

# Non-negative Matrix Factorization (*'Learning from Incomplete Ratings Using Non-negative Matrix Factorization'*. Abril, 2006)

---

Jorge Schellman

Autores:  
S. Zhang  
W. Wang  
J. Ford  
F. Makedon

# Introducción: NMF

En descomposición SVD admitimos que  $R = U \tilde{S} V^T$  (sin restricción).

En NMF hacemos  $R = P Q^T$ , con todas las entradas positivas.

Al restringir la descomposición a valores no-negativos podemos reconstruir  $R$  como combinación lineal con coeficientes positivos de los vectores de la base:

$$R^{(j)} = P Q^{T(j)} = \sum_{i=1}^k P^{(i)} Q_i^{T(j)}$$

# Introducción: NMF

$$R_{n \times m} \approx \tilde{R}_{n \times m} = P_{n \times k} \times Q_{k \times m}^T$$

$$\begin{array}{c}
 \begin{array}{cc}
 & \begin{array}{c} i1 \\ \downarrow \\ 4 \\ \downarrow \\ 3 \end{array} & \begin{array}{c} i2 \\ \downarrow \\ 1 \\ \downarrow \\ 2 \end{array} \\
 \begin{array}{c} u1 \rightarrow \\ u2 \rightarrow \end{array} & \mathbf{R} = & \begin{array}{cc} 4 & 1 \\ 3 & 2 \end{array}
 \end{array}
 &
 \begin{array}{c}
 \begin{array}{cc}
 & \begin{array}{c} f1 \\ \downarrow \\ 1 \\ \downarrow \\ 3 \end{array} & \begin{array}{c} f2 \\ \downarrow \\ 2 \\ \downarrow \\ 4 \end{array} \\
 \begin{array}{c} u1 \rightarrow \\ u2 \rightarrow \end{array} & \mathbf{P} = & \begin{array}{cc} 1 & 2 \\ 3 & 4 \end{array}
 \end{array}
 &
 \begin{array}{c}
 \begin{array}{cc}
 & \begin{array}{c} f1 \\ \downarrow \\ 3 \\ \downarrow \\ 2 \end{array} & \begin{array}{c} f2 \\ \downarrow \\ 5 \\ \downarrow \\ 1 \end{array} \\
 \begin{array}{c} i1 \rightarrow \\ i2 \rightarrow \end{array} & \mathbf{Q} = & \begin{array}{cc} 3 & 5 \\ 2 & 1 \end{array}
 \end{array}
 \end{array}$$

En paper:  $A \approx X = UV$

$$\begin{array}{c}
 \downarrow \quad \downarrow \quad \downarrow \\
 (\tilde{R}^T = QP^T)
 \end{array}$$

$$\begin{array}{c}
 \begin{array}{cc}
 & \begin{array}{c} f1 \\ \downarrow \\ 3 \\ \downarrow \\ 2 \end{array} & \begin{array}{c} f2 \\ \downarrow \\ 5 \\ \downarrow \\ 1 \end{array} \\
 \begin{array}{c} i1 \rightarrow \\ i2 \rightarrow \end{array} & \mathbf{U} = & \begin{array}{cc} 3 & 5 \\ 2 & 1 \end{array}
 \end{array}
 \\
 \\
 \begin{array}{c}
 \begin{array}{cc}
 & \begin{array}{c} u1 \\ \downarrow \\ 1 \\ \downarrow \\ 2 \end{array} & \begin{array}{c} u2 \\ \downarrow \\ 3 \\ \downarrow \\ 4 \end{array} \\
 \begin{array}{c} f1 \rightarrow \\ f2 \rightarrow \end{array} & \mathbf{V} = & \begin{array}{cc} 1 & 3 \\ 2 & 4 \end{array}
 \end{array}
 \end{array}$$

# Interpretación de Matrices

$X_{n \times m}$ : matriz que se aproxima a A con rango a lo más k.

$U_{n \times k}$ : matriz cuyas columnas son 'perfiles de rating representativos de cada comunidad de usuarios'.

$$U = \begin{array}{cc} & \begin{array}{c} f1 \\ \blacktriangledown \\ 3 \end{array} & \begin{array}{c} f2 \\ \blacktriangledown \\ 5 \end{array} \\ \begin{array}{c} i1 \rightarrow \\ i2 \rightarrow \end{array} & \begin{array}{cc} 3 & 5 \\ 2 & 1 \end{array} \end{array}$$

$V_{k \times m}$ : matriz cuyas columnas son 'afinidades de cada usuario con todas las comunidades de usuarios'.

$$V = \begin{array}{cc} & \begin{array}{c} u1 \\ \blacktriangledown \\ 1 \end{array} & \begin{array}{c} u2 \\ \blacktriangledown \\ 3 \end{array} \\ \begin{array}{c} f1 \rightarrow \\ f2 \rightarrow \end{array} & \begin{array}{cc} 1 & 3 \\ 2 & 4 \end{array} \end{array}$$

# Obtención de $X$ :

## Caso matriz $A$ *fully observable*

Maximizamos el log-likelihood de la distribución de  $A$  dado  $X$ , lo que es equivalente a encontrar matrices no-negativas  $U$  y  $V$  que minimicen la norma cuadrada de Frobenius:

$$\max \log \Pr ( A | X ) \Leftrightarrow \min \| A - UV \|_F^2$$

Luego se puede usar la técnica de multiplicadores de Lagrange para encontrar fórmulas de actualización para  $U_{ij}$  y  $V_{ij}$ .

# Obtención de $X$ : Caso matriz $A$ *sparse*

Queremos maximizar  $\log \Pr(A^\circ | X)$ .

Para esto 2 vías: **procedimiento EM** y **NMF ponderada**.

Una vez encontrado  $X$ , tomamos la predicción como  $X_{ij}$  dado que asumimos que  $E(A_{ij}) = X_{ij}$  (cuando no se conoce  $A_{ij}$ ) y que  $\Pr(A_{ij} | X_{ij})$  obtiene su máximo cuando  $A_{ij} = X_{ij}$

# Procedimiento EM

- Expectación-Maximización:

1. Expectación: en la iteración  $t$  calcular el valor de expectación del log-likelihood de toda la data con respecto a los datos desconocidos ( $A^u$ ) dado los observados ( $A^o$ ) y la actual estimación  $X^{(t-1)}$ .

$$Q(X, X^{(t-1)}) = E[\log \Pr(A^o, A^u | X) | A^o, X^{(t-1)}]$$

2. Maximización:

$$X^{(t)} = \underset{X}{\operatorname{argmax}} Q(X, X^{(t-1)})$$

Si  $A'$  matriz con datos observados más datos no observados reemplazados por la actual iteración, se puede demostrar que:

$$X^{(t)} = \underset{X}{\operatorname{argmin}} \sum_{ij} (A'_{ij} - (UV)_{ij})^2$$

# WNMF

- Weighted Non-negative Matrix Factorization:

El log-likelihood de los datos observados podemos expresarlos como:

$$\log Pr(A^o|X) = \frac{-1}{2\sigma^2} \sum_{A_{ij} \in A^o} (A_{ij} - X_{ij})^2 + C$$

Maximizar lo anterior es igual a minimizar  $\sum_{ij} W_{ij} (A_{ij} - (UV)_{ij})^2$

donde  $W_{ij} = 1$  si  $A_{ij}$  es la entrada observada y 0 si no.

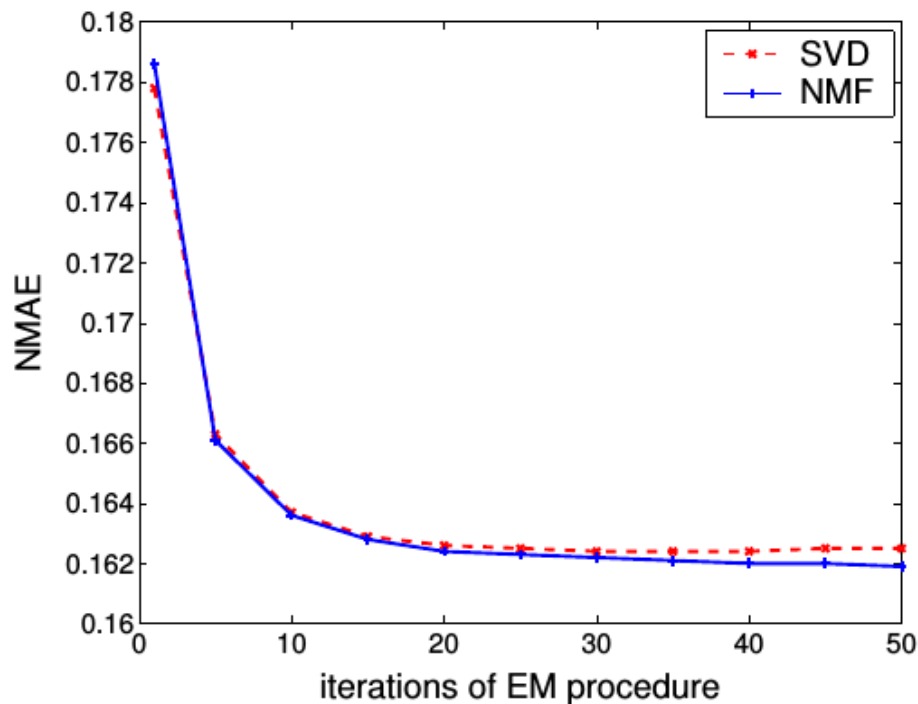


# Experimentos


- 2 datasets:
  - (1) 1426x2945 (items x users) rating matrix de MovieLens.
  - (2) 100 x 3000 de Jester
- 5-fold cross-validation
- Métricas: NMAE + área ROC-4

# Resultados: EM proc. vs WNMF

- SVD-based vs NMF-based EM approach:
  - En SVD, matriz de ratings normalizada por z-scores.
  - $k = 10$  en SVD y  $20$  en NMF.



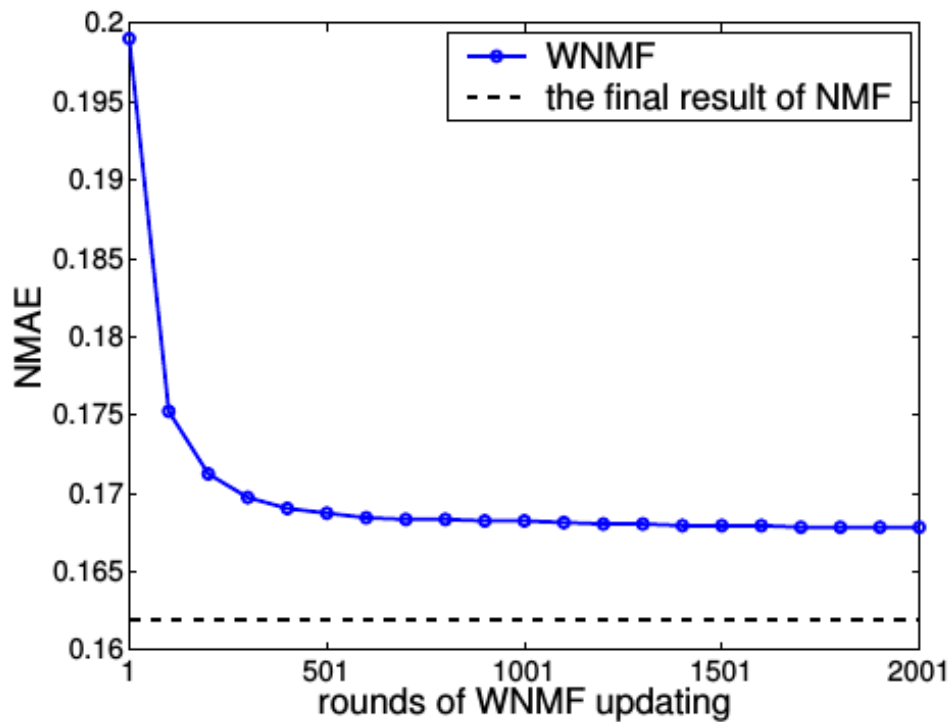
(a) NMAE




(b) ROC-4 area

# Resultados: EM proc. vs WNMF

- WNMF (en NFM) en donde valores iniciales de  $U$  y  $V$  son aleatorios.



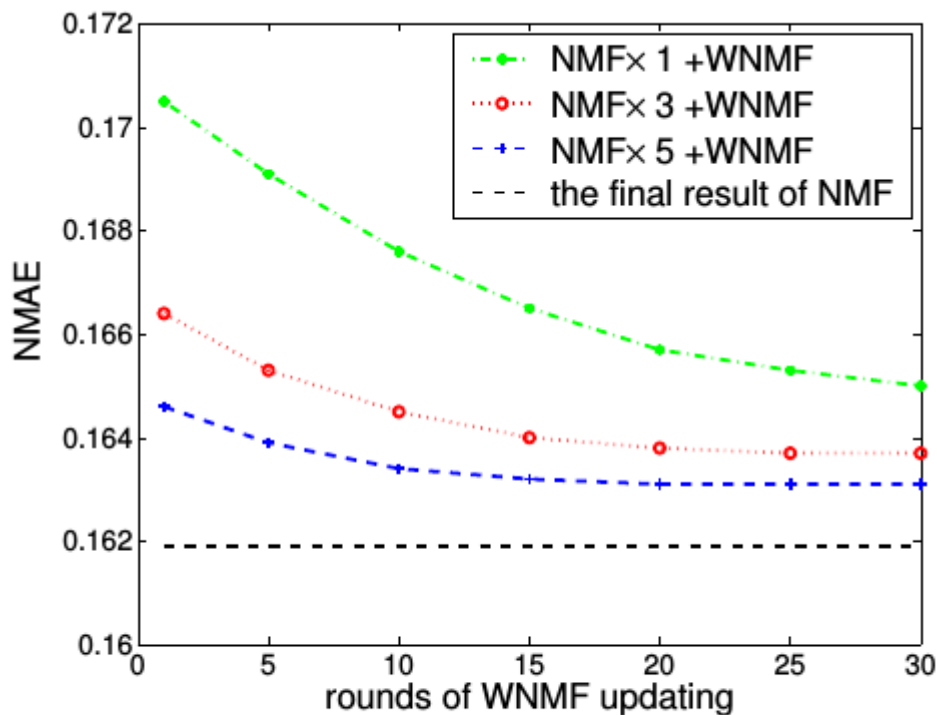
(a) NMAE




(b) ROC-4 area

# Resultados: EM proc. vs WNMF

- Cada iteración del EM proc.: 303.3s. Cada ronda de actualización en WNMF: 1.27s
- Hibridación EM/WNMF: aplicación procedimiento EM por varias iteraciones  $\rightarrow$  obtención de un buen par  $U, V \rightarrow$  aplicación WNMF.



(a) NMAE



(b) ROC-4 area

# Resultados:

## Algoritmos basados en NMF

- En NMAE, NMF+EM y SVD+EM obtienen mejores resultados.
- En área ROC-4, NMF+EM.

Table 1: Performance of CF algorithms on MovieLens.

	Pearson	SVD EM	NMF EM	Hybrid NMF
NMAE	0.1707	0.1629	0.1623	0.1634
ROC-4	0.7471	0.7682	0.7723	0.7691

Table 2: Performance of CF algorithms on Jester.

	Pearson	SVD EM	NMF EM	Hybrid NMF
NMAE	0.1634	0.1605	0.1599	0.1599
ROC-4	0.7539	0.7588	0.7612	0.7608

# Discusión

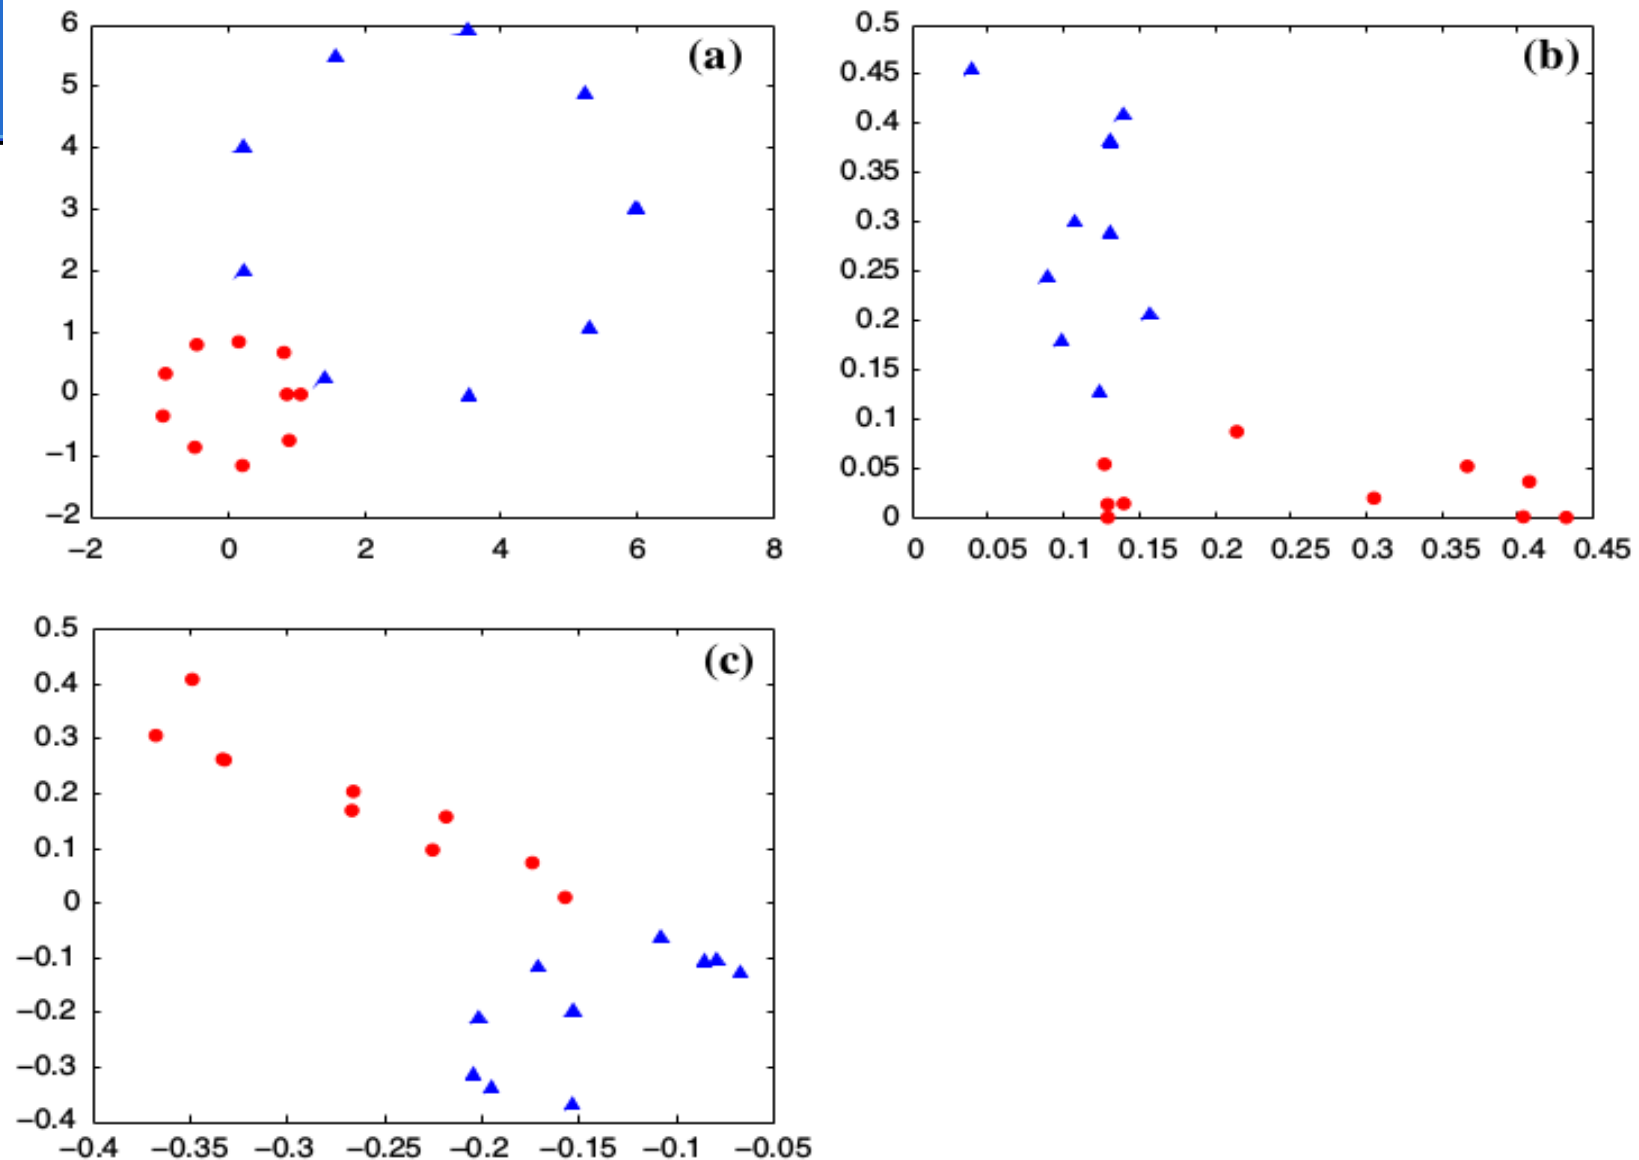
Ventaja de NMF: coordenadas obtenidas reflejan directamente las características de las *comunidades de usuarios*.

Al ver las columnas de  $U$  podemos obtener una lista rankeada de las preferencias que tiene cada *grupo* sobre todos los ítems.

<b>Interest Group 5</b>	<b>Interest Group 8</b>	<b>Interest Group 9</b>
<u>Austin Powers: International Man of Mystery</u> (Comedy)	<u>Terminator 2: Judgment Day</u> (Action   Sci-Fi   Thriller)	<u>Dumb &amp; Dumber</u> (Comedy)
<u>Austin Powers: The Spy Who Shagged Me</u> (Comedy)	<u>Die Hard</u> (Action   Thriller)	<u>Ace Ventura: When Nature Calls</u> (Comedy)
<u>Clerks</u> (Comedy)	<u>Independence Day (ID4)</u> (Action   Sci-Fi   War)	<u>Ace Ventura: Pet Detective</u> (Comedy)
<u>Big Lebowski</u> (Comedy   Crime   Mystery   Thriller)	<u>Matrix</u> (Action   Sci-Fi   Thriller)	<u>Home Alone 2: Lost in New York</u> (children's   Comedy)
<u>Happy Gilmore</u> (Comedy)	<u>Speed</u> (Action   Romance   Thriller)	<u>Nutty Professor</u> (Comedy   Fantasy   Romance   Sci-Fi)

<b>Interest Group 17</b>	<b>Interest Group 19</b>
<u>Pretty Woman</u> (Comedy   Romance)	<u>Sound of Music</u> (Musical)
<u>Notting Hill</u> (Comedy   Romance)	<u>Grease</u> (Comedy   Musical   Romance)
<u>Steel Magnolias</u> (Drama)	<u>Little Mermaid</u> (Animation   Children's   Comedy)
<u>Erin Brockovich</u> (Drama)	<u>Wizard of Oz</u> (Adventure   Children's   Drama   Musical)
<u>Sleepless in Seattle</u> (Comedy   Romance)	<u>Cinderella</u> (Animation   Children's   Musical)

# Clustering con NMF



**Fig. 1** **a** An artificial toy dataset consisting of two natural clusters. **b** Data distribution in the SS-NMF subspace of the two column vectors of  $\mathbf{G}$ . The data points from the two clusters get distributed along the two axes. **c** Data distribution in the SS-SNC subspace of the first two singular vectors. There is no relationship between the axes and the clusters



# Referencias

- S. Zhang, W. Wang, J. Ford, and F. Makedon, “Learning from Incomplete Ratings Using Non-Negative Matrix Factorization,” Proc. Sixth SIAM Int’l Conf. Data Mining (SDM), pp. 549-553, 2006.
- Y. Chen, M. Rege, M. Dong, and J. Hua, “Non-negative matrix factorization for semi-supervised data clustering,” Knowl. Inf. Syst., 17, pp. 355–379, 2008.
- W. Xu, X. Liu, and Y. Gong, “Document clustering based on non-negative matrix factorization,” Proc. of the 26th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, ACM, New York, pp. 267–273, 2003.
- D. Lee and H.S. Seung, “Learning parts of objects by non-negative matrix factorization,” Nature 401, pp. 788-791, 1999.