

Classification à partir d'une collection de matrices

Clément Grimal et Gilles Bisson (LIG, Université de Grenoble)

Atelier REiSO - 25 Mai 2010



UNIVERSITÉ DE
GRENOBLE


Classification...

La *classification* (ou *clustering*) : organiser des *individus* selon un critère de similarité, en « paquets » homogènes




Classification...

La *classification* (ou *clustering*) : organiser des *individus* selon un critère de similarité, en « paquets » homogènes




...et Bi-classification

La classification vue sous forme matricielle :




...et Bi-classification

La classification vue sous forme matricielle :



...et Bi-classification

Si les variables sont suffisamment homogènes...




La co-classification

Classifier **simultanément** deux types d'objets distincts

Classification de données multi-relationnelles

Données multi-relationnelles


Plusieurs (plus de 2) types d'objets distincts, liés par des relations de type co-occurrence




Classification de données multi-relationnelles

Données multi-relationnelles

Plusieurs (plus de 2) types d'objets distincts, liés par des relations de type co-occurrence



Autant de matrices de données que de relations, comment classifier au mieux les films ?



1 Algorithmes

- L'algorithme χ -SIM
- Extensions aux données multi-relationnelles

2 Expérimentations et Résultats

3 Conclusion et Perspectives

L'algorithme χ -SIM (1)

On considère une matrice de données \mathbf{M} *films* - *acteurs* et on cherche à calculer la matrice de similarité entre *films* \mathbf{SR} et entre *acteurs* \mathbf{SC} .

L'algorithme χ -SIM (1)

On considère une matrice de données \mathbf{M} *films* - *acteurs* et on cherche à calculer la matrice de similarité entre *films* \mathbf{SR} et entre *acteurs* \mathbf{SC} .

Fondements

- ▶ La similarité entre deux *films* est fonction de la similarité entre les *acteurs* qui y jouent
- ▶ La similarité entre deux *acteurs* est fonction de la similarité entre les *films* dans lesquels ils jouent

L'algorithme χ -SIM (1)

On considère une matrice de données \mathbf{M} *films* - *acteurs* et on cherche à calculer la matrice de similarité entre *films* \mathbf{SR} et entre *acteurs* \mathbf{SC} .

Fondements

- ▶ La similarité entre deux *films* est fonction de la similarité entre les *acteurs* qui y jouent
- ▶ La similarité entre deux *acteurs* est fonction de la similarité entre les *films* dans lesquels ils jouent

Classiquement, la similarité entre deux films $\mathbf{m}_i.$ et $\mathbf{m}_j.$ est calculée grâce aux *éléments* communs :

$$\text{Sim}(\mathbf{m}_i., \mathbf{m}_j.) =$$

$$F_s(m_{i1}, m_{j1}) + F_s(m_{i2}, m_{j2}) + \dots + F_s(m_{ic}, m_{jc})$$

L'algorithme χ -SIM (1)

On considère une matrice de données \mathbf{M} *films* - *acteurs* et on cherche à calculer la matrice de similarité entre *films* \mathbf{SR} et entre *acteurs* \mathbf{SC} .

Fondements

- ▶ La similarité entre deux *films* est fonction de la similarité entre les *acteurs* qui y jouent
- ▶ La similarité entre deux *acteurs* est fonction de la similarité entre les *films* dans lesquels ils jouent

Si l'on considère que $\forall i \in 1..c, sc_{ii} = 1$:

$$\text{Sim}(\mathbf{m}_{i.}, \mathbf{m}_{j.}) =$$

$$F_s(m_{i1}, m_{j1}) \times sc_{11} + F_s(m_{i2}, m_{j2}) \times sc_{22} + \dots + F_s(m_{ic}, m_{jc}) \times sc_{cc}$$

L'algorithme χ -SIM (1)

On considère une matrice de données \mathbf{M} *films* - *acteurs* et on cherche à calculer la matrice de similarité entre *films* \mathbf{SR} et entre *acteurs* \mathbf{SC} .

Fondements

- ▶ La similarité entre deux *films* est fonction de la similarité entre les *acteurs* qui y jouent
- ▶ La similarité entre deux *acteurs* est fonction de la similarité entre les *films* dans lesquels ils jouent

Généralisation afin de comparer tous les *acteurs* entre eux :

$$\text{Sim}(\mathbf{m}_{i.}, \mathbf{m}_{j.}) =$$

$$\begin{aligned} & F_s(m_{i1}, m_{j1}) \times sc_{11} + F_s(m_{i1}, m_{j2}) \times sc_{12} + \dots + F_s(m_{i1}, m_{jc}) \times sc_{1c} + \\ & F_s(m_{i2}, m_{j1}) \times sc_{21} + F_s(m_{i2}, m_{j2}) \times sc_{22} + \dots + F_s(m_{i2}, m_{jc}) \times sc_{2c} + \\ & \dots \\ & F_s(m_{ic}, m_{j1}) \times sc_{c1} + F_s(m_{ic}, m_{j2}) \times sc_{c2} + \dots + F_s(m_{ic}, m_{jc}) \times sc_{cc} \end{aligned}$$

L'algorithme χ -SIM (2)

En pratique, on considère que la fonction de similarité F_s est le produit, et on normalise les valeurs pour qu'elle appartienne à $[0, 1]$, par le produit du nombre d'acteurs du $i^{\text{ème}}$ film et du $j^{\text{ème}}$ film, soit $|\mathbf{m}_{i\cdot}| \times |\mathbf{m}_{j\cdot}|$

L'algorithme χ -SIM (2)

En pratique, on considère que la fonction de similarité F_s est le produit, et on normalise les valeurs pour qu'elle appartienne à $[0, 1]$, par le produit du nombre d'acteurs du $i^{\text{ème}}$ film et du $j^{\text{ème}}$ film, soit $|\mathbf{m}_{i\cdot}| \times |\mathbf{m}_{j\cdot}|$

Ainsi, on peut calculer :

$$\text{Sim}(\mathbf{m}_{i\cdot}, \mathbf{m}_{j\cdot}) = \frac{\mathbf{m}_{i\cdot} \times \mathbf{SC} \times \mathbf{m}_{j\cdot}^T}{|\mathbf{m}_{i\cdot}| \times |\mathbf{m}_{j\cdot}|}$$

L'algorithme χ -SIM (2)

En pratique, on considère que la fonction de similarité F_s est le produit, et on normalise les valeurs pour qu'elle appartienne à $[0, 1]$, par le produit du nombre d'acteurs du $i^{\text{ème}}$ film et du $j^{\text{ème}}$ film, soit $|\mathbf{m}_{i.}| \times |\mathbf{m}_{j.}|$

Ainsi, on peut calculer :

$$\text{Sim}(\mathbf{m}_{i.}, \mathbf{m}_{j.}) = \frac{\mathbf{m}_{i.} \times \mathbf{SC} \times \mathbf{m}_{j.}^T}{|\mathbf{m}_{i.}| \times |\mathbf{m}_{j.}|}$$

Le calcul pour *tous les films* peut d'exprimer sous forme matricielle :

$$\mathbf{SR} = (\mathbf{M} \times \mathbf{SC} \times \mathbf{M}^T) \circ \mathbf{NR} \quad \text{avec } nr_{ij} = \frac{1}{|\mathbf{m}_{i.}| \times |\mathbf{m}_{j.}|}$$

$$\mathbf{SC} = (\mathbf{M}^T \times \mathbf{SR} \times \mathbf{M}) \circ \mathbf{NC} \quad \text{avec } nc_{ij} = \frac{1}{|\mathbf{m}_{i.}| \times |\mathbf{m}_{j.}|}$$

L'algorithme χ -SIM (2)

En pratique, on considère que la fonction de similarité F_s est le produit, et on normalise les valeurs pour qu'elle appartienne à $[0, 1]$, par le produit du nombre d'acteurs du $i^{\text{ème}}$ film et du $j^{\text{ème}}$ film, soit $|\mathbf{m}_{i\cdot}| \times |\mathbf{m}_{j\cdot}|$

Ainsi, on peut calculer :

$$\text{Sim}(\mathbf{m}_{i\cdot}, \mathbf{m}_{j\cdot}) = \frac{\mathbf{m}_{i\cdot} \times \mathbf{SC} \times \mathbf{m}_{j\cdot}^T}{|\mathbf{m}_{i\cdot}| \times |\mathbf{m}_{j\cdot}|}$$

On résout le système d'équations correspondant de manière itérative :

$$\mathbf{SR}^{(t)} = (\mathbf{M} \times \mathbf{SC}^{(t-1)} \times \mathbf{M}^T) \circ \mathbf{NR} \quad \text{avec } nr_{ij} = \frac{1}{|\mathbf{m}_{i\cdot}| \times |\mathbf{m}_{j\cdot}|}$$


$$\mathbf{SC}^{(t)} = (\mathbf{M}^T \times \mathbf{SR}^{(t-1)} \times \mathbf{M}) \circ \mathbf{NC} \quad \text{avec } nc_{ij} = \frac{1}{|\mathbf{m}^i| \times |\mathbf{m}^j|}$$

avec $\mathbf{SR}^{(0)} = \mathbf{I}_r$ et $\mathbf{SC}^{(0)} = \mathbf{I}_c$.

Principe des extensions

Nous allons maintenant proposer trois méthodes, utilisant l'algorithme χ -SIM afin de classifier des données multi-relationnelles.

L'algorithme χ -SIM sera représenté de façon schématique :




avec \mathbf{I}_r la matrice identité de taille r , correspondant à une absence de connaissance *a priori* sur les similarités entre lignes.

Structure en Cascade

Principe


Utiliser la matrice de similarité calculée par une première instance de χ -SIM grâce à une première matrice de données pour initialiser une seconde instance de χ -SIM utilisant une seconde matrice de données



Structure en Cascade

Principe


Utiliser la matrice de similarité calculée par une première instance de χ -SIM grâce à une première matrice de données pour initialiser une seconde instance de χ -SIM utilisant une seconde matrice de données



Structure en Cascade

Principe

Utiliser la matrice de similarité calculée par une première instance de χ -SIM grâce à une première matrice de données pour initialiser une seconde instance de χ -SIM utilisant une seconde matrice de données




Questions

- ▶ Ordre des matrices ?
- ▶ Nombre d'itérations pour chaque instance ?

Structure en Anneau

Principe


Similaire à la structure en Cascade, sauf que le nombre d'itérations par instance de χ -SIM est fixé à 1, et que l'on peut alterner entre plusieurs instances



Structure en Anneau

Principe


Similaire à la structure en Cascade, sauf que le nombre d'itérations par instance de χ -SIM est fixé à 1, et que l'on peut alterner entre plusieurs instances



Structure en Anneau

Principe

Similaire à la structure en Cascade, sauf que le nombre d'itérations par instance de χ -SIM est fixé à 1, et que l'on peut alterner entre plusieurs instances




Questions

- ▶ Ordre des matrices ?
- ▶ Nombre d'itérations totales ?

Combinaison

Principe


Calcul des matrices de similarité grâce à plusieurs instances de χ -SIM utilisant des matrices de données différentes, puis combinaison de ces matrices



Combinaison

Principe


Calcul des matrices de similarité grâce à plusieurs instances de χ -SIM utilisant des matrices de données différentes, puis combinaison de ces matrices



Combinaison

Principe

Calcul des matrices de similarité grâce à plusieurs instances de χ -SIM utilisant des matrices de données différentes, puis combinaison de ces matrices



Questions

- ▶ Nombre d'itérations pour chaque instance ?
- ▶ Stratégie de combinaison (min, max, moyenne...)?

1 Contexte

- Classification et Bi-classification
- Classification de données multi-relationnelles

2 Algorithmes

- L'algorithme χ -SIM
- Extensions aux données multi-relationnelles

3 Expérimentations et Résultats

4 Conclusion et Perspectives

Base expérimentale

Créée à partir d'IMDb pour recueillir des films, ainsi que leur genre, leur casting et les mots-clés affectés par des utilisateurs.

Base expérimentale

Créée à partir d'IMDb pour recueillir des films, ainsi que leur genre, leur casting et les mots-clés affectés par des utilisateurs.

Description

- ▶ 617 films de 17 genres différents (environ 36 films par genre)
- ▶ 1878 mots-clés → Matrice *films - mots-clés* : \mathbf{M}_1
- ▶ 1398 acteurs → Matrice *films - acteurs* : \mathbf{M}_2

Base expérimentale

Créée à partir d'IMDb pour recueillir des films, ainsi que leur genre, leur casting et les mots-clés affectés par des utilisateurs.

Description

- ▶ 617 films de 17 genres différents (environ 36 films par genre)
- ▶ 1878 mots-clés → Matrice *films - mots-clés* : \mathbf{M}_1
- ▶ 1398 acteurs → Matrice *films - acteurs* : \mathbf{M}_2

Objectif : classifier les films par genre, en utilisant \mathbf{M}_1 **et** \mathbf{M}_2

Algorithmes utilisés et critère d'évaluation

Algorithmes utilisés

Comparaison de nos 3 méthodes à :

- ▶ la similarité de cosinus (notre « ligne de base »)
- ▶ la mesure de similarité induite par LSA (Deerwester et al., 1990)
- ▶ l'algorithme de co-classification ITCC (Dhillon et al., 2003)
- ▶ la co-similarité χ -SIM (Bisson and Hussain, 2008)

Algorithmes utilisés et critère d'évaluation

Algorithmes utilisés

Comparaison de nos 3 méthodes à :

- ▶ la similarité de cosinus (notre « ligne de base »)
- ▶ la mesure de similarité induite par LSA (Deerwester et al., 1990)
- ▶ l'algorithme de co-classification ITCC (Dhillon et al., 2003)
- ▶ la co-similarité χ -SIM (Bisson and Hussain, 2008)

Critère d'évaluation

La précision micro-moyennée introduite par Dhillon et al. (2003), pour laquelle une valeur de 1 correspond à une classification parfaite.

Résultats

Méthode	Cosinus	LSA	ITCC	χ -SIM
M_1	0,225	0,277	0,280	0,282
M_2	0,212	0,216	0,160	0,217
M_1M_2	0,284	0,295	0,266	0,280

Nous avons également tester ces méthodes avec une matrice nommée M_1M_2 , qui est la concaténation horizontale de M_1 et de M_2 .

Résultats

Méthode	Cosinus	LSA	ITCC	χ -SIM
M_1	0,225	0,277	0,280	0,282
M_2	0,212	0,216	0,160	0,217
$M_1 M_2$	0,284	0,295	0,266	0,280

Cascade	$M_1 \rightarrow M_2$	$M_2 \rightarrow M_1$
1 itération \rightarrow 1 itération	0,207	0,254
1 itération \rightarrow 2 itérations	0,227	0,241
1 itérations \rightarrow 3 itérations	0,222	0,285
2 itérations \rightarrow 1 itérations	0,216	0,292
2 itérations \rightarrow 2 itérations	0,227	0,246
2 itérations \rightarrow 3 itérations	0,225	0,285

Résultats

Méthode	Cosinus	LSA	ITCC	χ -SIM
M_1	0,225	0,277	0,280	0,282
M_2	0,212	0,216	0,160	0,217
$M_1 M_2$	0,284	0,295	0,266	0,280

Anneau	$M_1 \leftrightarrow M_2$	$M_2 \leftrightarrow M_1$
3 itérations	0,292	0,224
4 itérations	0,219	0,266

Résultats

Méthode	Cosinus	LSA	ITCC	χ -SIM
M_1	0,225	0,277	0,280	0,282
M_2	0,212	0,216	0,160	0,217
$M_1 M_2$	0,284	0,295	0,266	0,280

Combinaison	Combinaison : $M_1 M_2$		
	Moyenne	Minimum	Maximum
2 itérations - 2 itérations	0,232	0,220	0,241
3 itérations - 3 itérations	0,222	0,225	0,266

Conclusion et Perspectives

Conclusion

- ▶ Nous avons testé différentes méthodes utilisant un algorithme de calcul de co-similarité pour traiter des données multi-relationnelles
- ▶ Les résultats obtenus sont moins bon que ceux de LSA mais on observe une légère amélioration par rapport à l'utilisation de la méthode χ -SIM seule

Conclusion et Perspectives

Conclusion

- ▶ Nous avons testé différentes méthodes utilisant un algorithme de calcul de co-similarité pour traiter des données multi-relationnelles
- ▶ Les résultats obtenus sont moins bon que ceux de LSA mais on observe une légère amélioration par rapport à l'utilisation de la méthode χ -SIM seule


Perspectives

- ▶ Amélioration de χ -SIM en cours permettant d'obtenir de meilleurs résultats que LSA
- ▶ Tester nos méthodes sur des jeux de données
 - ▶ plus complexes
 - ▶ concernant d'autres domaines
- ▶ Trouver des fondements théoriques à notre approche


Références

- Bisson, G. and Hussain, F. (2008). Chi-sim : A new similarity measure for the co-clustering task. In *Seventh International Conference on Machine Learning and Applications (ICMLA)*, pages 211–217. IEEE Computer Society.
- Deerwester, S., Dumais, S. T., Furnas, G. W., Thomas, and Harshman, R. (1990). Indexing by latent semantic analysis. *Journal of the American Society for Information Science*, 41 :391–407.
- Dhillon, I. S., Mallela, S., and Modha, D. S. (2003). Information-theoretic co-clustering. In *Proceedings of The Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining(KDD-2003)*, pages 89–98.


Grphe bi-partite




Grphe bi-partite



Grphe bi-partite



Grphe bi-partite



Méthodes

Pour LSA

Nous avons fait varier le nombre k de valeurs singulières conservées dans l'intervalle $[10 \dots 200]$ avec un pas de 10.

Pour ITCC

Nous avons fait varier pour chaque ensemble de tests le nombre de classes de mots dans la plage de valeur suggérée par Dhillon et al. (2003).
+ Trois répétitions pour garder le meilleur résultat.

Pour Cosinus, LSA et χ -SIM

Utilisation d'un algorithme de Classification Ascendante Hiérarchique (CAH) pour déterminer les groupes en fonction des similarités.