

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Ecole nationale Supérieure d'Informatique (ESI)

MEMOIRE

Présenté pour l'obtention du diplôme de Magister
En : Informatique
Spécialité : Informatique mobile

Par : BAGHLI Raouida

Metaheuristiques pour la Classification non Supervisée

Mémoire soutenu devant le jury :

M. ADMANE Lotfi : Maitre de Conférences à l'ESI (Président du jury)
M. BADACHE : Professeur Cerist
Mme SI TAYEB Fatima : Maitre de Conférences à l'ESI
Mme BENATCHBA Karima : Professeur à l'ESI (Directrice du mémoire)

Abstract

The world today requires the handling of a large mass of information. This significant amount of information should not be lost and should be properly analyzed and exploited to satisfy the needs of competitiveness and performance increasingly growing in the field of business. This is where was born the need to resort to data mining, a semi-automatic process of data analysis. We can distinguish two main tasks of this process, predictive tasks and descriptive ones. The first attempts to predict future values as to the second aims to describe and exploit the current values. Unsupervised classification or clustering is a descriptive task considered as the most important one. It consists on a process that gathers objects in homogeneous classes where the most similar objects are in the same classes and the most distant ones are in different classes. This problem is NP-hard and the use of conventional methods to solve it is time consuming. Different metaheuristics have been used to overcome this problem. Among these metaheuristics, we are particularly interested in biomimetic and evolutionary methods. This work has two goals: First a state of the art on the application of these metaheuristics on clustering. Second, a comparative study on the behavior of three methods, namely evolutionary algorithms, artificial immune systems and bees' method, on different types of benchmarks.

Key words: Data-mining, Clustering, Metaheuristics, Biomimetic methods, Evolutionary methods, Artificial immune systems, Bees methods.

Résumé

Le monde d'aujourd'hui nécessite la manipulation d'une grande masse d'information. Cette quantité importante d'information ne doit pas être perdue et doit être correctement analysée et exploitée afin de satisfaire les besoins de compétitivité et de performance de plus en plus croissant dans le domaine de l'entreprise. Et c'est de là qu'est née la nécessité de recourir au Data mining, un processus semi-automatique d'analyse de données. Nous pouvons distinguer deux tâches principales de ce processus, les tâches prédictives et les tâches descriptives. Les premières visent à prédire des valeurs futurs quant aux secondes, elles ont pour objectif de décrire et d'exploiter au mieux les valeurs actuelles. La classification non supervisée ou clustering fait partie de ces dernières, c'est-à-dire les tâches descriptives, et peut être considérée comme l'une des plus importantes. C'est un processus de regroupement d'objets en classes homogènes où les données les plus similaires possibles sont dans la même classe et les données les plus éloignées possibles appartiennent à des classes différentes. Ce problème étant NP-difficile, l'utilisation de méthodes classiques pour le résoudre devient impossible. Différentes métaheuristiques sont alors apparues pour pallier au problème de clustering. Parmi ces métaheuristiques, nous nous sommes particulièrement intéressés aux méthodes biomimétiques et évolutionnaires. Notre travail consiste, dans une première étape, à faire un état de l'art sur leur application au clustering. Dans une seconde étape, il consiste à étudier et comparer le comportement de trois méthodes, à savoir les algorithmes évolutionnaires, les systèmes immunitaires artificiels et la méthode des abeilles, sur différents types de benchmarks et montrer l'influence du codage sur leur performance.

Mots- clés : Data-mining, Clustering, Métaheuristiques, Méthodes biomimétiques, Algorithmes évolutionnaires, Systèmes immunitaires artificiels, et la Méthode des abeilles.

Table des matières

<i>Abstract</i>	I
<i>Résumé</i>	II
<i>Liste des figures</i>	VI
<i>Liste des algorithmes</i>	VII
INTRODUCTION GENERALE	1
Chapitre 1 : DATA MINING ET KDD	4
1.1. Introduction	5
1.2. Définition du data mining	5
1.3. KDD (Knowledge Discovery in Databases)	7
1.3.1. Modèles académiques	7
1.3.2. Modèles industriels	9
1.3.3. Modèles hybrides	10
1.3.4. Comparaison entre les différentes catégories de modèle	10
1.4. Tâches du Data mining	12
1.4.1. Tâches descriptives	12
1.4.2. Tâches prédictives	13
1.5. Méthodes du data mining	13
1.6. Domaines d'application du data mining	14
1.7. Conclusion	14
Chapitre 2 : CLUSTERING	15
2.1. Introduction	16
2.2. Notions de base	16
2.2.1. Distance	16
2.2.2. Distance sur R^m	17
2.3. Classification hiérarchique	17
2.3.1. BIRCH	19
2.3.2. CURE	19
2.4. Classification par partitionnement	20
2.4.1. K-Means	20
2.4.2. K-MEDOÏDS	21
2.5. Classification basée sur la densité	23
2.5.1. DBSCAN	25
2.5.2. DENCLUE	26
2.6. Classification basée sur les grilles	27

2.6.1. STING	28
2.6.2. CLIQUE	28
2.7. Conclusion.....	28
Chapitre 3 : METHODES BIOMIMETIQUES POUR LE CLUSTERING	30
3.1. Introduction	31
3.2. Recuit Simulé	31
3.3. Recherche Tabou	33
3.4. Fourmis artificielles.....	35
3.4.1. ANTCLASS.....	35
3.4.2. ANTCLUST	39
3.4.3. AntTree	43
3.5. Classification par optimisation basée sur la biogéographie	47
3.5.1. Principe de la BBO	47
3.5.2. ALGORITHME DE LA BBO	48
3.6. Algorithmes d'abeilles basés sur la recherche de nourriture.....	49
3.6.1. ALGORITHME DE COLONIE ARTIFICIELLE D'ABEILLES (ABC)	49
3.6.2. ALGORITHME DES ABEILLES (BA)	50
3.7. Conclusion.....	51
Chapitre 4 : METHODES EVOLUTIVES POUR LE CLUSTERING	52
4.1. Introduction	53
4.2. Algorithmes évolutionnaires	53
4.2.1. SCHEMA TYPE D'UN ALGORITHME EVOLUTIONNAIRE	53
4.2.2. PRESSION DE SELECTION ET DERIVE GENETIQUE	54
4.2.3. POLITIQUES DE SELECTION POUR LE CROISEMENT.....	54
4.2.4. METHODE DE CROISEMENT	57
4.2.5. MUTATION	58
4.2.6. SELECTION POUR LE REMPLACEMENT.....	59
4.2.7. ALGORITHMES GENETIQUES.....	60
4.2.8. CONVERGENCE DES ALGORITHMES EVOLUTIONNAIRES	60
4.2.9. ALGORITHMES EVOLUTIONNAIRES POUR LA CLASSIFICATION NON SUPERVISEE	60
4.3. Les systèmes immunitaires artificiels	64
4.3.1. SYSTEME IMMUNITAIRES HUMAIN.....	64
4.3.2. INTERET POUR LES SYSTEMES IMMUNITAIRES	64
4.3.3. SYSTEMES IMMUNITAIRES ARTIFICIELS POUR L'OPTIMISATION	65
4.3.4. RESEAUX IMMUNITAIRES ET INTERACTION ENTRE LYMPHOCYTES.....	67
4.3.5. SYSTEMES IMMUNITAIRES ARTIFICIELS POUR LE CLUSTERING	68

4.3.6. CODAGE PAR ANTICORPS.....	70
4.4. Conclusion.....	71
Chapitre 5 : TESTS ET RESULTATS.....	72
5.1. Introduction	73
5.2. Présentation des benchmarks	73
5.2.1. FONCTION DE FIABILITE	73
5.2.2. BENCHMARKS UTILISES.....	74
5.3. Algorithmes Evolutionnaires	75
5.3.1. CODAGE PAR CENTRE	76
5.3.2. CODAGE PAR PARTITIONNEMENT	77
5.3.3. COMPARAISON ENTRE LES CODAGES.....	77
5.4. Colonies d'abeilles (ABC)	79
5.5. Algorithme évolutionnaire VS ABC.....	80
5.5.1. CODAGE PAR CENTRE	80
5.5.2. CODAGE PAR PARTITIONNEMENT	81
5.6. Système immunitaire artificiel.....	82
5.7. Conclusion.....	84
Conclusion générale	85
Bibliographie	87