



LABORATOIRE D'INFORMATIQUE DE PARIS 6

Apprentissage et Acquisition de Connaissances

**Apprentissage supervisé par
génération de règles : le système
SUCRAGE**

A. Borgi - Ben Bouzid

THÈSE de DOCTORAT de l'UNIVERSITÉ PARIS 6
LIP6 1999 / 008 janvier 1999

Table des matières

Introduction générale.....	9
I. Classification et Apprentissage automatique.....	15
I.1. Introduction.....	15
I.2. L'apprentissage automatique.....	16
I.2.1 L'apprentissage non supervisé.....	17
I.2.2 L'apprentissage supervisé.....	18
I.3. Classification en Reconnaissance des Formes.....	19
I.3.1 Introduction.....	19
I.3.2 L'espace de mesure.....	21
I.3.3 L'espace de représentation.....	21
I.3.4 L'espace de décision ou d'interprétation.....	22
I.4. Des méthodes de classification.....	24
I.4.1 De l'approche statistique	24
I.4.1.1 La régression.....	24
I.4.1.2 L'analyse discriminante.....	25
I.4.1.2.1 L'analyse discriminante à but descriptif.....	25
I.4.1.2.2 L'analyse discriminante à but décisionnel.....	28
I.4.1.3 La discrimination fonctionnelle.....	29
I.4.2.1 La théorie bayésienne de la décision	31
I.4.2.1.1 Méthodes non paramétriques.....	32
I.4.2.2 Classification par génération de règles.....	34
I.4.3.1 Les arbres de décision.....	35
I.4.3.2 Les méthodes polythétiques de génération de règles.....	38
I.4.3.3 Les Systèmes d'Inférence Floue ou SIF.....	42
I.5. Les grandes lignes de l'approche proposée	47
II. Apprentissage par génération automatique de règles à prémisses multi-valentes.....	51
II.1. Introduction	51
II.1.1 L'ensemble d'apprentissage.....	52
II.1.2 Morphologie des règles	53
II.2. Regroupement des attributs	54
II.2.1 Recherche de corrélations toutes classes confondues.....	54
II.2.1.1 Calcul de la matrice de corrélation linéaire R	54
II.2.1.2 Seuillage de R.....	55
II.2.1.3 Recherche de la partition orthogonale minimale.....	55

II.2.1.4 Un exemple.....	57
II.2.2 Recherche de corrélations intra-classes.....	58
II.2.2.1 Calcul des matrices de corrélation linéaire R^k	58
II.2.2.2 Seuillage des matrices R^k	59
II.2.2.3 Recherche des partitions orthogonales minimales	59
II.2.2.4 Un exemple de recherche de corrélations intra-classes.....	60
II.3. Génération des prémisses	61
II.3.1 Discrétisation de l'espace des attributs corrélés.....	61
II.3.1.1 Les méthodes de discrétisation non supervisée.....	62
II.3.1.1.1 La discrétisation régulière	62
II.3.1.2 Les méthodes de discrétisation supervisée.....	63
II.3.1.2.1 La méthode basée sur le MDLPC.....	64
II.3.1.2.2 FUSINTER.....	66
II.3.1.3 Discussion	67
II.3.2 Construction des prémisses	68
II.4. Conclusions des règles	71
II.4.1.1 Les conclusions	71
II.4.1.2 Représentation de l'incertitude.....	72
II.4.1.2.1 Le degré de croyance est une probabilité.....	73
II.4.1.2.2 Le degré de croyance est un coefficient de certitude.....	76
II.5. Complexité en nombre de règles générées.....	78
II.6. Discussion	83
II.6.1 Sélection des attributs.....	83
II.6.2 Prise en compte d'attributs symboliques.....	84
II.6.3 Les corrélations entre attributs	85
II.6.3.1 Le seuil de corrélation	85
II.6.3.2 Une autre méthode de recherche de corrélation linéaire	86
II.6.3.3 Autres formes de corrélations.....	87
II.6.4 La discrétisation.....	87
II.6.4.1 Détermination de la taille de la partition optimale.....	87
II.6.4.2 D'autres méthodes de discrétisation.....	89
II.6.5 Interprétation des règles et optimisation de leur nombre	90
II.6.6 Comparaison avec les SIF	94
II.7. Conclusion.....	95
III. Le système d'inférence.....	99
III.1. Le système d'inférence.....	100
III.1.1 Le raisonnement.....	100
III.1.2 Le traitement de l'incertitude.....	102
III.2. L'incertitude est représentée par des probabilités.....	104
III.3. L'incertitude est représentée par des CF.....	108
III.4. Cohérence et caractéristiques de la base de règles.....	111
III.5. Conclusion.....	111
IV. Le raisonnement approximatif.....	115
IV.1. Introduction.....	115

IV.2. Un raisonnement approximatif	117
IV.2.1 Adéquation entre observation et prémissse.....	120
IV.2.1.1 Une distance locale	121
IV.2.1.2 Une distance globale.....	125
IV.2.2 L'inférence approximative.....	131
IV.2.3 Récapitulatif.....	136
IV.3. Validation et apprentissage via le raisonnement approximatif.....	137
IV.3.1 Comparaison entre raisonnement exact et approximatif.....	138
IV.3.2 Apprentissage par le raisonnement approximatif	141
IV.3.3 Mise à jour de la base de règles	145
IV.4. Discussion.....	148
IV.4.1 Les distances	148
IV.4.2 Simplification de la base de règles	151
IV.5. Conclusion et Perspectives	153
V. Implémentation et résultats.....	159
V.1. Présentation.....	159
V.2. Implémentation : l'application SUCRAGE	160
V.2.1 Architecture.....	160
V.2.2 Les tests.....	161
V.2.3 La méthode de validation croisée.....	163
V.3. Les données IRIS	164
V.3.1 Inférence exacte	164
V.3.1.1 Recherche de corrélations toutes classes confondues	164
V.3.1.1.1 Probabilités	164
V.3.1.1.2 Coefficients de certitude	167
V.3.1.2 Recherche de corrélations intra-classes	168
V.3.1.2.1 Probabilités	168
V.3.1.2.2 Coefficients de certitude	169
V.3.2 Raisonnement approximatif	171
V.3.2.1 Recherche de corrélations toutes classes confondues	171
V.3.2.1.1 Probabilités	171
V.3.2.1.2 Coefficients de certitude	174
V.3.2.2 Recherche de corrélations intra-classes	176
V.3.2.2.1 Probabilités	176
V.3.2.2.2 Coefficients de certitude	178
V.3.3 Synthèse des résultats.....	179
V.3.4 Comparaison avec d'autres méthodes.....	181
V.4. Les images.....	182
V.4.1 Présentation générale	182
V.4.1.1 La segmentation	184
V.4.1.2 La classification	185
V.4.1.3 Notre approche appliquée aux images	186
V.4.2 Image de cryosection humaine.....	187
V.4.2.1 Inférence exacte	188
V.4.2.1.1 Recherche de corrélations toutes classes confondues	188
V.4.2.1.2 Recherche de corrélations intra-classes	191

V.4.2.2 Raisonnement approximatif	192
V.4.2.3 Synthèse des résultats.....	194
V.4.3 Image de papillon coloré.....	196
V.4.3.1 Inférence exacte	198
V.4.3.1.1 Recherche de corrélations toutes classes confondues	198
V.4.3.1.2 Recherche de corrélations intra-classes	200
V.4.3.2 Raisonnement approximatif	202
V.4.3.3 Synthèse des résultats.....	204
V.4.4 Image de texture.....	205
V.4.4.1 Inférence exacte	205
V.4.4.1.1 Recherche de corrélations toutes classes confondues	206
V.4.4.1.2 Recherche de corrélations intra-classes	207
V.4.4.2 Raisonnement approximatif	209
V.4.4.3 Synthèse des résultats.....	210
V.5. Discussion et conclusion.....	210
Conclusion et perspectives	217
Annexes	225
A. Les corrélations linéaires.....	227
B. Composantes connexes d'un graphe et partition orthogonale.....	229
C. Extraits du code de SUCRAGE.....	233
C.1 Exemples de structures de données.....	233
C.2 Des exemples de fonctions.....	233
D. Entrées/Sorties et traces d'exécution.....	237
D.1 Un exemple de fichier d'apprentissage.....	237
D.2 Extrait d'un fichier de résultats.....	237
D.3 Extrait d'un fichier de règles générées.....	238
E. Tests sur d'autres bases de données et comparaisons avec d'autres méthodes d'apprentissage.....	243
E.1. Les bases de test.....	243
E.2. Résultats des tests et comparaisons.....	244
F. Tests avec d'autres méthodes de discréttisation.....	247
F.1. Deux méthodes de discréttisation supervisée.....	247
F.2. Résultats expérimentaux.....	247
F.3. Conclusion	250
Bibliographie.....	251