

Maximum Margin Matrix Factorization

Nathan Srebro - Jason D. M. Rennie - Tommi S.
Jaakkola

Fabien Lepercque - Fouille de données

March 7, 2007

- (1) Introduction
- (2) Contexte
- (3) Factorisations de Matrices à Marge Maximun (MMMMF)
- (3) Résultats
- (3) Conclusion

Plan

(1) Introduction

(2) Contexte

(3) Factorisations de Matrices à Marge Maximun (MMMMF)

(3) Résultats

(3) Conclusion

Maximum Margin
Matrix
Factorization

Nathan Srebro -
Jason D. M.
Rennie - Tommi S.
Jaakkola

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximun
(MMMMF)

(3) Résultats

(3) Conclusion

- ▶ Nouvelle approche pour le filtrage collaboratif
- ▶ Inspiré par la technique de discrimination linéaire à large marge (SVM)
- ▶ Cas de matrices avec des données manquantes
- ▶ Pour le filtrage collaboratif, les techniques d'optimisation par SVD (Nathan Srebro and Tommi Jaakkola 2003) ne sont pas applicables
- ▶ Objectif : prédire des entrées non-observées de la matrice Y basé sur un ensemble d'entrées observées Y_s

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximum
(MMMMF)

(3) Résultats

(3) Conclusion

Données d'entrées

movies

	2	1		4			5	
	5	4			?	1		3
		3	5		2			
4		?		5	3		?	
		4	1	3			5	
		2			1	?		4
	1				5	5	4	
		2	?	5	?	4		
	3	3	1		5	2		1
	3			1		2	3	
	4		5	1		3		
		3			3	?		5
2	?	1		1				
		5		2	?	4	4	
	1		3	1	5	4		5
1		2		4			5	?

Users

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximun
(MMMMF)

(3) Résultats

(3) Conclusion

Données d'entrées

- ▶ On cherche à factoriser la matrice Y sous la forme $X = UV'$, $U \in R^{n \times k}$, $V \in R^{m \times k}$
- ▶ Dans le filtrage collaboratif, U (vecteurs de caractéristiques) et V sont inconnus et doivent être estimés.

The diagram shows the equation $Y \approx UV'$ where X is the result of the product. Y is a 10x10 matrix of ratings. U is a 10xk matrix of user features, V' is a kx10 matrix of item features, and X is a 10x10 matrix of predicted ratings with rank k .

2	4	5	1	4	2	
3	1		2	2	5	4
4	2	4	1		3	1
3		3	4	2		4
2	3	1		3	2	
	2	2	1		4	5
	2	4	1	4	2	3
1	3	1	1		4	3
4	2	2	5	3	1	

- ▶ Chaque colonne est une prédiction linéaire dans un espace de dimension réduite

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximum
(MMMF)

(3) Résultats

(3) Conclusion

- ▶ Simplification du problème : on utilise des labels binaires, $Y \in \pm 1^{n \times m}$
- ▶ Marge dure : recherche d'un minimum de la norme de la trace de la matrice = labels observés avec $X_{ia} Y_{ia} \geq 1$ pour $ia \in S$
- ▶ Marge molle : minimisation de la norme de la trace de X et la fonction coût relative à Ys : minimise $\|X\|_{\Sigma} + c \sum \max(0, 1 - Y_{ia} X_{ia})$

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximun
(MMMF)

(3) Résultats

(3) Conclusion

- ▶ Hypothèse: Matrices non négative
- ▶ Hypothèse: on peut reformuler la norme de la trace comme un problème semi-défini (SDP).
- ▶ Dans un problème typique de prédiction collaboratif, on observe une petite fraction des entrées de la matrice cible.

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximun
(MMMMF)

(3) Résultats

(3) Conclusion

Prédiction pour des nouveaux utilisateurs :

U

V'							
	-1	-1		+1			+1
	+1	+1			?	-1	-1
		-1	+1		+1		
+1		?		+1	-1		?
	+1	-1	-1			+1	
		-1			-1	?	+1
	-1			+1	+1	+1	
		-1	?	+1	?	+1	
	+1	+1	-1	+1	-1	-1	
	+1			-1		-1	+1
	+1		+1	-1		+1	
		-1			-1	?	+1
-1	?	-1	-1				
	+1		-1	?	+1	+1	
	-1	-1	-1	+1	+1	+1	
-1	-1		+1			+1	?

(1) Introduction

(2) Contexte


(3) Factorisations
de Matrices à
Marge Maximun
(MMMF)

(3) Résultats

(3) Conclusion

Prédiction pour des nouveaux utilisateurs :

- ▶ Objectif : prédire des entrées dans une ligne non observée sur l'apprentissage initial (nouvel utilisateur)
- ▶ Prédire la matrice cible avec les signes du rang k de la matrice revient à projeter les “items” et les “utilisateurs” vers des hyperplans
- ▶ Chaque hyperplan sépare les items positifs des négatifs (*large marge*).



Expérimentations

- ▶ Données tests : 100 utilisateurs sur un ensemble de 100K (données MovieLens)
- ▶ Comparaison entre 2 algorithmes comme référence/base : WLRA (weighted low rank approximation) et K-Medians
- ▶ 4 ensembles de données aléatoirement disposées
- ▶ Pour chacun des 4 sous-ensembles possibles, calcul de *3-fold cross-validation* sur le reste des données.
- ▶ Pour chacun des 4 sous-ensembles, on teste 2 MMMF et algorithmes références avec (*zero/one level-agreement error*) et MAE (erreur absolue moyenne) puis on mesure l'erreur avec les données tests

Résultats

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximun
(MMMF)

(3) Résultats

(3) Conclusion

Test Set	Method	ZOE		Method	MAE	
		CV	Test		CV	Test
1	WLRA rank 2	0.547	0.575	K-Medians K=2	0.678	0.691
2	WLRA rank 2	0.550	0.562	K-Medians K=2	0.686	0.681
3	WLRA rank 1	0.562	0.543	K-Medians K=2	0.700	0.681
4	WLRA rank 2	0.557	0.553	K-Medians K=2	0.685	0.696
Avg.			0.558			0.687
1	max-norm C=0.0012	0.543	0.562	max-norm C=0.0012	0.669	0.677
2	trace norm C=0.24	0.550	0.552	max-norm C=0.0011	0.675	0.683
3	max-norm C=0.0012	0.551	0.527	max-norm C=0.0012	0.668	0.646
4	max-norm C=0.0012	0.544	0.550	max-norm C=0.0012	0.667	0.686
Avg.			0.548			0.673

Conclusion

- ▶ Le calcul de MMMF est résolu avec une optimisation SDP.
- ▶ L'apprentissage est possible sur des dizaines de milliers de labels.
- ▶ Limitation : les entrées observées doivent être uniformément échantillonnées. Hypothèse peut réaliste
- ▶ Méthode généralisable

(1) Introduction

(2) Contexte

(3) Factorisations
de Matrices à
Marge Maximun
(MMMF)

(3) Résultats

(3) Conclusion