

# Computergestützte Mathematik zur Linearen Algebra

## Singulärwertzerlegung

Christiane Helzel

21. Dezember 2017

# Singulärwertzerlegung

**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**.

$$A = U \Sigma V^H \quad \text{mit } u_i = U(:, i) \quad \text{und } v_i = V(:, i)$$

# Singulärwertzerlegung

In Matrixschreibweise:

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

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

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

# 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

$$A = \begin{bmatrix} 1 & 2 \\ 0 & 2 \end{bmatrix}, \text{ Python: } U, S, V = \text{np.linalg.svd}(A)$$



# Anwendung

**Satz.** Sei  $A = U\Sigma V^H = \sum_{i=1}^n \sigma_i u_i v_i^H$  und  $A_k = \sum_{i=1}^k \sigma_i u_i v_i^H$ . 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  $A_k = U\Sigma_k V^H$  mit  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k, 0, \dots, 0)$

**Anwendung:** Datenkompression