

# Recommendation Systems I

Nutzer n	Movies <sup>m</sup>			
	M1	M2	M3	M4
N1	5	3	-	1
N2	4	-	-	1
N3	1	1	-	5
N4	1	-	-	4
N5	-	1	5	4

z.B. Netflix  
Movielens


Ratingmatrix  $A = (a_{ij})$ ,  $i = 1, \dots, n \leftarrow \# \text{Nutzer}$   
 $j = 1, \dots, m \leftarrow \# \text{Movies}$   
 ↑  
 Bewertung des j-ten Movie  
 vom i-ten Nutzer

Frage: wie vervollständigt man die Ratingmatrix A und gibt Empfehlungen ab?

## ① Ähnlichkeit von Nutzern / Movies

cosine Similarity =  $\cos \alpha$

$$S(i, e) = \frac{\sum_{j \in \mathcal{U}(i) \cap \mathcal{U}(e)} a_{ij} \cdot a_{ej}}{\sqrt{\sum_{j \in \mathcal{U}(i) \cap \mathcal{U}(e)} a_{ij}^2} \cdot \sqrt{\sum_{j \in \mathcal{U}(i) \cap \mathcal{U}(e)} a_{ej}^2}} = \frac{a_i \cdot a_e}{\|a_i\| \cdot \|a_e\|}$$



$$\mathcal{U}(i) := \{j \mid a_{ij} \text{ existiert}\}$$

↑  
 Movies, für welche der i-te Nutzer Bewertung abgab.

Aber:  $a_i \parallel a_e \Rightarrow \cos \alpha = 1$

↳ Mittelwert einbeziehen:  $\bar{a}_i := \frac{1}{|\mathcal{U}(i)|} \sum_{j \in \mathcal{U}(i)} a_{ij}$

Korrelation =  $\frac{\text{cov}(X_i, X_e)}{\sigma_{X_i} \cdot \sigma_{X_e}}$

$$S(i, e) = \frac{\sum_{j \in \mathcal{U}(i) \cap \mathcal{U}(e)} (a_{ij} - \bar{a}_i) \cdot (a_{ej} - \bar{a}_e)}{\sqrt{\sum_{j \in \mathcal{U}(i) \cap \mathcal{U}(e)} (a_{ij} - \bar{a}_i)^2} \cdot \sqrt{\sum_{j \in \mathcal{U}(i) \cap \mathcal{U}(e)} (a_{ej} - \bar{a}_e)^2}}$$

← Elementenanzahl

$\kappa$ -Nearest Neighbor  
( $\kappa$  NN - Algorithm)

$N_{\downarrow}(i) = \{ \kappa \text{ Nutzer mit gr\u00f6\u00dftester \u00c4hnlichkeit zu } i \}$   
welche  $j$  bewertet haben  
 $\leftarrow$  existiert

$$a_{ij} := \frac{\sum_{e \in N_{\downarrow}(i)} S(i, e) \cdot a_{ej}}{\sum_{e \in N_{\downarrow}(i)} |S(i, e)|}$$

$\uparrow$   
gesch\u00e4tzt

- gewichtete Summe von Bewertungen aller  $\kappa$  Nutzer, die dem Nutzer  $i$  am \u00e4hnlichsten sind.

Analog: \u00c4hnlichkeit von Movies, da Nutzervektoren d\u00fcnnbesetzt ("sparse") sind. (ii)


- wenig Aussagekraft, da d\u00fcnnbesetzt
- suche nach verdeckten Mustern (z.B. Genre, Land, Schauspieler etc.)

## 2 Singular Value Decomposition (SVD) (Singularwertzerlegung)

Frage: wie kann man Merkmale/Features identifizieren?  
Nutzer bewerten (n)  $\rightarrow$  charakterisieren Movies (m)

Sei zun\u00e4chst  $A$  vollst\u00e4ndig, d.h. alle Eintr\u00e4ge seien vorhanden

$$B := A^T \cdot A \text{ - symmetrisch}$$



Multiplication

• Eigenwerte und Eigenvektoren:

o.B.d.A.  $\lambda_i \neq \lambda_j \forall i, j = 1, \dots, r$   
paarweise verschieden

$$B \cdot v_i = \lambda_i \cdot v_i, \quad i = 1, \dots, r$$

$\in \mathbb{R} \quad \in \mathbb{R}^m$  mit  $\lambda_i \neq 0$ .

$$B \cdot v_\ell = 0, \quad \ell = r+1, \dots, m$$

$$\begin{aligned} \textcircled{1} \quad v_j^T \cdot B \cdot v_i &= v_j^T \cdot \lambda_i \cdot v_i \\ \textcircled{2} \quad v_i^T \cdot B \cdot v_j &= v_i^T \cdot \lambda_j \cdot v_j \end{aligned}$$

$$v_i^T \cdot v_j = 0 \Rightarrow$$

- $v_1, \dots, v_m$  sind p.w. orthogonal (linear unabhängig)
- $\|v_i\|_2 = 1$  (o.B.d.A.) (normiert)

$$\textcircled{3} \quad \frac{(Av_i)^T \cdot (Av_i)}{\|Av_i\|_2^2} = v_i^T A^T A v_i = v_i^T B \cdot v_i = \lambda_i \cdot \frac{v_i^T v_i}{\|v_i\|_2^2} = \lambda_i$$

$= 1 \Rightarrow \lambda_i > 0, i = 1, \dots, r$  (positiv)



• Rang:  $\underbrace{d_i}_{\neq 0} v_i = B \cdot v_i = A^T \cdot A \cdot v_i \Rightarrow v_i = A^T \left( \frac{A \cdot v_i}{d_i} \right) \in \text{Bild}(A^T)$  (3)  
 $i=1, \dots, r$

$\Rightarrow$   $\text{Rang}(A^T) = r \Rightarrow \text{Rang}(A) = r$  Rang einer Matrix ist max. Anzahl l.u. Spalten/Zeilen  
 $v_i$  - l.u.

• Orthogonalität

$\mathbb{R}^n \ni u_i := \frac{1}{\sqrt{d_i}} A \cdot v_i, i=1, \dots, r$

$\Rightarrow u_i^T \cdot u_j = \frac{1}{\sqrt{d_i \cdot d_j}} (A v_i)^T \cdot A v_j = \frac{1}{\sqrt{d_i \cdot d_j}} v_i^T \cdot \underbrace{A^T \cdot A \cdot v_j}_{= B} = \frac{1}{\sqrt{d_i \cdot d_j}} \cdot \underbrace{d_j}_{= d_i} \cdot v_i^T \cdot v_j$   
orthogonal + normiert  
 $= \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases}$   
 für  $i, j=1, \dots, r$

• Zerlegung:  $\sigma_i$  - Singulärwerte

$\sum_{i=1}^r \sqrt{d_i} u_i v_i^T = \sum_{i=1}^r A \cdot v_i \cdot v_i^T = \sum_{i=1}^r A \cdot v_i \cdot v_i^T = A$


$\|A v_e\|_2^2 = (A v_e)^T \cdot A v_e = v_e^T \underbrace{A^T \cdot A}_{= B} \cdot v_e = 0 \Rightarrow A v_e = 0, e=r+1, \dots, m$

Rang 1 - Matrix  $n \times m$

$n \begin{bmatrix} | & | & | \\ u_1 & \dots & u_r \\ | & | & | \end{bmatrix} \cdot r \begin{bmatrix} \sigma_1 & & \\ & \dots & \\ & & \sigma_r \end{bmatrix} \cdot r \begin{bmatrix} -v_1^T & & \\ & \dots & \\ & & -v_r^T \end{bmatrix} = n \begin{bmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{bmatrix} = A$

$\textcircled{ii} u \cdot u = I_r$


$v \cdot v^T = I_r$



Bewertung des  $k$ -ten Feature vom  $i$ -ten Nutzer



Gewichtung von Feature  $k$



Ausprägung des  $k$ -ten Feature in Movie  $j$ .

Ziel: Features nachahmen, wenn  $A$  nicht vollständig ist.  
→ Principal Component Analysis.