



# INTELLIGENTE DATENANALYSE IN MATLAB

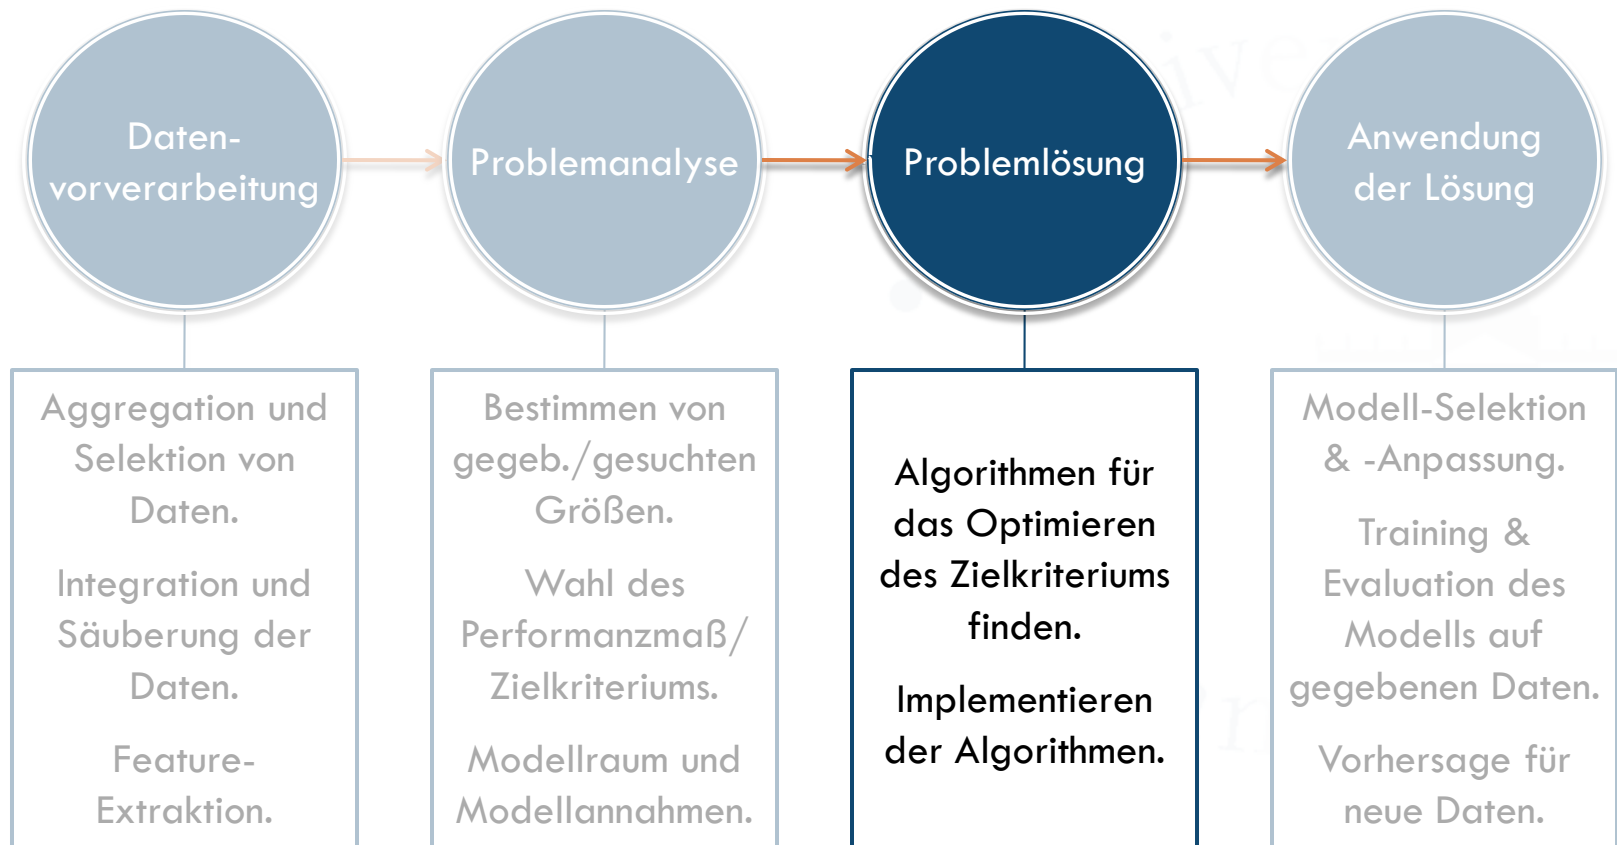
Collaborative Filtering

# Literatur

- Benjamin Marlin: Collaborative Filtering – A Machine Learning Perspective.
- Thomas Hofmann: Collaborative Filtering with Privacy via Factor Analysis.
- Robert Bell et. al: Scalable Collaborative Filtering with Jointly Derived Neighborhood Interpolation Weights.
- Markus Weimer et al.: CoFiRank.

# Überblick

## □ Schritte der Datenanalyse:



# Problemstellung

- Gegeben: Trainingsdaten mit mehreren (teilweise) bekannten nutzerabhängigen Sortierungen.
- Eingabe: Menge von Instanzen (mit/ohne Attribute), Nutzer (mit/ohne Attribute) und nutzerspezifische Instanz-Bewertungen.
- Ausgabe: Sortierung der Instanzen pro Nutzer.
  - Collaborative Filtering: Nur Instanz-Bewertungen teilweise bekannt.
  - Content-based Filtering: Eigenschaften von Instanzen und Nutzern bekannt; Präferenzen teilweise bekannt.

# Collaborative Filtering

## Motivation

### □ Beispiel:

- Empfehlungssysteme (*Recommendation Systems*) für Filme, Musik, Produkte, Restaurants, Nachrichten, Witze usw.

Predictions for you ↕	Your Ratings	Movie Information	Wish List
★★★★★	Not seen	<b>About a Boy (2002)</b> DVD, VHS, info   imdb Comedy, Drama	<input checked="" type="checkbox"/>
★★★★★	Not seen	<b>Chicago (2002)</b> info   imdb Comedy, Crime, Drama, Musical	<input checked="" type="checkbox"/>
★★★★★	Not seen	<b>And Your Mother Too (Y Tu Mamá También) (2001)</b> DVD, VHS, info   imdb Comedy, Drama, Romance	<input type="checkbox"/>
★★★★★	0.5 stars	<b>Monsoon Wedding (2001)</b> DVD, VHS, info   imdb Comedy, Romance	<input type="checkbox"/>
★★★★★	1.0 stars		
★★★★★	1.5 stars		
★★★★★	2.0 stars		
★★★★★	2.5 stars		
★★★★★	3.0 stars		
★★★★★	3.5 stars		
★★★★★	4.0 stars		
★★★★★	4.5 stars	<b>Talk to Her (Hable con Ella) (2002)</b> info   imdb Comedy, Drama, Romance	<input type="checkbox"/>
★★★★★	5.0 stars		

Film	Nutzer 1	Nutzer 2	Nutzer 3
About a Boy	5		4
Chicago	4	2	?
And Your M...			5
Monsoon Wedding	4	1	?
Talk to Her			4
Titanic			?
The Bourne Identity	2	2	?
SAW	1	5	?
Se7en		4	1
Earth			5
Stuart Little		1	?

Trainingsdaten

Zielgröße

# Collaborative Filtering

## Bewertungen: Erhebung

### □ Explizit:

- Bewertung einer Instanz auf einer Skala bzw. mehreren Skalen (z.B. bzgl. Qualität, Preis-Leistungsverhältnis).
- Textbeitrag (z.B. Buch-Rezension, Restaurant- & Hotelbeschreibung).

### □ Implizit:

- Kauf eines Artikels auf einer Webseite.
- Anklicken, Verweilen, Wechseln einer Webseite.
- Standortinformationen bei der Auswahl (z.B. Telefon- oder WLAN-Standort).

# Collaborative Filtering

## Bewertungen: Eigenschaften

### □ Umfang der Daten:

#### ■ Sehr wenig Bewertungen, z.B.

- Einzelner Kunde eines Web-Shops bewertet nur Bruchteil des Angebotes.
- Durchschnittliche „Besetzung“ einer Filmdatenbank beträgt nur ca. 2-5%.

Skalierbarkeit bzgl. Laufzeit  
und Speicherverbrauch

#### ■ Sehr viele Nutzer und Instanzen.

### □ Qualität der Daten:

- Nicht-zufälliges Fehlen von Bewertungen.
- Unterschiedliche Verteilung der Scores verschiedener Benutzer.
- Fehlerhafte/unfaire Bewertungen.
- Zeitliche Abhängigkeiten von Bewertungen (selbstverstärkend).

Robustheit und  
Generalisierungsfähigkeit

# Collaborative Filtering

## Ansatz

- Gegeben: Bewertungsmatrix  $Y$  wobei Instanz  $i = 1 \dots m$  von Nutzer  $j = 1 \dots n$  mit  $Y_{ij} \in [Y_{\min}, Y_{\max}]$  bewertet wurde und zahlreiche Bewertungen  $Y_{ij}$  unbekannt sind.
- Gesucht: Rating Scores  $R_{ij} \in \mathbb{R}$  für jeden Nutzer und jede Instanz.
- Ziel: Modell zur Vorhersage unbekannter Rating Scores.
  - Rating bzw. Ranking für bekannte  $Y_{ij}$  und zugehörige vorhergesagte Scores  $R_{ij}$  sollen möglichst gleich sein.
  - Hohe Generalisierungsfähigkeit/Robustheit.



# Collaborative Filtering

## Ansatz

- Modellierung als nutzerspezifische...
  - Rating-Vorhersage: Vorhersage des Scores (Klassifikations- bzw. Regressions-Problem).
  - Ranking-Vorhersage: Vorhersage der Reihenfolge (Ranking-Problem).
- Lösungsansätze:
  - *Ähnlichkeitsbasiert* (memory-based): Ähnliche Nutzer bewerten ähnlich und/oder ähnliche Instanzen werden ähnlich bewertet.
  - *Modellbasiert*: Jede Instanz hat versteckte Eigenschaften welche jeder Nutzer unterschiedlich bewertet; Eigenschaften und Bewertungen gleichzeitig aus Daten schätzen.

# Ähnlichkeitsbasiertes Filtern

## Nutzer-Nutzer-Ähnlichkeit

□ Annahmen:

- Ähnlichkeit  $U_{ij}$  zwischen Nutzer  $i$  und Nutzer  $j$  entspricht Ähnlichkeit gemeinsamer Bewertungen.

Film	Nutzer 1	Nutzer 2	Nutzer 3
About a Boy	5	3	4
Chicago	4	2	
And Your M...			5
Monsoon Wedding	4	1	4
Talk to Her	1		4

□ Nächste-Nachbarn-Modell:

- Unbekannte Bewertung = bekannte Bewertungen gewichtet mit Nutzer-Ähnlichkeit:

$$R_{ij} = \sum_{k \in B_j} \frac{U_{kj}}{\sum_{p \in B_j} U_{pj}} Y_{ik}$$

$B_j =$  Indexmenge  $\{k\}$  für welche  $Y_{kj}$  bekannt

	Nutzer 1	Nutzer 2	Nutzer 3
Nutzer 1	1,0	0,2	0,5
Nutzer 2	0,2	1,0	0,3
Nutzer 3	0,5	0,3	1,0

$$R_{23} = \frac{0,5 \cdot 4 + 0,3 \cdot 2}{0,5 + 0,3} = 3,25$$

# Ähnlichkeitsbasiertes Filtern

## Instanz-Instanz-Ähnlichkeit

### Annahmen:

- Ähnlichkeit  $V_{ij}$  zwischen Instanz  $i$  und Instanz  $j$  entspricht Ähnlichkeit gemeinsamer Bewertungen.

Film	Nutzer 1	Nutzer 2	Nutzer 3
About a Boy	5	3	4
Chicago	4	2	
And Your M...			5
Monsoon Wedding	4	1	4
Talk to Her	1		4

### Nächste-Nachbarn-Modell:

- Unbekannte Bewertung = bekannte Bewertungen gewichtet mit Instanz-Ähnlichkeit:

$$R_{ij} = \sum_{k \in B_i} \frac{V_{ik}}{\sum_{p \in B_i} V_{ip}} Y_{kj}$$

$B_i =$  Indexmenge  $\{k\}$  für welche  $Y_{ik}$  bekannt

	Film 1	Film 2	Film 3	Film 4	Film 5
Film 1	1,0	0,8	0,7	0,9	0,4
Film 2	0,8	1,0	0,1	0,9	0,2
Film 3	0,7	0,1	1,0	0,8	0,8
Film 4	0,9	0,9	0,8	1,0	0,6
Film 5	0,4	0,2	0,8	0,6	1,0

$$R_{23} = \frac{0,8 \cdot 4 + 0,1 \cdot 5 + 0,9 \cdot 4 + 0,2 \cdot 4}{0,8 + 0,1 + 0,9 + 0,2} = 4,05$$

# Ähnlichkeitsbasiertes Filtern

## Lösungsidee



### □ Allgemeiner Ansatz:

- Bestimmung eines Kernels  $\mathbf{K}$  für Nutzer-Nutzer- und/oder Instanz-Instanz-Ähnlichkeit.
- Bestimmung von Gewichten  $\mathbf{W}$ , so dass

$$R_{ij} = \sum_{k=1}^n K_{ik} W_{kj} \Rightarrow \mathbf{R} = \mathbf{KW}$$

- Beispiel Nächste-Nachbarn-Modell (bspw. Instanz-Instanz):

$$R_{ij} = \sum_{k \in B_i} \left( \frac{V_{ik}}{\sum_{p \in B_i} V_{ip}} \right) Y_{kj}$$

Ähnlichkeit  $K_{ik}$  zwischen  
Instanz  $i$  und Instanz  $k$

Gewichtungsfaktor  $W_{kj}$  für  
Instanz  $k$  und Nutzer  $j$

# Ähnlichkeitsbasiertes Filtern

## Bestimmung des Ähnlichkeitskernel

- 1. Möglichkeit: Empirische Korrelation (beispielhaft bzgl. Nutzern).

$$K_{ij} = \frac{1}{|B_{ij}| - 1} \sum_{k \in B_{ij}} \frac{Y_{ik} - \mu_i}{\sigma_i} \frac{Y_{jk} - \mu_j}{\sigma_j}$$

$B_{ij}$  = Indexmenge  $\{k\}$  für welche  $Y_{ik}$  und  $Y_{jk}$  bekannt

mit mittlerem Nutzer-Rating (empirischer Mittelwert)

$$\mu_i = \frac{1}{|B_i|} \sum_{k \in B_i} Y_{ik}$$

$B_i$  = Indexmenge  $\{k\}$  für welche  $Y_{ik}$  bekannt


und mittlerer Abweichung (empirische Varianz).

$$\sigma_i^2 = \frac{1}{|B_i| - 1} \sum_{k \in B_i} (Y_{ik} - \mu_i)^2$$

# Ähnlichkeitsbasiertes Filtern

## Bestimmung des Ähnlichkeitskernel

- 2. Möglichkeit: Für gegebene Gewichtematrix  $\mathbf{W}$ , Ähnlichkeitsfaktoren aus Daten lernen.
- Minimierung einer (regularisierten) Verlustfunktion wie z.B. die mittlere quadratische Abweichung zwischen gegebenen und vorhergesagtem Rating:



# Ähnlichkeitsbasiertes Filtern

## Bestimmung der Gewichtematrix

- 1. Möglichkeit: Nächste-Nachbarn-Ansatz bspw. mit Mittelwert-Korrektur (beispielhaft bzgl. Instanzen).

$$W_{ij} = \mu_j + \sum_{k \in B_i} \left( \frac{V_{ik}}{\sum_{p \in B_i} V_{ip}} \right) (Y_{kj} - \mu_k)$$

- 2. Möglichkeit: Für gegebenen Ähnlichkeitskernel  $\mathbf{K}$ , Gewichtematrix aus Daten lernen:

$$\arg \min_{\mathbf{W}} \sum_{i=1}^n \sum_{j \in B_i} l \left( \sum_{k=1}^n K_{ik} W_{kj}, Y_{ij} \right) + \Omega(\mathbf{W})$$

Feste Ähnlichkeiten  $K_{ik}$

Gesuchte Gewichte  $W_{kj}$

# Ähnlichkeitsbasiertes Filtern

## Bestimmung der Gewichtematrix

### □ Verlustfunktion:

- Squared Loss (Regressions-Problem).
- Relaxiertes NDCG Loss (Ranking-Problem).

### □ Regularisierer:

- Sparse Lösung bevorzugt, z.B.  $\Omega \mathbf{W} = \sum_{i,j} |W_{ij}|$  bzw.  $\Omega \mathbf{K} = \sum_{i,j} |K_{ij}|$ .

### □ Kombination aus Instanz-Instanz- und Nutzer-Nutzer-Ähnlichkeit:

- Annahme: Ähnliche Instanzen werden von ähnlichen Nutzern nahezu gleich bewertet.



# Modellbasiertes Filtern

## Annahmen

### □ Annahmen:

- Jede Instanz (z.B. Film, Produkt) hat versteckte Eigenschaften, d.h. Vektor  $\mathbf{x}_i$  ( $i = 1 \dots m$ ) mit  $k$  unbekanntem Attribut-Belegungen.
- Jeder Nutzer hat versteckte Interessen, d.h. Vektor  $\mathbf{w}_j$  ( $j = 1 \dots n$ ) mit  $k$  unbekanntem Attribut-Bewertungen (Nutzer-Profil).
- Rating  $R_{ij}$  eines Nutzers  $j$  für Instanz  $i$  ist Skalarprodukt aus Attribut-Belegung  $\mathbf{x}_i$  und Attribut-Bewertung  $\mathbf{w}_j$ :  $R_{ij} = \mathbf{x}_i^T \mathbf{w}_j$ .

### □ Ziel:

- Vektoren  $\mathbf{x}_i$  und  $\mathbf{w}_j$  für alle Instanzen und Nutzer aus Daten Schätzen sodass  $R_{ij}$  möglichst gleich den bekannten  $Y_{ij}$ .
- Hohe Generalisierungsfähigkeit, d.h. Vorhersage basierend auf möglichst wenig Attributen (kleines  $k$ ).

# Modellbasiertes Filtern

## Beispiel

- Beispiel für (versteckte) Attribut-Belegungen:

Film	Drama	Action	Dialoge
About a Boy	0,6	0,1	1,0
Chicago	0,7	0,2	0,7
Terminator	0,1	0,9	0,1
Matrix	0,2	1,0	0,3

- Beispiel für (versteckte) Attribut-Bewertungen:

Nutzer	Mag Drama	Mag Action	Mag Dialoge
Nutzer 1	0,5	4,5	1,0
Nutzer 2	3,5	0,0	2,5
Nutzer 3	1,5	2,0	1,0

- Beispiel-Ratings:

Film	Nutzer 1	Nutzer 2	Nutzer 3
About a Boy	1,75	4,60	2,10
Chicago	1,95	4,20	2,15
Terminator	4,20	0,60	2,05
Matrix	4,90	1,45	2,60

$$= 0.6 \cdot 1.5 + 0.1 \cdot 2.0 + 1.0 \cdot 1.0$$

# Modellbasiertes Filtern

## Lösungsidee

- Gleichzeitiges Schätzen von allen Vektoren  $\mathbf{x}_i$  und  $\mathbf{w}_j$

$$\begin{bmatrix} - & \mathbf{x}_1 & - \\ & \vdots & \\ - & \mathbf{x}_m & - \end{bmatrix} \begin{bmatrix} | & & | \\ \mathbf{w}_1 & \cdots & \mathbf{w}_n \\ | & & | \end{bmatrix} \Rightarrow \mathbf{X}^T \mathbf{W} = \mathbf{R} \begin{bmatrix} R_{11} & \cdots & R_{1n} \\ \vdots & \ddots & \vdots \\ R_{m1} & \cdots & R_{mn} \end{bmatrix}$$

Gesuchte Instanz-Attribute

Gesuchte Attribut-Bewertungen

mit dem Ziel den Abstand (Verlust) zwischen vorhergesagtem Rating  $\mathbf{R}$  und echtem Rating  $\mathbf{Y}$  zu minimieren:

$$\arg \min_{\mathbf{X}, \mathbf{W}} \sum_{i=1}^m \sum_{j \in B_i} l \left( \sum_{l=1}^k x_{il} w_{lj}, Y_{ij} \right) + \Omega(\mathbf{X}, \mathbf{W})$$

# Modellbasiertes Filtern

Annahme: Alle Ratings bekannt

- Betrachten zunächst vereinfachende Annahmen:
  - ▣ Alle Ratings  $Y$  bekannt.
  - ▣ Squared Loss.
  - ▣ Keine Regularisierung.
- Optimale Lösung:

Matrix-Faktorisierung

$$\arg \min_{\mathbf{X}, \mathbf{W}} \sum_{i=1}^m \sum_{j=1}^n (\mathbf{x}_i^T \mathbf{w}_j - Y_{ij})^2 \Rightarrow \mathbf{X}^T \mathbf{W} = \mathbf{Y}$$

- Optimierungsproblem besitzt unendlich viele Lösungen!
- Eindeutige Lösung durch Regularisierung.

# Modellbasiertes Filtern

Annahme: Alle Ratings bekannt

- Welchen Regularisierer verwenden?
  - ▣ Anzahl versteckte Attribute soll  $k$  sein (= Rang von  $\mathbf{R}$ ).
- Optimale Lösung:

$$\mathbf{U} \underset{i=1 \dots \min m, n}{\text{diag}} (\sigma_i) \mathbf{V}^T = \mathbf{Y} \Rightarrow \mathbf{X} = \mathbf{U}^T, \mathbf{W} = \underset{i=1 \dots k}{\text{diag}} (\sigma_i) \mathbf{V}^T \Rightarrow \mathbf{R} = \mathbf{U} \underset{i=1 \dots k}{\text{diag}} (\sigma_i) \mathbf{V}^T$$

Singulärwertzerlegung mit Singulärwerten  $\sigma_i$

Rang von  $\mathbf{R}$  ist  $k$

- Spalte von  $\mathbf{U}$  ist Koordinatenachse des Attribute-Raums.
- Zeile von  $\mathbf{U}$  ist eine Instanz (z.B. Film) in diesem Raum.

# Modellbasiertes Filtern

Annahme: Nicht alle Ratings bekannt

- Problem: Nicht alle Ratings bekannt.
- Idee: Minimiere Rang von  $\mathbf{X}$  und  $\mathbf{W}$  direkt.

$$\arg \min_{\mathbf{X}, \mathbf{W}} \sum_{i=1}^m \sum_{j \in B_i} l \left( \sum_{l=1}^k x_{il} w_{lj}, Y_{ij} \right) + \frac{\lambda}{2} (rk(\mathbf{X}) + rk(\mathbf{W}))$$

- Rang-Funktion ist nicht konvex!
- Statt Minimierung des Rangs (Anzahl Singulärwerte  $\neq 0$ ), Minimierung der Summe der quadrierten Singulärwerte = (quadrierte) Frobenius-Norm.

$$\arg \min_{\mathbf{X}, \mathbf{W}} \sum_{i=1}^m \sum_{j \in B_i} l \left( \sum_{l=1}^k x_{il} w_{lj}, Y_{ij} \right) + \frac{\lambda}{2} \|\mathbf{X}\|_F^2 + \frac{\lambda}{2} \|\mathbf{W}\|_F^2$$

# Modellbasiertes Filtern

Annahme: Nicht alle Ratings bekannt

- Für Frobenius-Norm einer Matrix gilt:

$$\|\mathbf{X}\|_F^2 = \sum_{i=1}^{\min(m,n)} \sigma_i^2 = \text{tr}(\mathbf{X}\mathbf{X}^T) = \sum_{i=1}^m \|\mathbf{x}_i\|^2$$

- (Ein mögliches) konvexes Optimierungsproblem für modellbasiertes Collaborative Filtering:

$$\arg \min_{\mathbf{X}, \mathbf{W}} \sum_{i=1}^m \sum_{j \in B_i} l(\mathbf{x}_i^T \mathbf{w}_j, Y_{ij}) + \frac{\lambda_x}{2} \sum_{i=1}^m \|\mathbf{x}_i\|^2 + \frac{\lambda_w}{2} \sum_{j=1}^n \|\mathbf{w}_j\|^2$$

- Lösen beispielsweise durch abwechselnde Optimierung bzgl.  $\mathbf{X}$  und  $\mathbf{W}$ .

# Modellbasiertes Filtern

## $l_2$ -Regularized Collaborative Filtering

### □ Algorithmus:

RegCoFilter(*Ratings*  $\mathbf{Y}$ , *Anzahl versteckter Attribute*  $k$ )

Setze  $l=0, \forall j \mathbf{w}_j^0 = \mathbf{0}$  und wähle zufällig  $\forall i \mathbf{x}_i^0 \in \mathbb{R}^k$

DO

FOR  $j = 1 \dots n$

$$\mathbf{w}_j^{l+1} = \arg \min_{\mathbf{w}_j} \sum_{i \in B_j} l(\mathbf{w}_j^T \mathbf{x}_i^l, Y_{ij}) + \frac{\lambda_w}{2} \|\mathbf{w}_j\|^2$$

Lösen bspw. mit RegERM und Trainingsbeispielen  $\mathbf{x}_i^l, Y_{ij} \mid i \in B_j$  .

FOR  $i = 1 \dots m$

$$\mathbf{x}_i^{l+1} = \arg \min_{\mathbf{x}_i} \sum_{j \in B_i} l(\mathbf{x}_i^T \mathbf{w}_j^{l+1}, Y_{ij}) + \frac{\lambda_x}{2} \|\mathbf{x}_i\|^2$$

Lösen bspw. mit RegERM und Trainingsbeispielen  $\mathbf{w}_j^{l+1}, Y_{ij} \mid j \in B_i$  .

$l = l + 1$

$$\text{WHILE } \frac{1}{m} \sum_{i=1}^m \|\mathbf{x}_i^l - \mathbf{x}_i^{l-1}\| + \frac{1}{n} \sum_{j=1}^n \|\mathbf{w}_j^l - \mathbf{w}_j^{l-1}\| > \varepsilon$$

$$\mathbf{R} = \begin{bmatrix} \mathbf{x}_1^l & \dots & \mathbf{x}_m^l \end{bmatrix}^T \begin{bmatrix} \mathbf{w}_1^l & \dots & \mathbf{w}_n^l \end{bmatrix}$$

RETURN  $\mathbf{R}$



# Modellbasiertes Filtern

## Erweiterungen

- Ranking-Loss verwenden (z.B. CoFiRank).
- Kombination mit Ähnlichkeitsbasierten Verfahren (z.B. Jointly Derived Neighborhood).
- Spezielle Regularisierer welche bspw. Ähnlichkeitskernel berücksichtigen.
- Approximationen für hohe Skalierbarkeit.
- Normierung der gegebenen Daten (z.B. mittlere Bewertung jedes Nutzers auf 0 skalieren).

# Zusammenfassung

- Ziel: Vorhersage von Nutzerbewertungen bzw. nutzerspezifischen Rankings.
  - Vorhersage basierend ausschließlich auf bekannten Bewertungen/Rankings anderer Nutzer.
- Ähnlichkeitsbasierter Ansatz:
  - Nächste-Nachbarn-Modell mit Ähnlichkeiten zweier Nutzer und/oder Instanzen.
- Modellbasierter Ansatz:
  - Versteckte Instanz-Attribute und nutzerspezifischen Attribut-Bewertungen gleichzeitig aus Daten schätzen.