

Factorización no negativa de matrices

Una aplicación a los motores de recomendación

Carlos J. Gil Bellosta
cgb@datanalytics.com

Febrero de 2015

Factorización
no negativa de
matrices

Carlos J. Gil
Bellosta –
datanalytics

Motivación

¿SVD?

¡NMF!

Una
interpretación
probabilística

NMF y LDA

¿Son así nuestros súper súper clientes?



Fuente: Rich and Famous <http://rf.ro>

Datos “diádicos” (¿matrices?)

| | T_1 | T_2 | ... | T_m |
|-------|-------|-------|-----|-------|
| C_1 | 0 | 3 | ... | 1 |
| C_2 | 2 | 1 | ... | 0 |
| ... | ... | ... | ... | 0 |
| C_n | 1 | 0 | ... | 1 |

Tenemos n clientes (filas) y m (tipos de) productos (columnas).

Objetivo

Entender (¿microsegmentar?) los gustos y preferencias de los clientes.

Lo primero que se te ocurre: SVD

La descomposición en valores singulares (SVD) de X :

$$X = UDV$$

donde:

- D es una matriz diagonal con entradas $d_1 \geq d_2 \geq \dots \geq 0$.
- Las columnas (filas) de U (V) son ortogonales.

Recomposición del comportamiento de un cliente

El comportamiento de un cliente es su fila de X . El comportamiento del cliente i sería

$$X_i = \sum_j u_{ij} d_j v_j.$$

Interpretación:

- Las filas de V , v_j son *preferencias* comunes a todos los clientes.
- Cada cliente asigna un valor a dichas preferencias en función de su fila (la i) en U .
- Los valores d_j son pesos globales de cada *preferencia*.

Reducción de la dimensionalidad

¿Qué si ignoramos aquellas preferencias de menor peso?

Interpretación de las preferencias

¡Buena suerte con los signos negativos!

Pros, cons y un canje razonable

- Nos gusta la descomposición $X = UDV$.
- Nos gusta la posibilidad de reducir la dimensionalidad de la matriz original (aun perdiendo algo de precisión).
- Nos gustaría poder canjear la ortogonalidad por otra propiedad que facilitase la interpretación.

Un canje razonable

Perder la ortogonalidad a cambio de que $u_{ij}, v_{ij} \geq 0$.

Factorización no negativa de matrices

Es posible encontrar matrices U y V donde

- Como antes (casi) $X \sim UV$ donde U y V son matrices positivas.
- Como antes (casi) es posible reducir la dimensionalidad descartando columnas (filas) de U (V).
- Se pierde la ortogonalidad (¡necesariamente!).

Interpretación:

- Las filas de V siguen siendo preferencias.
- Las filas de U son los pesos que un cliente asigna a las distintas preferencias.
- ¡Qué bien si hubiese muchos ceros!

Algoritmos y herramientas

Algoritmos:

- NMF es un problema NP-completo (me dicen).
- Existen algoritmos heurísticos, aproximados, etc.

Herramientas:

- Paquete NMF de R (para matrices pequeñas y medianas).
- GraphLab para matrices grandes en clústers (¡buena suerte compilando!)
- GraphChi para matrices algo menos grandes (en una única máquina).

De números positivos a probabilidades

Si U y V son positivas, pueden encontrarse matrices D , \tilde{U} y \tilde{V} tales que

$$UV = D\tilde{U}\tilde{V}$$

donde

- D es una matriz diagonal y $d_i \geq 0$.
- \tilde{U} y \tilde{V} son matrices positivas.
- Cada fila de \tilde{U} suma 1.
- Cada fila de \tilde{V} suma 1.

Y valores positivos que suman 1 son... ¡probabilidades!
(Nota: en lo sucesivo ignoraremos las tildes de U y V .)


Una mezcla (mixture) de multinomiales

- La estructura probabilística revelada es la de una mezcla (*mixtura*) de multinomiales.
- Las filas de V son un menú de preferencias.
- Estas preferencias son distribuciones multinomiales con probabilidades dadas por los valores de esas filas.
- Las filas de U son los pesos de la mezcla.
- Los valores de la diagonal de D son el número (¿entero?) de muestras extraídas de cada cliente.

Mezclas de variables aleatorias

Dadas variables aleatorias X_1, \dots, X_n , una mezcla de ellas con pesos p_1, \dots, p_n donde $p_i > 0$ y $\sum p_i = 1$ es otra variable aleatoria que se muestra así:

- 1 Se elige una v.a. de entre las X_1, \dots, X_n con probabilidad dada por los p_1, \dots, p_n .
- 2 Se obtiene un valor de ella.



Interpretabilidad y más

- 1 Tenemos una lista de preferencias comunes a los clientes
- 2 Son tanto o más interpretables cuantos más ceros tengan, cuanto más *puras* sean
- 3 Los clientes se clasifican de acuerdo con su (desigual) apego a ellas

Otras cuestiones:

- 1 Cuando aparece un cliente nuevo, es posible asignarle unas preferencias (i.e., sus pesos)
- 2 ¿Qué pasaría con clientes de los que no tienes información en absoluto? ¿Te treverías con un enfoque bayesiano?

NMF... ¿LDA para pobres?

¿Latent Dirichlet Allocation?

- 1 Un documento contiene palabras y trata uno o más temas.
- 2 Las palabras aportan información sobre el tema al que se refiere el documento.
- 3 Es posible construir algoritmos que detectan temas o que permiten identificar los temas a los que se refiere un documento.
- 4 Es una técnica bayesiana donde las distribuciones *a priori* siguen una Dirichlet.
- 5 ¡Es terriblemente exigente computacionalmente!

El modelo *generativo* que hemos planteado...

- 1 ... es conceptualmente similar al que subyace a LDA.
- 2 ¡Es mucho más liviano!

Factorización
no negativa de
matrices

Carlos J. Gil
Bellosta –
datanalytics

Motivación

¿SVD?

¿NMF!

Una
interpretación
probabilística

NMF y LDA

¡Y eso fue todo!

¿Preguntas?