seien die absteigend sortierten Eigenwerte von  $A^T A$

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p > \lambda_{p+1} = \dots = \lambda_n = 0$$

und  $v_1, \dots, v_n \in \mathbb{R}^n$  sei eine Orthonormalbasis von Eigenvektoren (von  $A^T A$ ). Definiere

$$u_i = \frac{1}{\sqrt{\lambda_i}} A v_i, \quad i = 1, \dots, p,$$

dann gilt

$$u_i^T u_j = \frac{1}{\sqrt{\lambda_i}} \frac{1}{\sqrt{\lambda_j}} (A v_i)^T A v_j = \frac{1}{\sqrt{\lambda_i \lambda_j}} v_i^T (A^T A) v_j = \frac{\lambda_j}{\sqrt{\lambda_i \lambda_j}} v_i^T v_j = \delta_{ij}$$

## Singulärwertzerlegung II

Damit ist  $\{u_1, \dots, u_p\}$  eine Orthonormalbasis von  $\text{Bild}(A)$ , denn

$$\dim \text{bild}(A) = \dim \text{bild}(A^T A) = \text{rang}(A^T A) = p$$

Ergänze diese durch weitere  $m - p$  Vektoren  $u_{p+1}, \dots, u_m$  zu einer Orthonormalbasis von  $\mathbb{R}^m$ . Diese Vektoren spannen  $\text{bild}(A)^\perp = \text{kern}(A^T)$  auf:

$$A^T u_i = \frac{1}{\sqrt{\lambda_i}} A^T A v_i = \sqrt{\lambda_i} v_i, \quad i = 1, \dots, p$$

$$A^T u_i = 0 \quad i = p + 1, \dots, m$$

# Singulärwertzerlegung III

**Definition und Satz.** Jede Matrix  $A \in \mathbb{K}^{m,n}$  mit  $\text{rang}(A) = p$  besitzt eine **Singulärwertzerlegung**, d.h. ein System

$$\{\sigma_i, u_j, v_k \mid i = 1, \dots, p, j = 1, \dots, m, k = 1, \dots, n\}$$

mit  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p > 0$  und Orthonormalbasen  $\{u_j\}_{j=1}^m$  und  $\{v_k\}_{k=1}^n$  des  $\mathbb{K}^m$  bzw.  $\mathbb{K}^n$ , wobei

$$\begin{aligned} Av_i &= \sigma_i u_i, & A^T u_i &= \sigma_i v_i, & i &= 1, \dots, p, \\ Av_k &= 0, & A^T u_j &= 0, & j, k &> p \end{aligned}$$

$\sigma_i$  heißen **Singulärwerte** von  $A$ ,  $v_i$  **rechte** und  $u_i$  **linke Singulärvektoren**.

# Singulärwertzerlegung IV

In Matrixschreibweise:

$$U = [u_1, \dots, u_m] \in \mathbb{R}^{m,m}, \quad V = [v_1, \dots, v_n] \in \mathbb{R}^{n,n}$$
$$\Sigma = \begin{bmatrix} \sigma_1 & & 0 & 0 \\ & \ddots & & \vdots \\ 0 & & \sigma_p & 0 \\ 0 & \dots & 0 & 0 \end{bmatrix}$$

Dann gilt  $U^T U = I$ ,  $V^T V = I$  und

$$A = U \Sigma V^T, \quad A^T = V \Sigma^T U^T, \quad \Sigma = U^T A V,$$
$$A = \sum_{i=1}^p \sigma_i u_i v_i^T, \quad A^T = \sum_{i=1}^p \sigma_i v_i u_i^T$$



# Geometrische Interpretation

Durchlaufen die Vektoren

$$x = \alpha_i v_i + \alpha_j v_j + \alpha_k v_k, \quad \|x\|^2 = \alpha_i^2 + \alpha_j^2 + \alpha_k^2 = 1$$

die Einheitskugel des Unterraums  $\text{span}\{v_i, v_j, v_k\}$ , dann durchlaufen ihre Bilder

$$Ax = \sigma_i \alpha_i u_i + \sigma_j \alpha_j u_j + \sigma_k \alpha_k u_k, = \beta_i u_i + \beta_j u_j + \beta_k u_k,$$


ein Ellipsoid in dem durch  $u_i, u_j$  und  $u_k$  aufgespannten Teilraum des  $\mathbb{R}^m$ , denn

$$\frac{1}{\sigma_i^2} \beta_i^2 + \frac{1}{\sigma_j^2} \beta_j^2 + \frac{1}{\sigma_k^2} \beta_k^2 = \alpha_i^2 + \alpha_j^2 + \alpha_k^2 = 1$$

(Ellipsoid mit Scheitelpunkten  $(\pm\sigma_i, 0, 0)$ ,  $(0, \pm\sigma_j, 0)$ ,  $(0, 0, \pm\sigma_k)$  in den zu  $(u_i, u_j, u_k)$  gehörenden Koordinaten.)

# Beispiel

$$A = \begin{bmatrix} 1 & 2 \\ 0 & 2 \end{bmatrix}, \quad \text{Matlab: } [U, S, V] = \text{svd}(A)$$



# Eigenwert- / Singulärwertzerlegung

Für  $A \in \mathbb{R}^{n,n}$  diagonalisierbar gibt es  $X \in \mathbb{C}^{n,n}$  nicht singulär mit

$$A = X\Lambda X^{-1}, \quad \Lambda = \text{diag}(\lambda_1, \dots, \lambda_n) \in \mathbb{C}^{n,n}$$

Für  $A \in \mathbb{R}^{m,n}$  beliebig gibt es orthogonale Matrizen  $U \in \mathbb{R}^{m,m}$ ,  $V \in \mathbb{R}^{n,n}$  mit

$$A = U\Sigma V^T, \quad \Sigma = \text{diag}(\sigma_1, \dots, \sigma_n) \in \mathbb{R}^{m,n}$$

mit  $\sigma_i \geq 0$ .

# Anwendung

**Satz.** Sei  $A = U\Sigma V^T = \sum_{i=1}^n \sigma_i u_i v_i^T$  und  $A_k = \sum_{i=1}^k \sigma_i u_i v_i^T$ . Dann gilt

$$\|A - A_k\|_2 \leq \|A - B\|_2$$

für alle Matrizen  $B$  mit  $\text{rang } B = k$  und  $\|A - A_k\| = \sigma_{k+1}$ .

Es gilt auch  $A_k = U\Sigma_k V^T$  mit  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k, 0, \dots, k)$

**Anwendung:** Datenkompression

## Definition:

Eine Abbildung  $\|\cdot\| : \mathbb{C}^n \rightarrow \mathbb{R}$  heißt **Vektornorm**, wenn

- 1  $\|x\| \geq 0$  für alle  $x$  und  $\|x\| = 0 \iff x = 0$  (Positivität)
- 2  $\|x + y\| \leq \|x\| + \|y\|$  (Dreiecksungleichung)
- 3  $\|\alpha x\| = |\alpha| \|x\|$

Eine Abbildung  $\|\cdot\| : \mathbb{C}^{m,n} \rightarrow \mathbb{R}$  heißt **Matrixnorm**, wenn  $\|\cdot\|$  eine Vektornorm ist und zusätzlich

- 4  $\|AB\| \leq \|A\| \|B\|$  für alle  $A, B$  für die  $AB$  existiert

## Beispiele/Aufgabe

Schreiben Sie eine Matlab-Funktion `plotnorm(p)`, welche die Menge  $\{x \in \mathbb{R}^2 \mid \|x\|_p \leq 1\}$  plottet.

$$\|x\|_1 = \sum_{i=1}^n |x_i|$$

$$\|x\|_2 = \left( \sum_{i=1}^n |x_i|^2 \right)^{1/2} = \sqrt{x^T x}$$

$$\|x\|_\infty = \max_{i=1}^n |x_i|$$

$$\|x\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{1/p} \quad (1 \leq p < \infty)$$

# Induzierte Matrixnormen

Seien  $\|\cdot\|_{(n)}$  und  $\|\cdot\|_{(m)}$  Vektornorm über  $\mathbb{R}^n$  bzw.  $\mathbb{R}^m$ . Durch

$$\|A\|_{(m,n)} = \sup_{x \in \mathbb{R}^n \setminus \{0\}} \frac{\|Ax\|_{(m)}}{\|x\|_{(n)}} = \sup_{x \in \mathbb{R}^n, \|x\|=1} \|Ax\|_{(m)}$$

wird eine (von einer Vektornorm) **induzierte Matrixnorm** auf  $\mathbb{R}^{m,n}$  definiert.

Beispiele:  $\|A\|_1$  und  $\|A\|_\infty$

Sei  $A = [a_1 \mid a_2 \mid \cdots \mid a_n] \in \mathbb{C}^{m,n}$  und  $\|x\|_1 = 1$ :

$$\|Ax\|_1 = \left\| \sum_{j=1}^n x_j a_j \right\|_1 \leq \sum_{j=1}^n |x_j| \|a_j\|_1 \leq \max_{1 \leq j \leq n} \|a_j\|_1$$

Damit:  $\|A\|_1 \leq \max_{1 \leq j \leq n} \|a_j\|_1$

Für  $x = e_k$ , wobei  $k$  so, dass  $\|a_k\|_1 = \max_{1 \leq j \leq n} \|a_j\|_1$ , gilt Gleichheit, also

$$\|A\|_1 = \max_{1 \leq j \leq n} \|a_j\|_1 \quad \text{maximale Spaltensummennorm}$$

analog:

$$\|A\|_\infty = \max_{1 \leq i \leq n} \|A(i, :)\|^T \quad \text{maximale Zeilensummennorm}$$