

21 Janvier 2013

Utiliser le front de Pareto pour évaluer les performances d'un algorithme non supervisé de construction d'attributs

Marian-Andrei RizoIU

**Laboratoire ERIC
Université Lumière Lyon 2
France**

Les données : Représentation matricielle attribut-valeur ;
 Les valeurs sont **booléennes**.

Les défis :


- Corrélation entre les attributs ;
- Mauvaise représentation des données.

	a_1	a_2	a_3	a_4	a_5
φ_1		0	0		x_1^d
φ_2		1	0		x_2^d
φ_3		0	0		x_3^d
φ_4		0	0		x_4^d
φ_5		1	1		x_5^d
φ_6		1	1		x_6^d

L'objectif : Réduire les corrélations entre les attributs ;
Découvrir des informations manquantes sur les relations entre les attributs.

Étant donné l'ensemble des attributs :

{eau, cascade, manifestation, urbain, groupe, intérieur}



Relations structurelles :

cascade ↔ *eau*

(e.g. type-de, part-du)

Relations sémantiques :

manifestation ↔ *urbain*

(issues des données)

L'objectif : Réduire les corrélations entre les attributs ;
Découvrir des informations manquantes sur les relations entre les attributs.

{groupes, rue, bâtiment, intérieur}



groupes \wedge rue \wedge intérieur

groupes \wedge rue \wedge bâtiment

Le plan:


1. La problématique
 - 1.1 Les données
 - 1.2 L'objectif
2. La solution proposée:
 - 2.1 **uFC** - construire des conjonctions d'attributs
 - 2.2 Exemple d'exécution
 - 2.3 Évaluation - deux mesures opposées
 - 2.4 Le compromis entre les deux critères opposés
3. Utilisations du front de Pareto
 - 3.1 Premières conclusions
 - 3.2 Heuristique pour choisir les paramètres
 - 3.3 Évaluation de l'heuristique "risk-based"
 - 3.4 Évaluation du filtrage
4. Conclusion




La solution proposée : Remplacer les paires d'attributs très corrélées par des conjonctions d'attributs et leur négations.

$$\{f_i, f_j\} \longrightarrow \{f_i \wedge f_j, f_i \wedge \overline{f_j}, \overline{f_i} \wedge f_j\}$$

Algorithme *uFC* :

- Chercher des paires d'attributs corrélées (coefficient de Pearson) ;
- Construire de nouveaux attributs.
- Éliminer les anciens attributs et les attributs sans support.





Évaluation d'un ensemble d'attributs - deux mesures contraires :

Overlapping Index : basée sur la formule de Poincaré,
mesure la corrélation totale de la collection des attributs

→ $OI(F) \in [0,1]$, *meilleur vers 0*

Complexité : nombre des attributs par rapport au nombre
maximal qui peut être construit ;

→ A chaque itération, le nombre des attributs augmente ;

→ La longueur moyenne des attributs augmente ;


→ $C_0(F) \in [0,1]$, *meilleur vers 0*

Le compromis entre les deux critères opposés.

- Notre problème se réduit à optimiser 2 critères opposés simultanément ;
- On utilise la notion d'optimalité Pareto ;
- Pas de solution unique, mais un ensemble de solutions – **Front de Pareto.**

Idée:

Faire varier les 2 paramètres et projeter les solutions dans l'espace (OI, C_0)





Le plan:

1. La problématique
 - 1.1 Les données
 - 1.2 L'objectif
2. La solution proposée:
 - 2.1 uFC - construire des conjonctions d'attributs
 - 2.2 Exemple d'exécution
 - 2.3 Évaluation - deux mesures opposées
 - 2.4 Le compromis entre les deux critères opposés
3. Utilisations du front de Pareto
 - 3.1 Premières conclusions
 - 3.2 Heuristique pour choisir les paramètres
 - 3.3 Évaluation de l'heuristique "risk-based"
 - 3.4 Évaluation du filtrage
4. Conclusion

Premières conclusions :

- Visualisation de l'espace des solutions ;
- Stabilité de l'algorithme ;
- Détecter empiriquement le **sur-apprentissage** ;
- Vitesse de convergence.





Heuristique pour choisir les paramètres :

L'heuristique "Closest-point" consiste à choisir sur le front Pareto le point où la perte de complexité (C_θ) et le gain de score de co-occurrence (OI) sont relativement égaux.

groupes \wedge rue \wedge intérieur
groupes \wedge rue \wedge intérieur
groupes \wedge rue \wedge intérieur
eau \wedge cascade \wedge arbre \wedge forêt
eau \wedge cascade \wedge arbre \wedge forêt
eau \wedge cascade \wedge arbre \wedge forêt
ciel \wedge bâtiment \wedge panorama
ciel \wedge bâtiment \wedge panorama

ciel \wedge bâtiment \wedge panorama
groupes \wedge rue \wedge personne
groupes \wedge rue \wedge personne
groupes \wedge rue \wedge personne
ciel \wedge bâtiment \wedge groupes \wedge rue
ciel \wedge bâtiment \wedge groupes \wedge rue
ciel \wedge bâtiment \wedge groupes \wedge rue
eau \wedge cascade
arbre \wedge forêt
gazon
statue




L'heuristique "risk-based" :

Un des paramètres (λ) est choisi en utilisant des tests statistiques

Le deuxième est transformé dans une condition d'arrêt des itérations.

Ça évite les exécutions multiples pour déterminer les valeurs des paramètres.

Nous utilisons le front de Pareto pour évaluer les solutions choisies par rapport à la solution "closest-point"




On utilise l'optimalité Pareto pour identifier des problèmes :


L'heuristique "risk-based" ne donne pas toujours de bons résultats

On propose un filtrage théorique


Risk-based and closest-point (magnified)



Pruned and Non-pruned Pareto Fronts (zoomed)



Risk-based and closest-point (magnified)



Le plan:

1. La problématique
 - 1.1 Les données
 - 1.2 L'objectif
2. La solution proposée:
 - 2.1 **uFC** - construire des conjonctions d'attributs
 - 2.2 Exemple d'exécution
 - 2.3 Évaluation - deux mesures opposées
 - 2.4 Le compromis entre les deux critères opposés
3. Utilisations du front de Pareto
 - 3.1 Premières conclusions
 - 3.2 Heuristique pour choisir les paramètres
 - 3.3 Évaluation de l'heuristique "risk-based"
 - 3.4 Évaluation du filtrage
4. Conclusion

Conclusion :

Le front de Pareto nous a aidé à :

- visualiser l'espace de nos solutions;
- évaluer empiriquement la convergence et les performances;
- choisir les paramètres de notre algorithme;
- comparer les performances des deux algorithmes.

pourtant...

On n'a pas utilisé tout le pouvoir de l'optimalité et du front de Pareto.

Perspectives :

Comment mieux utiliser l'agrégation multi-critères dans notre contexte?

Est-ce que vous avez
des idées?

Merci!

Bibliographie :

[a] Rizoïu, M.-A., Velcin, J., & Lallich, S. (2013). Unsupervised feature construction for improving data representation and semantics. *Journal of Intelligent Information Systems*.

[b] Sawaragi Y, Nakayama H, Tanino T (1985) *Theory of multiobjective optimization*, vol 176. Academic Press New York.