

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université M'hamed BOUGARA de BOUMERDES



Faculté des Sciences
Département d'Informatique

MEMOIRE DE MAGISTER

Spécialité : Système informatique et génie des logiciels

Option : Spécification de Logiciel et Traitement de l'Information
Ecole Doctorale

Présenté par :
Alouane Basma

Thème
Recherche de partitions floues optimales par segmentation floue pour
la fouille de données quantitatives.

Devant le jury de soutenance composé de:

| | | | |
|--------------------------|----------------------|-------|--------------|
| Mr. MEZGHICHE Mohamed | Professeur | UMBB | Président. |
| Mr. DJOUADI Yassine | Maître de conférence | UMMTO | Rapporteur. |
| Mr. AHMED NACER Mohamed | Professeur | USTHB | Examinateur. |
| Mr. BABA-ALI Ahmed Riadh | Maître de conférence | USTHB | Examinateur. |

Année Universitaire : 2007/2008

Table de matière

| | |
|---|----|
| Chapitre I : Introduction | I. |
| Introduction..... | 1 |
| | |
| Chapitre II : Extraction de connaissance et fouille de données | |
| | |
| II.1 Extraction de connaissances à partir des données..... | 4 |
| II.1.1 Définition générale..... | 5 |
| II.1.2 Les étapes d'un processus d'Extraction de Connaissances à partir des données | 6 |
| II.2 Fouille de données (Data Mining)..... | 11 |
| II.2.1 Historique | 11 |
| II.2.2 Définition de la fouille de données | 12 |
| II.2.3 Les méthodes de fouille de données..... | 14 |
| II.3 Les règles d'association | 17 |
| II.3.1 Cadre informel..... | 17 |
| II.3.2 Cadre formel..... | 18 |
| II.3.3 La découverte des règles d'association | 21 |
| II.3.3.1 Extraction des itemsets fréquents | 21 |
| II.3.3.2 Génération des règles d'association | 27 |
| II.3.4 Les amélioration de l'algorithme Apriori..... | 32 |
| II.3.5 Réduction de l'ensemble de règles d'association..... | 33 |
| II.3.5.1 Approche orientée données | 33 |
| II.3.5.2 Approche orientée utilisateur | 39 |
| II.3.6 Domaine d'applications..... | 40 |
| II.3.7 Types des données considérées | 41 |
| II.4 Règles d'association quantitatives | 41 |
| II.4.1 Problème des règles d'association quantitatives | 44 |
| II.4.2 Constat..... | 45 |
| II.5 Conclusion..... | 46 |
| III.1 La théorie des sous ensembles flous | 47 |
| III.1.1 Ensemble classique et Ensemble flou | 47 |
| Ensemble classique | 47 |
| III.1.1.2 Ensemble flou..... | 48 |
| III.1.2 Fonction d'appartenance | 50 |
| Le type | 51 |
| Le noyau | 51 |
| La hauteur..... | 51 |
| Les coupes de niveau α | 52 |
| Le support..... | 52 |
| III.1.3 La cardinalité | 53 |
| III.1.3.1 La cardinalité scalaire \sum -count | 53 |
| III.1.3.2 La cardinalité floue de Zadeh..... | 53 |
| III.1.3.3 Cardinalité relative d'un ensemble flou | 53 |
| III.1.4 Opérations sur les sous-ensembles flous | 54 |
| III.1.4.1 L'égalité | 54 |
| III.1.4.2 L'inclusion | 54 |
| III.1.4.3 L'union | 54 |
| III.1.4.4 L'intersection | 55 |
| III.1.4.5 Le complément | 56 |

| | |
|---|-----|
| III.1.4.6 Le produit cartésien..... | 56 |
| III.1.4.7 Normes et conormes triangulaires..... | 57 |
| III.1.5 Raisonnement à partir des ensembles flous..... | 58 |
| III.1.5.1 Variable linguistique | 58 |
| III.1.5.2 Proposition floues..... | 60 |
| III.1.6 Règles floues | 61 |
| III.2 Règles d'association floues | 63 |
| III.2.1 Approche ensembliste | 63 |
| III.2.1.1 Principe générale | 63 |
| III.2.1.2 Evaluation algébrique du support et de la confiance..... | 64 |
| III.2.1.3 Approche sémantique | 70 |
| III.2.2 Approche logique (Dubois et Prade)..... | 76 |
| III.3 Constat..... | 78 |
| III.4 Conclusion..... | 79 |
| IV.1 Principe fondamental de la segmentation | 80 |
| IV.1.1 Différents domaines d'application de segmentation | 82 |
| IV.1.2 Processus de segmentation | 82 |
| IV.2 Méthodes de segmentation..... | 83 |
| IV.2.1 La segmentation hiérarchique | 85 |
| IV.2.1.1 Méthodes ascendantes ou agglomératives..... | 85 |
| IV.2.1.2 Méthodes descendantes | 87 |
| IV.2.2 La segmentation par partition..... | 87 |
| IV.2.2.1 Méthode basé sur la densité | 88 |
| IV.2.2.2 Méthode basée sur les grilles | 89 |
| IV.2.2.3 Méthodes basés sur la théorie des graphes..... | 90 |
| IV.2.2.4 Méthodes basés sur la minimisation d'une fonction objective | 91 |
| IV.3 Segmentation floue..... | 93 |
| IV.3.1 Algorithme de C-moyennes floues (CMF)..... | 93 |
| IV.3.2 Avantages et inconvénients de l'algorithme (CMF) | 98 |
| IV.3.3 Les algorithmes dérivés de l'algorithme CMF | 99 |
| IV.3.3.1 Algorithme de Gustafson et kessel..... | 99 |
| IV.3.3.2 Algorithme de Gath et Geva (FMLE) | 100 |
| IV.4 Le nombre de groupes et les indices de validités | 101 |
| IV.4.1 Le nombre de groupes | 101 |
| IV.4.2 Les indices de validités dédiés à la segmentation floue | 103 |
| IV.5 Conclusion..... | 107 |
| V.1 Principe général..... | 108 |
| V.1.1 Adaptation de l'Algorithme CMF | 110 |
| V.1.2 Justification du choix de l'algorithme CMF | 114 |
| V.2 Détermination du nombre optimal de groupes..... | 116 |
| V.2.1 Proposition basée sur le support..... | 116 |
| V.2.2 Proposition utilisant l'indice de validité V_{PC} | 118 |
| V.2.3 Proposition utilisant l'indice de validité V_{FS} | 118 |
| V.3 Proposition pour la découverte des règles d'association floues..... | 120 |
| V.3.1 Sémantique des règles d'association floues | 120 |
| V.3.2 Proposition d'une mesure de cardinalité floue | 121 |
| V.3.3 Proposition d'une t-norme..... | 121 |
| V.3.4 Présentation détaillée de l'algorithme de découverte des règles d'association floues 121 | |
| V.3.5 Evaluation des règles d'association floues | 125 |

| | |
|--|-----|
| V.4 Comparaison des ensembles flous | 126 |
| V.4.1 Mesure de ressemblance..... | 127 |
| V.4.2 L'agrégation des mesures de ressemblances..... | 128 |
| Si on veut donnée une valeur général de degré de ressemblance S définit sur Ω , qui satisfait les propriétés des mesure de ressemblance, [111] [112] [114] propose d'utiliser une t-norme comme opérateur d'agrégation..... | 128 |
| V.5 Conclusion..... | 128 |
| VI.1 Présentation des bases de données | 130 |
| VI.1.1 La base de données KDD'99 | 130 |
| Attributs d'une connexion dans la base de données KDD'99..... | 130 |
| Attributs retenus pour le cas de notre étude | 132 |
| VI.1.2 La base de données adult ¹ | 133 |
| VI.2 Résultats obtenus..... | 135 |
| VI.2.1 Le nombre de partitions trouvées par chaque méthode | 141 |
| ➤ Base KDD'99 | 141 |
| VI.2.2 Génération des règles d'association floues | 142 |
| VI.2.2.1 Règles d'association générées à partir de KDD'99..... | 143 |
| VI.2.2.2 Règles d'association floues générées à partir de Adult..... | 146 |
| VI.3 Comparaison des règles d'association floues..... | 148 |
| VI.3.1 Construction du modèle de validation..... | 148 |
| VI.3.2 Principe de comparaison par rapport au modèle de validation | 150 |
| VI.3.3 Evaluation des règle générées à partir de la base KDD'99 | 151 |
| VI.3.4 Evaluation des règles générée à partir de la base adult | 156 |
| VI.3.5 Interprétation des résultats | 161 |
| VI.4 Le temps d'exécution | 162 |
| VI.5 Conclusion..... | 163 |

Abstract

The original problem of research of association rules was to extract some correlations from binary data.

Noting that the data are often quantitative, the problem has been extended for quantitative attributes by partitioning attribute domain and consequently mapping the quantitative problem to a binary one. However, such mapping generates sharp boundary problem.

In order to avoid such problem, fuzzy sets have been considered. All existing approaches, assume that fuzzy sets are empirically given. For this purpose, an original approach is proposed in this work in order to generate automatically fuzzy partitions. Our approach is based on fuzzy clustering method. We also suggest how to find automatically the optimal number of the fuzzy sets by using validity indices.

Key words: Data mining, association rules, fuzzy sets, fuzzy association rules, fuzzy clustering, validity indices, fuzzy resemblance measure.

Résumé

Le problème original de recherche de règles d'association consistait à extraire certaines corrélations à partir de données binaires.

Constatant que souvent les données sont quantitatives, le problème a été étendu. L'idée consiste à ramener le problème à un cas binaire. Cependant une telle transformation cause le problème de valeurs aux limites.

Afin de pallier à ce problème, les ensembles flous ont été proposés. Toutes les approches existantes dans la littérature considèrent que les ensembles flous sont donnés d'une manière empirique. A cette fin, nous proposons dans notre mémoire une approche originale qui permet de générer automatiquement les partitions floues. Nous proposons aussi deux méthodes pour trouver le nombre de partitions floues.

Mots clés : Fouille de données, Règles d'association, ensembles flous, Règles d'association floues, Segmentation floue, Indice de validité, Mesure de ressemblance floue.