

Matrix Factorization

Dr. rer. nat. Hendri Murfi

Intelligent Data Analysis (IDA) Group

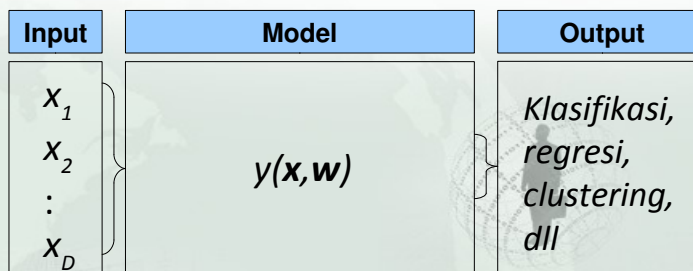
Departemen Matematika, Universitas Indonesia – Depok 16424

05.11.13

1

Telp. +62-21-7862719/7863439, Fax. +62-21-7863439, Email. hendri@ui.ac.id

Machine Learning



- *Preprocessing*: ekstraksi fitur dan representasi data, misal dalam bentuk vektor $\mathbf{x}_i = (x_1, x_2, \dots, x_D)^T$
- *Learning*: pemilihan model dan penentuan parameter model, misal \mathbf{w} , berdasarkan data pelatihan (*training data*)
- *Evaluation*: pengujian metode dengan data pengujian (*testing data*) yang tidak sama dengan data pelatihan, sehingga didapat nilai estimasi untuk kapabilitas generalisasi dari model.

2

Learning

Diberikan data pelatihan $\mathbf{x}_i, i = 1 \text{ sd } N$, dan/atau $\mathbf{t}_i, i = 1 \text{ as } N$


- **Supervised Learning**. Data pelatihan disertai target, yaitu $\{\mathbf{x}_i, \mathbf{t}_i\}, i = 1 \text{ sd } N$. Tujuan pembelajaran adalah membangun model yang dapat menghasilkan output yang benar untuk suatu data input, misal untuk pengklasifikasian (*classification*) dan regresi (*regression*)
- **Unsupervised Learning**. Data pelatihan tidak disertai target, yaitu $\mathbf{x}_i, i = 1 \text{ sd } N$. Tujuan pembelajaran adalah membangun model yang dapat menemukan variabel tersembunyi pada data pelatihan. Selanjutnya, variabel tersembunyi tersebut dapat digunakan untuk kebutuhan pemodelan (*latent variable models*)

3

Unsupervised Learning

Bertujuan untuk mengekstraksi variabel tersembunyi pada data pembelajaran. Selanjutnya, variabel tersembunyi tersebut dapat digunakan, misal, untuk:

- *Clustering*
- *Features Extraction*
- *Dimensional Reduction*
- *Recommendation*
- *Topic Modeling*



4



Unsupervised Learning

- Ada beberapa metode yang sering digunakan untuk mengekstrak variabel tersembunyi dari suatu koleksi data, antara lain:
 - *K-Means*
 - *Principal Component Analysis (PCA)*
 - *Independent Component Analysis (ICA)*
 - *Matrix Factorization*

5



Matrix Factorization

- *Matrix Factorization* adalah penguraian suatu matriks menjadi beberapa buah matriks.
- Ada beberapa metode yang sering digunakan untuk memfaktorkan suatu matriks, antara lain:
 - *Singular Value Decomposition (SVD)*
 - *Nonnegative Matrix Factorization (NMF)*

6

Matrix Factorization

Singular Value Decomposition

- Diberikan suatu matriks $A_{m \times n}$, SVD akan menguraikan matriks A menjadi:

$$A_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}$$

dimana U dan V adalah matriks orthogonal, Σ adalah matriks diagonal dengan nilai-nilai pada diagonal lebih besar atau sama dengan nol

- Bentuk faktorisasi diatas dapat juga dimodifikasi menjadi:

$$\begin{aligned} A_{m \times n} &\approx U_{m \times k} \Sigma_{k \times k} V_{k \times n} \\ &= (U_{m \times k} \Sigma_{k \times k}^{1/2}) (\Sigma_{k \times k}^{1/2} V_{k \times n}) \\ &= W_{m \times k} H_{k \times n} \end{aligned}$$

dimana $k < \text{rank}(A)$

7

Matrix Factorization

Nonnegative Matrix Factorization

- Diberikan suatu matriks $A_{m \times n}$, NMF akan menguraikan matriks A menjadi:

$$A_{m \times n} \approx W_{m \times k} H_{k \times n}$$

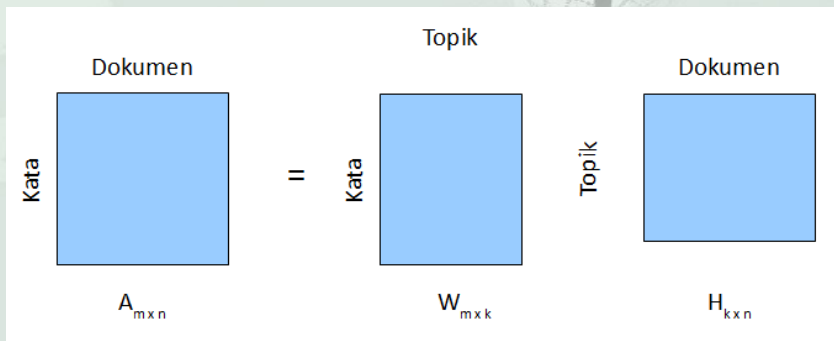
dimana W dan H adalah matriks dengan entri-entri bernilai non negatif

8

Matrix Factorization

Latent Variable Models

- Misal matriks $A_{m \times n}$ adalah matriks kata-dokumen, maka variabel tersembunyi pada data tersebut dapat berupa topik-topik:

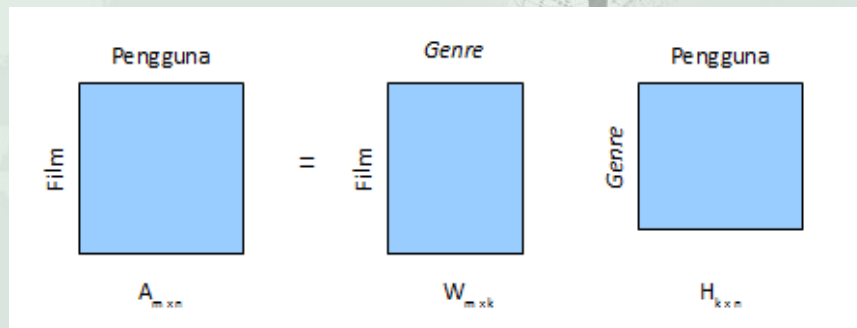


9

Matrix Factorization

Latent Variable Models

- Misal matriks $A_{m \times n}$ adalah matriks film-pengguna, maka variabel tersembunyi pada data tersebut dapat berupa genre-genre film:



10

Nonnegative Matrix Factorization

Formulasi Masalah

Diberikan suatu matriks non negatif V berukuran $m \times n$ dan suatu bilangan bulat positif $k < \min\{m, n\}$, maka masalah NMF dapat diformulasikan sebagai suatu masalah optimasi berkendala sbb:

$$\begin{aligned} \min_{W, H} \quad & f(W, H) = \frac{1}{2} \|V - WH\|^2 \\ \text{s.t.} \quad & W_{ij} \geq 0, H_{kl} \geq 0, \forall i, j, k, l \end{aligned}$$

dimana W adalah matriks $m \times k$, dan H adalah matriks $k \times n$

11

Nonnegative Matrix Factorization

Formulasi Masalah : Karakteristik Solusi

- *Definisi:* $S \in R^n$ adalah suatu *himpunan konveks* jika ruas garis lurus yang menghubungkan dua titik didalam S terletak semuanya didalam S . Secara formal, untuk sembarang dua titik $x \in S$ dan $y \in S$, maka $\alpha x + (1-\alpha)y \in S$
- *Definisi:* f adalah suatu *fungsi konveks* jika domainnya adalah suatu himpunan konveks dan jika untuk sembarang dua titik \mathbf{x} dan \mathbf{y} pada domain ini, maka grafik dari f terletak dibawah garis lurus yang menghubungkan $(\mathbf{x}, f(\mathbf{x}))$ ke $(\mathbf{y}, f(\mathbf{y}))$ di dalam ruang R^{n+1} , yaitu:

$$f(\alpha \mathbf{x} + (1-\alpha)\mathbf{y}) \leq \alpha f(\mathbf{x}) + (1-\alpha)f(\mathbf{y}), \text{ untuk semua } \alpha \in [0,1]$$

12

Nonnegative Matrix Factorization

Formulasi Masalah : Karakteristik Solusi

- *Definisi:* Suatu masalah optimasi berkendala disebut konveks jika fungsi objektif f adalah suatu *fungsi konveks* dan kendalanya membentuk suatu *himpunan konveks*.
- *Teorema:* Jika suatu masalah optimasi berkendala adalah konveks maka sembarang titik minimum lokal \mathbf{x}^* adalah suatu titik minimum global dari f . Jika ada tambahan bahwa f dapat diturunkan, maka sembarang titik stasioner \mathbf{x}^* adalah suatu titik minimum global dari f .

Bukti: lihat [1] hal 349-350 dan hal 17

13

Nonnegative Matrix Factorization

Formulasi Masalah : Karakteristik Solusi

- Fungsi $f(W,H)$ adalah konveks pada W atau H , akan tetapi tidak konveks pada W dan H .
- Sehingga, solusi optimal yang realistis untuk formulasi masalah diatas adalah bersifat minimum lokal, bukan minimum global

14

Nonnegative Matrix Factorization

Metode

- Secara umum, ada tiga metode yang sering digunakan untuk menyelesaikan masalah NMF, yaitu:
 - *Gradient Descent*
 - *Multiplicative Update*
 - *Alternating Least Squares*

15

Nonnegative Matrix Factorization

Gradient Descent

Algoritma 1. Metode *Projected Gradient Descent*

1. $\mathbf{W} = \text{rand}(m,k)$, dimana $w_{ij} \geq 0$
2. $\mathbf{H} = \text{rand}(k,n)$, dimana $h_{ij} \geq 0$
3. **for** $i = 1$ to maxiter **do**
4. $\mathbf{H} = \mathbf{H} - \alpha_{\mathbf{H}} \partial f / \partial \mathbf{H}$
5. Proyeksikan semua elemen negatif \mathbf{H} pada 0
6. $\mathbf{W} = \mathbf{W} - \alpha_{\mathbf{W}} \partial f / \partial \mathbf{W}$
7. Proyeksikan semua elemen negatif \mathbf{W} pada 0
8. **end for**

- Karena hasil dari metode *gradient descent* mungkin negatif, maka memproyeksikan nilai negatif tersebut ke nilai non negatif terdekat adalah cara yang umum dilakukan (Langkah 5, 7) [2]

16

Nonnegative Matrix Factorization

Gradient Descent : Konvergensi

- Tanpa pemilihan yang cermat terhadap parameter ukuran langkah pencarian α_w dan α_H , sedikit sekali yang dapat dikatakan terkait dengan konvergensi dari metode *gradient descent*.
- Penambahan proyeksi non negatif membuat analisis kekonvergenan metode ini semakin sulit dilakukan.

17

Nonnegative Matrix Factorization

Multiplicative Update

Algoritma 2. *Multiplicative Update*

1. $\mathbf{W} = \text{rand}(m,k)$, dimana $w_{ij} \geq 0$
2. $\mathbf{H} = \text{rand}(k,n)$, dimana $h_{ij} \geq 0$
3. **for** $i = 1$ to maxiter **do**
4. $\mathbf{H} = \mathbf{H} \cdot (\mathbf{V}^T \mathbf{V}) ./ (\mathbf{W}^T \mathbf{W} \mathbf{H})$
5. $\mathbf{W} = \mathbf{W} \cdot (\mathbf{V} \mathbf{H}^T) ./ (\mathbf{W} \mathbf{H} \mathbf{H}^T)$
6. **end for**

- Berbeda dengan metode *gradient descent* yang menggunakan operasi penjumlahan, metode *multiplicative update* menggunakan operasi perkalian untuk pembaruan nilai \mathbf{W} dan \mathbf{H} (Langkah 4,5) [3]

18

Nonnegative Matrix Factorization

Multiplicative Update : Konvergensi

- Metode ini menggunakan *gradient* dan sifat *continual non-increasing* dari fungsi objektif $f(W,H)$ untuk mengklaim bahwa algoritma akan konvergen ke titik minimum lokal [4].
- Akan tetapi klaim ini kemudian dibantah pada beberapa penelitian
- Secara ringkas, konvergensi dari metode *multiplicative update rule* dapat dinyatakan sebagai berikut: ketika algoritma konvergen ke suatu titik limit yang terletak di dalam (*interior*) dari daerah layak (*feasible*), maka titik ini adalah suatu titik stasioner. Titik stasioner ini bisa jadi minimum lokal atau bukan. Jika titik limit tersebut terletak pada batas (*boundary*) dari daerah layak, maka stasioneritas dari titik tersebut tidak dapat ditentukan [5]

19

Nonnegative Matrix Factorization

Alternating Nonnegative Least Squares

Algoritma 3. *Alternating Non-negative Least Squares*

1. $W = \text{rand}(m,k)$
2. **for** $i = 1$ to maxiter **do**
3. $H = \min_{H \geq 0} f(W,H)$
4. $W = \min_{W \geq 0} f(W,H)$
5. **end for**

- W adalah suatu konstanta, sehingga Langkah 3 adalah suatu masalah *nonnegative least squares*
- Sebaliknya H menjadi konstanta pada Langkah 4, sehingga Langkah 4 juga adalah suatu masalah *nonnegative least squares*
- Dengan kata lain, W dan H dicari dengan menggunakan *nonnegative least squares* secara bergantian (*alternating*)

20

Nonnegative Matrix Factorization

Alternating Nonnegative Least Squares : Konvergensi

- Sembarang titik limit yang dihasilkan oleh metode *alternating least squares* adalah suatu titik stasioner [5]
- Dengan kata lain, metode ini memiliki sifat kekonvergenan yang lebih baik dari dua metode sebelumnya

21

Nonnegative Matrix Factorization

Alternating Nonnegative Least Squares

- Selanjutnya, kinerja metode ini sangat dipengaruhi oleh metode yang digunakan untuk menyelesaikan sub masalah *nonnegative least squares*
- Sub masalah ini dapat juga dilihat sebagai masalah *bound-constrained optimization*, yaitu:

$$\begin{aligned} \min_H \quad & f(W, H) = \frac{1}{2} \|V - WH\|^2 \\ \text{s.t.} \quad & H_{kl} \geq 0, \forall k, l \end{aligned}$$

$$\begin{aligned} \min_W \quad & f(W, H) = \frac{1}{2} \|V - WH\|^2 \\ \text{s.t.} \quad & W_{ij} \geq 0 \forall i, j \end{aligned}$$

22

Nonnegative Matrix Factorization

Alternating Nonnegative Least Squares

- Beberapa metode yang telah dikembangkan untuk menyelesaikan masalah *bound-constrained optimization* tersebut antara lain:
 - *Projected gradient descent* [6]
 - *Active-set* [7]
 - *Block principal pivoting* [8]

23

Alternating Nonnegative Least Squares

Projected Gradient Descent

Algoritma 4a. Metode *Projected Gradient Descent*

1. \mathbf{W} = prosedur sebelumnya
2. **for** $i = 1$ to maxiter **do**
3. $\mathbf{H} = \mathbf{H} - \alpha_{\mathbf{H}} \partial f / \partial \mathbf{H}$
4. Proyeksikan semua elemen negatif \mathbf{H} pada 0
5. **end for**

Algoritma 4b. Metode *Projected Gradient Descent*

1. \mathbf{H} = prosedur sebelumnya
2. **for** $i = 1$ to maxiter **do**
3. $\mathbf{W} = \mathbf{W} - \alpha_{\mathbf{W}} \partial f / \partial \mathbf{W}$
4. Proyeksikan semua elemen negatif \mathbf{W} pada 0
5. **end for**

24

Referensi

- 1) Nocedal, J., Wright, S. J. *Numerical Optimization*. Springer-Verlag, 1999
- 2) P. Paatero and U. Tapper. Positive matrix factorization: A non-negative factor model with optimal utilization of error estimates of data values. *Environmetrics*, 5:111–126, 1994.
- 3) D. D. Lee and H. S. Seung. Learning the parts of objects by non-negative matrix factorization. *Nature*, 401(6755):788–791, 1999
- 4) D. D. Lee and H. S. Seung. Algorithms for non-negative matrix factorization. In *Advances in Neural Information Processing System*, 2001
- 5) M. W. Berry, M. Browne, A. N. Langville, V. P. Pauca, R. J. Plemmons. Algorithms and applications for approximate nonnegative matrix factorization. *Computational Statistics & Data Analysis*, 52: 155-173, 2007.
- 6) C. J. Lin. Projected gradient methods for non-negative matrix factorization. *Neural Computation*, 19:2756-2779, 2007.

25

Referensi

- 7) H. Kim, H. Park. Nonnegative matrix factorization based on alternating nonnegativity constrained least squares and active set method. *SIAM Journal on Matrix Analysis and Applications*, 30(2): 713–730, 2008
- 8) J. Kim, H. Park. Fast nonnegative matrix factorization: an active-set-like method and comparisons. *SIAM Journal on Scientific Computing*, 33(6): 3261-3281, 2011
- 9) S. Arora, R. Ge, R. Kanna, A. Moitra. *Computing a nonnegative matrix factorization – provably*. Proceedings of the 44th Symposium on Theory of Computing, New York, 2012

26