

De l'usage de la statistique implicative dans les arbres de classification

Gilbert Ritschard
Dept Econométrie, Université de Genève
Journées ASI, Palerme, octobre 2005

Plan

- 1 Introduction
- 2 Arbres et indices d'implication
 - Le contexte
 - Indice implication et résidu
- 3 Pertinence individuelle des règles
- 4 Choix de la conclusion dans les feuilles
- 5 Conclusion

<http://mephisto.unige.ch>

ASI05 toc intro impl arbre res pert choix conc

◀▶▲▼ 4/10/2005gr 1

1 Introduction

- Statistique implicative (SI)
 - Outil d'analyse de données (Gras, 1979)
 - Intérêt pour fouille de règles d'association (Suzuki and Kodratoff, 1998; Gras et al., 2001)
- **La SI a-t-elle un intérêt pour la classification supervisée ?**
- Nous discutons ici le cas des arbres d'induction (règles de classification).
 - Indice d'implication pour règles de classification
 - Présentation comme résidu standardisé
 - Variantes issues de l'analyse de tables de contingence
 - Validation individuelle des règles de classification
 - Conclusion optimale des règles (alternative à la règle majoritaire)

ASI05 toc intro impl arbre res pert choix conc

◀▶▲▼ 4/10/2005gr 2

2 Arbres et indices d'implication

2.1 Le contexte

- Jeu de données et exemple d'arbre induit
- Règles de classification et contre-exemples (notations)

ASI05 toc intro impl arbre res pert choix conc

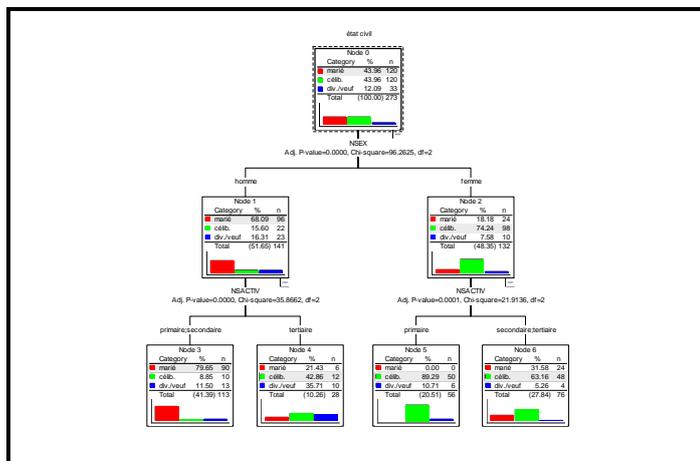
◀▶▲▼ 4/10/2005gr 3

Jeu (fictif) de 273 données

Etat civil	Sexe	Secteur activité	Nombre de cas
marié	homme	primaire	50
marié	homme	secondaire	40
marié	homme	tertiaire	6
marié	femme	primaire	0
marié	femme	secondaire	14
marié	femme	tertiaire	10
célibataire	homme	primaire	5
célibataire	homme	secondaire	5
célibataire	homme	tertiaire	12
célibataire	femme	primaire	50
célibataire	femme	secondaire	30
célibataire	femme	tertiaire	18
divorcé/veuf	homme	primaire	5
divorcé/veuf	homme	secondaire	8
divorcé/veuf	homme	tertiaire	10
divorcé/veuf	femme	primaire	6
divorcé/veuf	femme	secondaire	2
divorcé/veuf	femme	tertiaire	2

ASI05 toc intro impl arbre res pert choix conc

◀▶▲▼ 4/10/2005gr 4



ASI05 toc intro impl arbre res pert choix conc

◀▶▲▼ 4/10/2005gr 5

Table associée à l'arbre induit

Etat civil	Homme		Femme		total
	primaire ou secondaire	tertiaire	primaire ou secondaire	tertiaire	
Marié	90	6	0	24	120
Célibataire	10	12	50	48	120
divorcé/veuf	13	10	6	4	33
Total	113	28	56	76	273

Règles (selon classe majoritaire) :

- R1. Homme du secteur primaire ou secondaire ⇒ marié
- R2. Homme du secteur tertiaire ⇒ célibataire
- R3. Femme du secteur primaire ⇒ célibataire
- R4. Homme du secteur secondaire ou tertiaire ⇒ célibataire

ASI05 toc intro impl arbre res pert choix conc

◀▶▲▼ 4/10/2005gr 6

Contre-exemples

Indice d'implication de Gras se définit à partir des contre-exemples.

Contre-exemple : vérifie prémisses, mais pas la conclusion (erreur de classement)

Notations :

- b conclusion de la règle j (varie avec j)
- n_b nombre total de cas vérifiant b , $n_{\bar{b}} = n - n_b$ (varie avec j)
- n_{bj} nombre de cas avec prémisses j qui vérifient la conclusion b
- $n_{\bar{b}j}$ nombre de contre-exemples de la règle j

H_0 Hypothèse de répartition entre b et \bar{b} indépendante de la condition

Nombre de contre-exemples sous H_0 :

$$N_{\bar{b}j} \sim \text{Poisson}(n_{\bar{b}j}^e)$$

avec $E(N_{\bar{b}j}|H_0) = \text{Var}(N_{\bar{b}j}|H_0) = n_{\bar{b}j}^e = n_{\bar{b}} \cdot n_{\cdot j}$. (!!! b varie avec j)

Effectifs $n_{\bar{b}j}$ et n_{bj} des contre-exemples et exemples observés

classe prédite c_{pred}	Homme		Femme		total
	primaire ou secondaire	tertiaire	primaire ou secondaire	tertiaire	
0 (contre-exemple)	23	16	6	28	73
1 (exemple)	90	12	50	48	200
Total	113	28	56	76	273

Effectifs $n_{\bar{b}j}^e$ et n_{bj}^e des contre-exemples et exemples attendus (indép.)

classe prédite c_{pred}	Homme		Femme		total
	primaire ou secondaire	tertiaire	primaire ou secondaire	tertiaire	
0 (contre-exemple)	63.33	15.69	31.38	42.59	153
1 (exemple)	49.67	12.31	24.62	33.41	120
Total	113	28	56	76	273

2.2 Indice implication et résidu

$$\text{Imp}(j) = \frac{n_{\bar{b}j} - n_{\bar{b}j}^e}{\sqrt{n_{\bar{b}j}^e}}$$

Contributions au Khi^2 mesurant la distance entre observés et attendus

classe prédite c_{pred}	Homme		Femme	
	primaire ou secondaire	tertiaire	primaire ou secondaire	tertiaire
0 (contre-exemple)	-5.068	0.078	-4.531	-2.236
1 (exemple)	5.722	-0.088	5.116	2.525

$$\chi^2 = \sum_j \underbrace{\frac{(n_{\bar{b}j} - n_{\bar{b}j}^e)^2}{n_{\bar{b}j}^e}}_{\text{Imp}^2(j)} + \sum_j \frac{(n_{bj} - n_{bj}^e)^2}{n_{bj}^e}$$

Autres résidus (utilisés pour l'ajustement de table de contingence)

- standardisé (=Imp(j)) res_s contribution au Khi^2 de Pearson
- déviance res_d contribution au Khi^2 du rapport de vraisemblance (Bishop et al., 1975, p 136)
- ajusté d'Haberman res_a res_s divisé par son erreur standard (Agestri, 1990, p 224)
- Freeman-Tukey res_{TF} stabilisation de la variance (Bishop et al., 1975, p 137)

Résidu	Règle 1	Règle 2	Règle 3	Règle 4
standardisé (=Imp(j)) res_s	-5.068	0.078	-4.531	-2.236
déviance res_d	-6.826	0.788	-4.456	-4.847
Freeman-Tukey res_{TF}	-6.253	0.138	-6.154	-2.414
ajusté res_a	-9.985	0.124	-7.666	-3.970

$n_{\bar{b}j}^e$ n'est qu'une estimation \Rightarrow variance de Imp(j) < 1

Et Imp(j) tend à sous-estimer l'implication.

Les autres résidus sont plus proches d'une $N(0, 1)$.

Degré de signification de l'indice d'implication

p -valeur de l'indice d'implication = $p(N_{\bar{b}j} \geq n_{\bar{b}j}|H_0)$.

Prob. que le hasard génère plus de contre-exemples que le nombre observé

Calcul conditionnel à n_b et $n_{\cdot j}$.

- avec Poisson lorsque n petit
- approximation normale pour n grand (≥ 5)

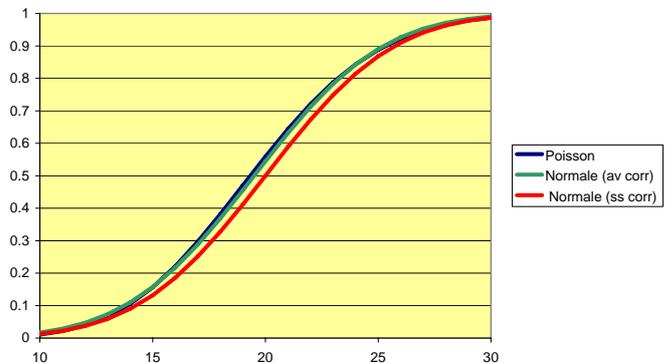
Pour l'approximation avec la normale :

correction pour la continuité

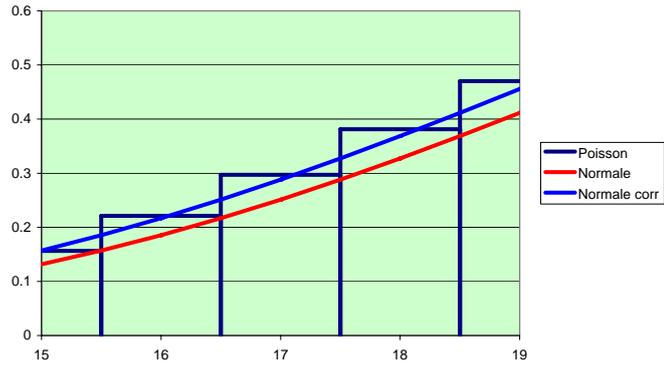
(ajouter 0,5 aux effectifs observés)

La différence peut encore atteindre 2.6 points de pourcentage pour $n_{\bar{b}j} = 100$.

Distributions (cumulées) de Poisson, normale et normale avec correction



Détail des distributions (cumulées) de Poisson, normale et normale avec correction



ASI05 toc intro impl arbre res pert choix conc

◀ ▶ ▲ ▼ 4/10/2005gr 13

Intensité d'implication

Intensité d'autant plus forte que la p -valeur est petite

⇒ **Intensité implication** = complémentaire à 1 de la p -valeur

Prob. obtenir sous H_0 moins de contre-exemples qu'observés

Gras et al. (2004) la définissent en termes de l'approximation normale, sans correction pour la continuité

Nous utilisons

$$\text{Intens}(j) = 1 - \phi\left(\frac{n_{\bar{b}j} + 0.5 - n_{b_j}^e}{\sqrt{n_{b_j}^e}}\right)$$

ASI05 toc intro impl arbre res pert choix conc

◀ ▶ ▲ ▼ 4/10/2005gr 14

Variantes d'intensité d'implication (avec correction continuité)

Résidu		Règle 1	Règle 2	Règle 3	Règle 4
standardisé	res_s	1.000	0.419	1.000	0.985
déviante	res_d	1.000	0.099	1.000	1.000
Freeman-Tukey	res_{FT}	1.000	0.350	1.000	0.988
ajusté	res_a	1.000	0.373	1.000	1.000

Intensité < 0.5 signifie qu'on a plus de contre-exemples que le nombre attendu sous H_0 .

Règle 2 sans intérêt puisqu'elle fait moins bien que le hasard.

ASI05 toc intro impl arbre res pert choix conc

◀ ▶ ▲ ▼ 4/10/2005gr 15

3 Pertinence individuelle des règles

En classification, et avec les arbres en particulier, il est d'usage d'évaluer la performance du classifieur globalement avec par exemple le taux d'erreur du classifieur en généralisation.

L'*intensité d'implication* et ses variantes sont des mesures utiles pour juger de la **pertinence individuelle des règles**.

Dans notre exemple

- R1, R3 et R4 sont clairement pertinents
- R2 ne l'est pas

Que faire des règles non pertinentes? (L'ensemble des règles devant définir une partition).

ASI05 toc intro impl arbre res pert choix conc

◀ ▶ ▲ ▼ 4/10/2005gr 16

Taux d'erreur et indice d'implication

nombre d'erreurs = nombre de contre-exemples

Taux d'erreur de la règle j :

$$\text{err}(j) = \frac{n_{\bar{b}j}}{n_j} = 1 - \text{conf}(j)$$

⇒ taux d'erreur a même inconvénient que confiance

Ne dit rien sur ce que la règle apporte de plus qu'une classification indépendante de toute condition!

Pour notre exemple :

	Règle 1	Règle 2	Règle 3	Règle 4	Nœud initial
taux d'erreur	0.20	0.57	0.11	0.36	0.56

Il faut comparer avec erreur au nœud initial.

En tant que résidu, l'indice d'implication inclut cette comparaison.

ASI05 toc intro impl arbre res pert choix conc

◀ ▶ ▲ ▼ 4/10/2005gr 17

Indice d'implication en généralisation

En pratique, on considère le taux d'erreur en généralisation (sur échantillon test) ou en validation croisée.

On peut de même calculer les indices et intensités d'implication en généralisation.

Alternativement, on peut songer dans l'esprit BIC et MDL, à calculer sur les données d'apprentissage un

indice d'implication pénalisé pour la complexité de la règle

ASI05 toc intro impl arbre res pert choix conc

◀ ▶ ▲ ▼ 4/10/2005gr 18

Indice pénalisé pour la complexité

complexité = longueur k de la règle (branche de l'arbre)

$$\text{Imp}_{pen}(j) = \text{res}_d(j) + \ln(n)k$$

Règle	res_d	k	Imp_{pen}
1	-6.826	2	4.39
2	0.788	2	12.01
3	-4.456	2	6.76
4	-4.847	2	6.37
Homme \Rightarrow marié	-7.119	1	-1.51
Femme \Rightarrow célib.	-7.271	1	-1.66

De ce point de vue, seules les règles définies au premier niveau de l'arbre seraient ici pertinentes.

Que faire des règles non pertinentes ?

1. Fusionner les cas concernés avec une autre règle.
2. Changer la conclusion de la règle.

Fusion

Dans exemple, fusion de R2 non pertinente avec la règle sœur R1

Résidu	Règle 1+2	Règle 1	Règle 2	Règle 3	Règle 4
standardisé	-3.8	-5.1	0.1	-4.5	-2.2
déviante	-7.1	-6.8	0.8	-4.5	-4.8
Freeman-Tukey	-8.3	-6.3	0.1	-6.2	-2.4
ajusté	-4.3	-10.0	0.1	-7.7	-3.9

4 Choix de la conclusion dans les feuilles

Conclusion SI-optimale :

classe pour laquelle on maximise l'intensité d'implication .

(Zighed and Rakotomalala, 2000, pp 282-287)

Exemple : choix de la conclusion pour la règle R2

Résidu		Indices			Intensité		
		marié	célib.	div./v	marié	célib	div./v
Standardisé	res_s	1.6	0.1	-1.3	0.043	0.419	0.891
Déviante	res_d	3.9	0.8	-3.4	0.000	0.099	0.999
Freeman-Tukey	res_{FT}	1.5	0.1	-1.4	0.054	0.398	0.895
Ajusté	res_a	2.4	0.1	-2.0	0.005	0.379	0.968
Imp_{pen}		15.1	12.0	7.9			

La conclusion "divorcé/veuf" est préférable à "célibataire" (classe majoritaire). R2 devient ainsi pertinente.

5 Conclusion

– Indices et intensités d'implication complètent utilement les mesures traditionnelles de qualité d'arbres d'induction en donnant des indications précieuses sur la pertinence individuelle de chaque règle.

– L'interprétation de l'indice d'implication comme un résidu, suggère des variantes issues de la modélisation de table de contingence.

– La conclusion SI-optimale fait apparaître que la classe modale n'est pas toujours la meilleure solution .

Perspectives

- Mettre en œuvre sur des jeux de données réelles.
- Expérimenter, en particulier l'indice d'implication pénalisé,

MERCI

Références

- Agresti, A. (1990). *Categorical Data Analysis*. New York: Wiley.
- Bishop, Y. M. M., S. E. Fienberg, and P. W. Holland (1975). *Discrete Multivariate Analysis*. Cambridge MA: MIT Press.
- Gras, R. (1979). *Contribution à l'étude expérimentale et à l'analyse de certaines acquisitions cognitives et de certains objectifs didactiques*. Thèse d'état, Université de Rennes 1, France.
- Gras, R., R. Couturier, J. Blanchard, H. Briand, P. Kuntz, et P. Peter (2004). Quelques critères pour une mesure de qualité de règle d'association. *Revue des nouvelles technologies de l'information RNTI E-1*, 3–30.
- Gras, R., P. Kuntz, et H. Briand (2001). Les fondements de l'analyse statistique implicite et leur prolongement pour la feuille de données. *Mathématique et Sciences Humaines 39*(154-155), 9–29.
- Suzuki, E. et Y. Kodratoff (1998). Discovery of surprising exception rules based on intensity of implication. In J. M. Zytkow et M. Quafafou (Eds.), *Principles of Data Mining and Knowledge Discovery, Second European Symposium, PKDD '98, Nantes, France, September 23-26, Proceedings*, pp. 10–18. Berlin : Springer.
- Zighed, D. A. et R. Rakotomalala (2000). *Graphes d'induction : apprentissage et data mining*. Paris : Hermes Science Publications.