

Table des matières

Remerciements	i
Résumé	ii
Abstract	iii
Table des matières	v
Table des figures	vi
Liste des tableaux	
Introduction générale	1
1 Aide au diagnostic médicale	3
1 Introduction	3
2 La maladie de Diabète	3
2.1 Définition	3
2.2 Facteurs de risque du diabète	4
2.3 Le diabète dans le Monde :	5
2.4 Tests pour le diagnostic :	6
2.5 Classification du diabète :	6
3 Conclusion :	7
2 La Logique Floue et Les méthodes d'optimisation évolutionnaires	8
1 La logique Floue	8
1.1 Introduction	8
1.2 Ensembles nets et ensembles flous	8
1.3 Les types des fonctions d'appartenance	9
1.4 Variable linguistique :	9
1.5 Opérations sur les ensembles flous :	10
1.6 Notion de règle linguistique :	10
1.7 Structure d'un système flou	11
1.8 Les types des SIF :	12
1.9 Conclusion	13
2 Méthodes d'optimisation évolutionnaires	13
2.1 Introduction	13
2.2 Aspect d'Optimisation :	13
2.3 Algorithmes d'optimisation :	14
2.4 algorithmes de la colonie d'abeille :	19
3 Conclusion	27

3	Expérimentations, Résultats et Interprétations	28
1	Introduction	28
2	Description de la base de données utilisée	29
	2.1 L'intérêt de la base de données :	29
	2.2 Base de données utilisées	29
3	Le raisonnement flou	30
4	Apprentissage classificateur flou basé sur l'algorithme de la colo- nie d'abeille :	31
	4.1 Représentation de la solution :	31
	4.2 Fonction objective (fitness)	32
	4.3 les différents paramètres	33
5	Phase de test et évaluation	33
6	les Résultats de l'approche flou-ABC :	34
	6.1 Résultats obtenus	34
7	Comparaison des résultats avec l'état de l'art	39
8	Conclusion	39
	Conclusion générale et perspectives	40
	Bibliographie	42

Table des figures

2.1	Présentation d'un ensemble classique et d'un ensemble flou.	9
2.2	Exemples des fonctions d'appartenance	9
2.3	Exemples des sous ensembles floue	10
2.4	Schéma général d'un SIF	11
2.5	Nombre de documents écrits sur le sujet, à partir de web of science	19
2.6	Danse frétilante des abeilles	20
2.7	Direction du fourage chez les abeilles	21
2.8	Distance de la nourriture par apport au nombre de tour de danse .	21
2.9	Comportement des abeilles mellifères butinent le nectar	23
3.1	Schéma de fonctions d'appartenance pour chaque variable d'entrée	31
3.2	Présentations de paramètres de solutions (Le codage de la solution)	32
3.3	Histogramme des taux obtenus - Expérimentation 1-	35
3.4	Histogramme des taux obtenus Expérimentation 2	37

Liste des tableaux

2.1	Algorithmes inspiré du comportement des abeilles	25
3.1	Tables de multiplication	30
3.2	Spécification des Paramètres utilisé dans l'application	33
3.3	Résultats d' Apprentissage - Expérimentation 1-	35
3.4	Résultats du meilleur Taux de classification du Test - Expérimentation 1-	35
3.5	Résultats d' Apprentissage Expérimentation 2	36
3.6	Résultat meilleur Taux de classification Test - Expérimentation 2 - .	36
3.7	Résulta du 10-cross-validations	38
3.8	Taux de classification obtenus avec notre modèle et autres classifieurs de la littérature	39

Introduction générale

Dans les dernières années, plusieurs processus biologiques et naturels ont influencé beaucoup de chercheurs à établir des nouvelles méthodes d'optimisation d'une manière croissante. L'intelligence inspirée de la Nature devient de plus en plus populaire et un nombre important de méthodes entraînées par des concepts issus de la nature / la biologie ont été développés. Quand la tâche est d'optimisation au sein de domaines complexes de données ou d'information, les méthodes qui représentent succinctement des animaux et comportement de l'équipe micro-organisme sont les approches les plus populaires inspirées de la nature. Les approches inspirées de la nature telles que l'optimisation par essaim de particules PSO (inspiré par les troupes d'oiseaux ou de poissons écoles), les systèmes artificiels immunitaires (qui imitent le biologique), ou les colonies de fourmis (les comportements butineur des fourmis ont donné lieu à l'optimisation par colonies de fourmis) . Récemment, un certain nombre d'algorithmes d'intelligence d'essaim, basée sur le comportement des abeilles ont été présentés . Ces algorithmes sont divisés, principalement en deux catégories en fonction de leur comportement dans la nature, le comportement de butinage et le comportement d'accouplement. L'algorithme de colonie d'abeille artificielle est, principalement, appliquée à des problèmes d'optimisation continue et simule la frétillante et le comportement de danse qui un essaim d'abeilles effectué au cours du processus de recherche de nourriture. Dans cet algorithme, il ya trois groupes d'abeilles, les abeilles employées (Abeilles qui déterminent la source de nourriture (solutions possibles) à partir d'un ensemble prédéfini des sources de nourriture et de partager cette information (danse frétillante) avec les autres abeilles dans la ruche), les abeilles spectateurs (les abeilles qui en fonction des informations qu'ils prennent des abeilles employées ils recherchent une meilleure source de nourriture dans le voisinages des sources de nourriture mémorisées) et les abeilles éclaireuses (abeilles employés que leur source de nourriture a été abandonné et ils recherchent une nouvelle source de nourriture au hasard).

Ce mémoire de master propose une nouvelle technique de reconnaissance automatique du diabète. Cette technique est une méthode hybride qui combine les systèmes d'inférences à base de règles flous et l'optimisation par l'algorithme de colonie d'abeille artificielle. Cette méthode possède donc la capacité de modélisation et d'adaptation universelle des algorithmes évolutionnaires et la facilité d'interprétation et d'intégration des connaissances des systèmes d'inférence floue.

Le manuscrit de ce mémoire de master est divisé en trois chapitres :

Le premier chapitre présente sommairement la maladie du diabète et des sta-

tistiques réelles sur le danger que représente, et notamment ses facteurs de risque, ses causes et son origine. Il permet en particulier de comprendre l'origine et la nature de l'hypoglycémie et l'hyperglycémie ainsi que le diagnostic et la classification du diabète.

Le deuxième chapitre présente résumé l'essentiel des principes des deux techniques utilisées pour la résolution des problèmes de la reconnaissance automatique et de classification, que sont les systèmes a base de règles floue et la programmation évolutionnaire et plus particulièrement l'algorithme de colonie d'abeille. L'étude faite dans ce chapitre sert à mieux connaître ces deux paradigmes de l'intelligence artificielle pour pouvoir les hybrider dans un même système « modèle hybride flou abeille » qui exploite les avantages des deux techniques.

Enfin, le troisième et dernier chapitre présente le modèle hybride flou-Colonie d'abeille que nous avons implémenté pour la reconnaissance automatique du diabète ainsi que la comparaison de nos résultats avec d'autres techniques citées dans la littérature.

Chapitre 1

Aide au diagnostic médicale

1 Introduction

Les systèmes de classification ont été largement utilisés dans le domaine médical pour explorer les données du patient et développer des modèles fiables et prédictifs. Ces modèles permettent d'aider les médecins à faire leurs diagnostic afin d'avoir des bonnes procédures de planification, de pronostic ou de traitement. En outre, ces systèmes d'aide au diagnostic permettent aussi de prendre des décisions rapides par les médecins, sachant que dans certains cas, le moindre retard peut provoquer des conséquences graves pour le malade si on tarde à lui établir un diagnostic précis et correct. Ceci est notamment le cas pour la maladie du diabète. Aussi il faut établir des décisions significatives et précises. La détection précoce des problèmes médicaux tels que le diabète est très importante pour augmenter les chances de succès du traitement. Cette détection est souvent formulée comme un problème de classification binaire. Les systèmes de classification fournissent une aide primordiale et qui peut être décisive dans certains cas, car elles réduisent les erreurs et le temps nécessaire pour le diagnostic. Mais reste toujours la décision finale par l'expert est l'élément le plus important lors du diagnostic. Dans ce premier chapitre, nous présentons la maladie du diabète, ses facteurs de risques ainsi que les différents types et classes qui existent et qui ont été établi par des organisations mondiales. Ceci est afin de mieux connaître les propriétés de cette maladie très répandu dans le monde, cette maladie sera la base d'évaluation de notre algorithme hybride basé sur la colonie des abeilles et la logique floue.

2 La maladie de Diabète

2.1 Définition

Le diabète est une maladie métabolique caractérisée par une hypertension les niveaux de glucose, qui résultent que le corps ne produit pas assez d'insuline ou le corps est résistant aux effets de l'insuline. Le corps a besoin d'insuline pour transformer le sucre, les graisses et les protéines de l'alimentation en énergie [HYT09].

Le diabète est associé à de nombreuses complications et il peut augmenter le risque de cécité, l'hypertension artérielle, de maladie cardiaque, maladie rénale, lésions nerveuses selon ADA [HYT09]

2.2 Facteurs de risque du diabète

Diabète qui est classé comme quatrième cause de décès dans le monde, est qui est malheureusement en augmentation constante. Plusieurs facteurs favorisent l'apparition du diabète citant :

L'âge :

Plusieurs facteurs expliquent une diminution de la tolérance glucosée : modifications des apports alimentaires, diminution de la proportion de la masse maigre corporelle, modifications quantitatives et qualitatives de la sécrétion d'insuline, des mécanismes d'insulino-résistance, réduction de l'activité physique, Tous ces facteurs surviennent avec l'avancée en âge des individus. Ainsi le diabète pourrait être une maladie du sujet âgé. Il est par ailleurs admis que l'hyperglycémie et l'hyperinsulinisme jouent un rôle dans la survenue des complications du diabète, notamment vasculaires . A ce titre le diabète est souvent considéré comme un modèle de vieillissement accéléré. Il en résulte que toute manifestation vasculaire pourrait apparaître comme étant la conséquence de l'âge que celle du diabète [cgw97]

Quelque soit la population étudiée, la prévalence du diabète augmente avec l'âge. L'étude menée entre 1998 et 2000 par la CNAMTS [Lan04] analyse le taux de prévalence par classe d'âge, du diabète traité par médicaments dans la population protégée du Régime général et constate que la prévalence du diabète croît de manière régulière entre 0 à 79 ans, mais que c'est vraiment à partir de 40 ans que sa fréquence dépasse les 1 . (0,68 . dans la classe d'âge 35-39 ans et 1,27 . dans la classe d'âge 40-44 ans puis jusqu'à 13,96 . dans la classe d'âge 75-79 ans).. [Dia02]

Le facteur de risque génétique :

Certaines personnes ont une prédisposition génétique face au diabète- La présence d'un diabétique dans Les antécédents familiaux augmente le risque de survenue du diabète chez leurs enfants dans une même famille-Ce facteur est très marqué pour le diabète de type 2, qui est une maladie familiale donc à forte composante génétique. Pour les diabétiques de type 1, il existe aussi des facteurs génétiques, mais la "pénétrance" de la maladie est beaucoup plus faible. Cela signifie que si vous avez un diabète de type 1, le risque pour vos enfants de développer un diabète de type 1 est de l'ordre de 3% Cela reste une prédisposition faible en comparaison de celle du type 2 : si vous avez un parent diabétique de type 2, le risque pour vous de développer un diabète est de l'ordre de 40%. L'expression génétique est beaucoup plus puissante.

L'obésité :

Il y a 400 millions d'adultes obèses sur Terre, et ils seront plus de 700 millions en 2025. L'obésité pourrait devenir la première cause de mortalité aux USA dans un futur proche. Les trois-quarts des diabétiques de type 2 souffrent d'obésité, Le diabète et l'obésité sont deux grandes épidémies en marche à travers le monde. Le constat est simple Obésité et diabète : des maladies fortement liées. Si les épidémies de diabète et d'obésité semblent suivre la même progression, ce n'est pas un hasard : ces deux maladies sont intimement liées, à tel point que l'on parle souvent d'une épidémie de "diabésité". Alors comment expliquer ces liens entre les deux maladies : Le constat est simple : 90% des diabètes de type 2 apparaissent après une prise de poids. Mais le surpoids seul ne suffit pas à provoquer la maladie du diabète .

Il faut donc un terrain génétique préalable, qui va entraîner un diabète en cas de déséquilibre alimentaire et de gain de poids important. Dans ce cas, c'est le mécanisme à l'origine du diabète qui est directement lié aux kilos : l'insulinorésistance. Car avant que le vrai diabète apparaisse, la maladie se développe de manière insidieuse, avec une résistance progressive à l'action de l'insuline .

Le constat est donc simple : deux des quatre causes importante de la résistance à l'insuline sont communes à l'obésité : l'alimentation et la sédentarité.

La tension artérielle :

L'hypertension artérielle constitue l'un des problèmes majeurs de santé publique dans les pays développés et émergents. Il s'agit de la plus fréquente des affections cardio-vasculaires : on estime sa prévalence à environ 20% de la population adulte. Chez les personnes de 20 ans, le pourcentage d'hypertendus est très faible, il augmente ensuite régulièrement pour atteindre 40% à 65 ans et 90% à 85 ans mais le risque est multiplié par 2 ou 3 en cas de diabète. Association hypertension artérielle-diabète cause plusieurs risque principalement la morbidité et de la mortalité, la nécessité des médicaments antihypertenseurs est primordiaux. Il existe d'autre cause du diabète citant : l'augmentation de la fécondité des femmes diabétique, le stress chronique, le tabagisme qui peut causer l'apparition de l'insulino-resistance [Mer04].

2.3 Le diabète dans le Monde :

– L'OMS a annoncé que le nombre de diabétiques dans le monde en 2000 à plus de 177 millions de cas [Dia02] Chaque année, 7 millions de personnes développent un diabète, soit deux par seconde on comptera ainsi 380 millions en 2025. Si le nombre de cas augmente en Europe et en Amérique, on constate une véritable explosion en Chine et en Inde. Il serait ainsi responsable de 3 millions de morts et d'un million d'amputations.

2.4 Tests pour le diagnostic :

Les tests suivants sont utilisés pour le diagnostic :

*Glycémie plasmatique occasionnelle (GPO) : appelé également Test aléatoire de glucose plasmatique effectuée des mesures de la glycémie prélevée après que le patient a mangé normalement avant les analyses. Elle doit être ≥ 200 mg/dl et accompagner ainsi de symptômes classiques du diabète.

* Glycémie plasmatique à jeun (GPJ) : mesure la glycémie chez le patient qui n'a rien consommé durant les huit heures avant les analyses. Elle doit être ≥ 126 mg/dl.

*Hyperglycémie provoquée par voie orale (HGPO) : appelé également Test oral de tolérance au glucose la glycémie est mesurée après le jeûne d'au moins 8 heures et ensuite Après deux heures après avoir ingéré 75g de glucose par voie orale. Elle doit être ≥ 200 mg/dl

2.5 Classification du diabète :

L'Association Américaine de Diabète (ADA) par comité de organisation mondiale de la santé l'OMS ont établi classification Les critères pour le diagnostic :

Diabète de type 1 :

Le diabète de type 1 (DM1), auparavant appelé diabète sucré insulino-dépendant, apparaît généralement pendant l'enfance ou l'adolescence, et la survie du patient est liée à de nombreuses injections quotidiennes d'insuline. La forme la plus courante du diabète de type 1 résulte d'un processus auto-immun de destruction à 90% de quantité normale des cellules β des îlots de Langerhans, qui entraîne une incapacité du pancréas à sécréter l'insuline, la sécrétion d'insuline est déficiente mais pas inexistante. Il est rapidement mortel sans l'administration quotidienne d'insuline, Le diabète de type 1 représente entre 5% et 10% de tous les cas diagnostiqués de diabète.

Diabète de type 2 :

Le diabète de type 2 (DM2), auparavant appelé non insulino-dépendant débute généralement après l'âge de 40 ans. Le diabète de type 2 peut représenter entre 90% et 95% de tous les cas diagnostiqués de diabète. Diabète de type 2 est une maladie qui est caractérisé par premièrement une résistance à l'action de l'insuline, souvent exacerbée par l'obésité, est suivie par une incapacité du pancréas à augmenter suffisamment la sécrétion d'insuline pour compenser adéquatement cette résistance. L'espérance de vie est réduite de 5 à 10 ans chez les personnes d'âge moyen atteintes du diabète de type 2. L'espérance de vie varie selon l'âge au début de la maladie, et plus le sujet est jeune au moment du diagnostic, plus son espérance de vie se trouve réduite.

Malgré les progrès médicaux récents, le diagnostic précoce de la maladie s'est

améliorée, mais environ la moitié des patients du diabète de type 2 ne sont pas conscients de leur maladie et peut prendre plus de dix ans comme retard d'apparition de la maladie au diagnostic tout début diagnostic et le traitement de cette maladie est indispensable [PGA07] Le diagnostic de diabète de type 2 n'est pas un travail facile, parce que patients diabétiques présentent des nombreux symptômes que certains de ces symptômes sont apparaissent dans les autres maladies, c'est à dire beaucoup de maladies ont des mêmes symptômes . Donc, en plus de l'évaluation du test résultats, les médecins doivent prêter une attention à des décisions antérieures, qui faite pour les patients dans les mêmes conditions [TYT07] [MFMS11].

Diabète sucré gestationnel :

Le diabète sucré gestationnel (DSG) est une intolérance au glucose découverte pour la première fois au cours d'une grossesse. Cette forme de diabète est généralement transitoire et disparaît dans les six semaines suivant l'accouchement. Les femmes qui ont souffert du diabète gestationnel risquent davantage de développer un diabète de type 2 par la suite. Certaines données indiquent qu'environ le tiers des femmes ayant des antécédents de diabète gestationnel seront plus tard atteintes du diabète de type 2.

3 Conclusion :

L'étude approfondie menée dans ce premier chapitre a permis de bien comprendre l'origine et les caractéristiques principales liées au diabète, et aussi de donner des renseignements importants sur la classification des différents types de cette maladie dangereuse. Cette étude sera très utile et bénéfique pour la suite de ce travail pour mieux choisir une bonne caractérisation du vecteur d'entrée de notre classifieur flou-colonie d'abeille Implémenté dans ce projet de fin d'études. En effet, le deuxième chapitre sera consacré à la présentation détaillé de la théorie de base de l'optimisation par l'algorithme de colonie d'abeille, ainsi que les notions de base de la logique floue.

Chapitre 2

La Logique Floue et Les méthodes d'optimisation évolutionnaires

1 La logique Floue

1.1 Introduction

La logique floue a été introduite par le professeur Lotfi Zadeh [Zad65] comme une généralisation de la logique binaire [Kos92], [L.X94]. L'intérêt de la logique floue réside dans sa capacité à traiter l'imprécis, l'incertain et le vague. Elle est issue de la capacité de l'homme à décider et agir de façon pertinente malgré le flou des connaissances disponibles. En effet, la logique floue a été introduite pour approcher le raisonnement humain à l'aide d'une représentation adéquate des connaissances. Ces dernières années, la logique floue a été appliquée dans divers domaines. Cependant, la commande floue est le domaine qui suscite le plus de curiosité et s'avère être un champ d'application actif à travers le monde [L.X94], [JC95], [KS98], [Men95], les systèmes à base de connaissances, le regroupement et la classification floue et aussi utilisée dans des domaines aussi variés que l'automatisme, la robotique (reconnaissance de formes), la gestion de la circulation routière, le contrôle aérien, la médecine (aide au diagnostic). Cette partie présente quelques notions théoriques de la logique floue.

1.2 Ensembles nets et ensembles flous

la théorie mathématique des sous ensembles flous, est une extension de la théorie des ensembles classiques pour la prise en compte des sous ensembles définis de façon imprécise. À l'inverse de la logique booléenne, la logique floue permet à une condition d'être un autre état que vrai ou faux. Il y a des degrés dans la vérification d'une condition. La logique floue tient compte de l'imprécision de la forme des connaissances et propose un formalisme rigoureux afin d'inférer de nouvelles connaissances. Ainsi, la notion d'un sous ensemble flou permet de considérer des classes d'objets, dont les frontières ne sont pas clairement définies, par l'introduction d'une fonction caractéristique (fonction d'appartenance des objets à la classe) prenant des valeurs entre 0 et 1. La théorie des

ensembles flous repose sur la notion d'appartenance partielle de chaque élément appartient partiellement ou graduellement aux ensembles flous qui ont été définis. Les contours de chaque ensemble flou Figure2.1. ne sont pas « nets », mais « flous » ou « graduels ».

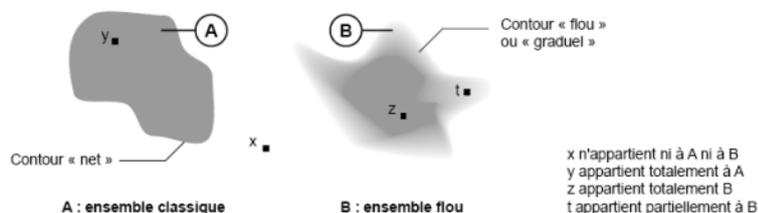


FIGURE 2.1 – Présentation d’un ensemble classique (A) et d’un ensemble flou (B).

La notion d’ensemble flou provient du constat que « très souvent, les classes d’objets rencontrés dans le monde physique ne possèdent pas de critères d’appartenance bien définis » [Men95]. Mathématiquement, un ensemble flou A est défini sur un univers de discours X, par une fonction d’appartenance $\mu_A(x)$ qui prend ces valeur dans l’intervalle [0,1]. Cette fonction donne le degré d’appartenance de chaque élément x à A. En fait, un élément de l’univers de discours peut être entièrement ou partiellement membre de l’ensemble A.

1.3 Les types des fonctions d’appartenance

Il n’y a pas de règle précise pour la définition de fonction d’appartenance. Alors chaque ensemble flou peut être représenté par sa fonction d’appartenance. En général, la forme de fonction d’appartenance dépend de l’application. Les fonctions d’appartenance peuvent avoir différentes formes [God99], [AA04]

*Triangulaire (figure (2.a)) *Trapézoïdales (figure (2.b)) * En forme de cloche (Gaussiennes), comme le montre figure2.2

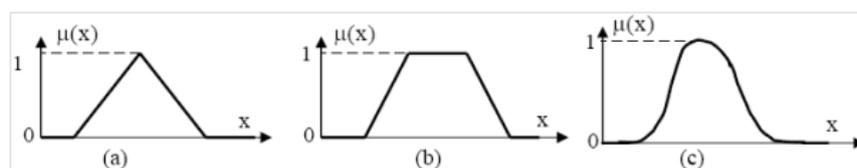


FIGURE 2.2 – Exemples de fonctions d’appartenance triangulaire (a), trapézoïde (b) et gaussienne (c)

1.4 Variable linguistique :

C’est une variable dont les valeurs ne sont pas des nombres, mais des mots ou phrases exprimés en langage naturel [L.X94], [Men95], [KS98]. Une variable

linguistique x est généralement caractérisée par un triplet $x, T(x), X$ où x désigne le nom de la variable, X son univers de discours, et $T(x)$ son ensemble de termes ou valeurs linguistiques. Dans notre cas, l'univers de discours X est toujours un sous-ensemble des réels. Par exemple, si l'erreur est considérée comme variable linguistique définie dans le domaine $X [-10;10]$, ses valeurs linguistiques peuvent être définies comme suit : $T(\text{erreur}) = \text{NégativeGrande (NG), Négative Petite (NP), EnvironZéro (EZ), Positive Petite (PP), PositiveGrande (PG)}$

Ces valeurs linguistiques peuvent être considérées comme des ensembles flous dont les fonctions d'appartenance sont montrées figure 2.3 :

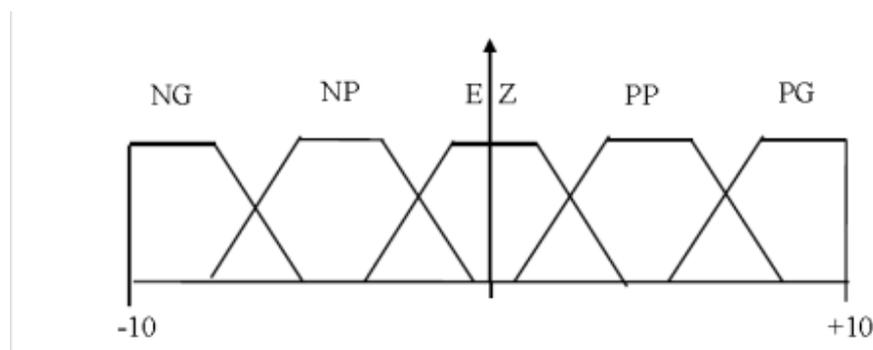


FIGURE 2.3 – Exemples des sous ensembles floue

Fonctions d'appartenance de $T(\text{erreur}) = \text{NG, NP, EZ, PP, PG}$

1.5 Opérations sur les ensembles flous :

Nous définissons, ci dessous, les notions d'intersection, d'union et de complémentation d'ensembles flous. Soient A et B deux ensembles flous décrits par leurs fonctions d'appartenance $\mu_A(x)$ et $\mu_B(x)$. Une définition de l'union flou mène à la fonction d'appartenance donnée par :

$$\mu_{(A \cup B)}(x) = \max(\mu_A(x), \mu_B(x))$$

Et une définition de l'intersection flou mène à la fonction d'appartenance donnée par :

$$\mu_{(A \cap B)}(x) = \min(\mu_A(x), \mu_B(x))$$

En ajoutant la définition de la fonction d'appartenance du complément flou :

$$\mu_{(\bar{A})}(x) = 1 - \mu_A(x)$$

1.6 Notion de règle linguistique :

La principale idée dans la logique floue est de représenter le raisonnement humain sous forme de règles linguistiques de la forme (Si ... Alors ...). Chaque règle comporte deux parties :

La prémisse : c'est la partie d'évaluation, exprimée par : Si et

La conséquence : la partie de conclusion, exprimer par : Alors

Zadeh est le premier qui a introduit la notion de règles floues.

La forme générale d'une règle linguistique pour un système à deux entrées et une seule sortie est :

Si (x est A) et (y est B) alors (z est C) Selon la nature de C : il existe deux types de règles :

Les règles de type Mamdani où les conclusions, comme les prémisses, sont des propositions floues :

Si x est A et y est B Alors Z est C Les règles de type Takagi-Sugeno où dans les conclusions, la sortie est une fonction numérique :

Si x est A et y est B Alors $z = f(x, y)$ [R]

1.7 Structure d'un système flou

Un système flou peut être interprété selon deux points de vue : mathématique ou logique. D'un point de vue mathématique, un système flou est une fonction non linéaire reliant un vecteur de données d'entrée à un vecteur de sortie et, de point de vue logique, un système flou est un système à base de connaissance particulière composé de quatre modules principaux, à savoir : la base de règles, la fuzzification, le moteur d'inférence et la défuzzification [S98]

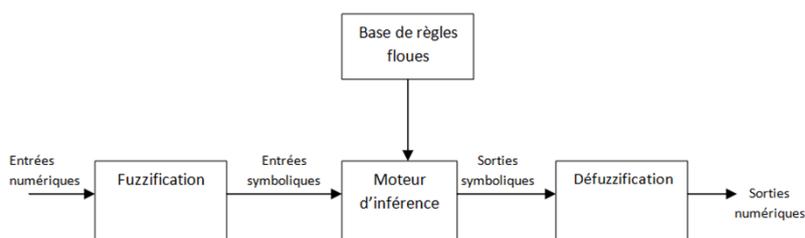


FIGURE 2.4 – Schéma général d'un SIF

Base de règles :

La base de règles floues, ou base de connaissances, contient les règles floues décrivant le comportement du système ; elle est le cœur du système entier dans le sens où tous les autres composants sont utilisés pour interpréter et combiner ces règles pour former le système final. Ces règles peuvent être fournies par un expert ou peuvent être extraites de données numériques. Dans les deux cas, les règles prennent la forme « Si prémisses Alors conclusion ». D'une manière générale, la base de règles d'un système flou doit respecter les conditions de complétude et de consistance afin d'assurer le bon fonctionnement de ce dernier.

Fuzzification :

La fuzzification transforme la grandeur physique d'entrée en une grandeur floue. On l'utilise pour pouvoir activer les règles qui sont exprimées à l'aide de variables linguistiques associées à des ensembles flous. Dans la littérature de la

commande floue, deux approches de fuzzification sont généralement utilisées, à savoir : la fuzzification singleton et la fuzzification non-singleton.

Moteur d'inférence :

Le moteur d'inférence floue transforme, à l'aide des techniques de raisonnement flou, la partie floue issue de la fuzzification en une nouvelle partie floue. En fait, le moteur d'inférence combine les règles floues, en utilisant les principes de la logique floue, pour effectuer une transformation à partir des ensembles flous dans l'espace d'entrée vers des ensembles flous dans l'espace de sortie.

Défuzzification :

La défuzzification transforme la grandeur floue issue de l'inférence en une grandeur physique. Cependant, il n'existe pas une procédure systématique pour choisir la stratégie de défuzzification. Un critère de choix des méthodes de défuzzification en commande floue est la simplicité des calculs. Ce critère a conduit à l'utilisation, le plus souvent, de la méthode de défuzzification dite la moyenne des centres « center-average » [S04]

1.8 Les types des SIF :

On distingue classiquement deux grandes familles de systèmes flous à base de règles : *Les systèmes flous à conclusion symbolique (systèmes flous linguistiques ou de Mamdani). *Les systèmes flous à conclusion fonctionnelle- (systèmes flous de Takagi-Sugeno). Ces deux types de systèmes flous sont basés sur une collection de règles « si... alors... ». Dans les deux cas, les prémisses de règles sont exprimées symboliquement, seule l'expression des conclusions de règles permet alors de dissocier les deux familles.

Méthode de Mamdani :

Dans la méthode de MAMDANI, les prémisses et les conclusions des règles sont flou. Cette méthode repose sur l'utilisation de l'opérateur min (minimum) pour l'inférence floue et de l'opérateur max (maximum) pour l'agrégation des règles. La défuzzification est généralement effectuée par la méthode du centre de gravité. [R]

Méthode de Takagi-Sugeno

Dans la méthode de Takagi-Sugeno [TM], les conclusions des règles sont des valeurs numériques calculées à partir des entrées. L'inférence floue est réalisée avec les opérateurs min ou produit . La valeur finale est obtenue en effectuant une moyenne pondérée des conclusions .

1.9 Conclusion

la logique floue est une approche très efficace et très utilisée pour augmenter l'interprétabilité des systèmes de classification. En résumé, il serait utile d'automatiser le processus de conception des systèmes flous. On pourrait diviser cette tâche en deux parties [J],

*Identification de la structure du système (recherche du nombre idéal de règles),

*Identification des paramètres (ajustement des fonctions d'appartenance).

Ces deux raisons conduisent vers l'idée de fusionner l'approche des méthodes évolutionnaire avec la technique floue. Nous allons aborder ce problème dans la partie qui suit. La partie suivante présente un état de l'art sur les techniques d'optimisation utilisées pour la classification dans les différents domaines.

2 Méthodes d'optimisation évolutionnaires

2.1 Introduction

Les systèmes flous sont capables de modéliser des systèmes d'aide à des solutions simples et qui sont : non-linéaires et quelques fois impossible de décrire par un formalisme mathématique. Cependant, le choix optimal des paramètres du classifieur flou (les fonctions d'appartenance, les règles flous, etc...) représente une tâche très difficile. Cette tâche requiert du temps, de l'expérience et de l'habileté de la part de l'expérimentateur. En principe, il n'y a pas de méthode générale pour l'ajustement d'un classifieur flou – même si des méthodes méta heuristiques et itératives ont été proposées dans la littérature pour ajuster les fonctions d'appartenance .

L'étude de phénomènes réels est une source nouvelle d'inspiration en ingénierie d'informatique et en biomédicale , où l'étude et la modélisation des systèmes complexes sont très présentes. Parmi les domaines de la biologie fertiles en inspiration, l'éthologie (étude du comportement des animaux) a récemment donnée lieu à plusieurs avancées significatives, dont la conception des systèmes artificiels. Ces systèmes sont notamment étudiés en robotique, en classification ou encore en optimisation. Les méta heuristiques constituent une famille d'algorithmes inspirés de la nature. Ces algorithmes sont particulièrement utiles pour résoudre des problèmes où les algorithmes d'optimisation classiques sont incapables de produire des résultats satisfaisants [TFA07].

2.2 Aspect d'Optimisation :

Un problème d'optimisation est défini par un ensemble de variables, une fonction objective (fonction de coût) et un ensemble de contraintes. L'espace d'état, appelé aussi domaine de recherche, est l'ensemble des domaines de définition des différentes variables du problème. Il est en général fini, puisque les méthodes opèrent dans des espaces bornés Et, pour des raisons pratiques et de temps de calcul, l'espace de recherche doit être fini. Cette dernière limitation ne pose pas de problème, puisqu'en général le décideur précise exactement le domaine de définition de chaque variable. Enfin, même dans le cas des problèmes à variables

continues, une certaine granularité est définie. La fonction objective définit le but à atteindre, on cherche à minimiser ou à maximiser celle-ci. [TFA07].

Inspiration biologique :

À la fin des années 80, une nouvelle voie d'exploration est apparue en intelligence artificielle. Il s'agit de l'étude et de l'utilisation des phénomènes observés dans la nature. En effet, ce sont des systèmes composés d'agents très simples, qui peuvent produire des constructions complexes et des solutions à des problèmes non triviaux (tri, parcours optimaux, répartition de tâches, . . .). Les informaticiens ont repris les principes d'auto-organisation et d'"émergence" présents dans ces sociétés, pour définir ce que l'on nomme l'intelligence collective.

Nous pouvons dire que l'intelligence collective caractérise un système où le travail collectif des entités (non complexes) interagissant entre elles fait "émerger" un comportement complexe global. Les avantages liés à l'utilisation d'une telle approche sont : – la production d'une performance collective supérieure à celle des individus ; – une plus grande adaptation et flexibilité aux environnements réels (en général dynamiques) – la fiabilité du système dans son ensemble (la perte d'un agent ne met pas en cause le processus général) . [TFA07].

Meta heuristiques :

Les premiers méta heuristiques datent des années 1980, Les méta heuristiques peuvent être utilisées pour plusieurs types de problèmes, tandis qu'une heuristique est adaptée à un problème donné, ont également comme caractéristiques communes leur caractère stochastique, ainsi que leur inspiration, une analogie avec d'autres domaines de recherche (la biologie, la physique, etc.). [TFA07], certains méta heuristiques sont adaptables à un grand nombre de problèmes différents sans changements majeurs dans l'algorithme. En plus de cette base stochastique, les méta heuristiques sont généralement itératives, c'est-à-dire qu'un même schéma de recherche est appliqué plusieurs fois au cours de l'optimisation.

Elles tirent en particulier leur intérêt de leur capacité à éviter les optima locaux, soit en acceptant une dégradation de la fonction objective au cours de leur progression, soit en utilisant une population de points comme méthode de recherche, la figure 3 montre les grande catégorie en des domaines d' intelligence informatique

2.3 Algorithmes d'optimisation :

Algorithme Génétique :

Les algorithmes génétiques sont sans doute la classe la plus représentative et la plus populaire parmi les algorithmes évolutionnaires. Ils sont basés sur les travaux de Holland [Hol92] et de Goldberg [Gol89] , Un algorithme génétique est un modèle d'apprentissage machine, qui est inspiré du processus de l'évolution observé dans la nature. Pour ce faire, un système artificiel contenant une population d'individus représentée par des chromosomes est créée. Des processus observés

dans la nature montrent que différents individus sont en compétition pour l'accès aux ressources dans leur environnement. Des individus sont meilleurs que d'autres. Ces derniers individus ont plus de chances de survivre et par conséquent de transmettre leurs gènes à la génération suivante. [TFA07]

La base d'un AG se compose de cinq éléments. Il s'agit d'un générateur de nombres aléatoires, une unité d'évaluation fitness et les opérateurs génétiques pour la reproduction, les opérations de croisement et la mutation. L'algorithme de base est résumée ci-dessous :

Algorithm 1 Algorithme Génétique..

- 1: Initialisation de la population
 - 2: Répéter
 - 3: Évaluation
 - 4: Reproduction
 - 5: Croisement
 - 6: Mutation
 - 7: Jusqu'à des exigences sont remplies
-

La population initiale requise au début de l'algorithme, est un ensemble des chaînes de nombres générés par le générateur aléatoire. Chaque chaîne est une représentation d'une solution au problème d'optimisation prises en compte. Les chaînes binaires sont couramment employées. Associée à chaque chaîne une valeur ' fitness ' calculée par l'unité d'évaluation. Une valeur fitness est une mesure de la bonne solution qu'il représente. L'objectif des opérateurs génétiques est de transformer cet ensemble de chaînes aux ensembles avec valeurs élevées de fitness. L'opérateur de reproduction effectue une fonction de sélection naturelle connue sous le nom de sélection ensemencée. Les chaînes des individus sont copiés à partir d'un ensemble (représentant une génération de solutions) à d'autre en fonction de leurs valeurs fitness la plus élevée, plus la probabilité d'une chaîne est grande plus avait de chance d'être choisi pour la prochaine génération. L'opérateur de croisement choisit paires de chaînes au hasard et produit de nouvelles paires. L'opération de croisement constitue de couper les chaînes et d'échanger leurs queues. Le nombre d'opérations de croisement est régi par un taux de croisement. L'opérateur de mutation mute de façon aléatoire ou inverse les valeurs de bits dans une chaîne. Le nombre d'opérations de mutations est déterminé par un taux de mutation. Une phase de l'algorithme consiste à appliquer l'évaluation, la reproduction, opérations de croisement et de mutation. Une nouvelle génération de solutions est produit à chaque phase de l'algorithme [DB02]

Optimisation par Colonie de Fourmis (OCF) :

- inspiration

A travers plusieurs expériences, il a été démontré qu'en se déplaçant les fourmis déposent sur leur passage une substance qu'on appelle « phéromone » [Hue03].

elles empruntent généralement le chemin qui contient le plus de « phéromones ». du fait du mécanisme d'attraction via la trace de phéromone, le chemin le plus court devient le plus emprunté : en effet, dans la mesure où les fourmis ayant emprunté la voie la plus courte auront mis moins de temps à faire un aller-retour, la voie est donc rapidement plus chargée en phéromones. ainsi, plus les fourmis suivent cette piste, plus cette piste devient attractive [AM04]

- la métaheuristique OCF

marco dorigo est à l'origine de l'ocf. il estime que rechercher une source de nourriture est analogue à rechercher une solution dans un espace de recherche commun.

- Algorithme de base

Pour mieux comprendre l'Algorithme AS(Ant system) l'exemple suivant appliqué sur graphe où chaque point représente une ville qui à chaque itération t ($1 \leq t \leq tmax$), chaque fourmi k ($k = 1, \dots, m$) parcourt le graphe et construit un trajet complet de $n = |N|$ étapes (on note $|N|$ le cardinal de l'ensemble N). Pour chaque fourmi, le trajet entre une ville i et une ville j dépend de :

1. la liste des villes déjà visitées, qui définit les mouvements possibles à chaque pas, quand la fourmi k est sur la ville $i : J_i^k$

2. l'inverse de la distance entre les villes : $\mu_{ij} = 1/d_{ij}$, appelée visibilité. Cette information « statique » est utilisée pour diriger le choix des fourmis vers des villes proches, et éviter les villes trop lointaines ;

3. la quantité de phéromone déposée sur l'arête reliant les deux villes, appelée l'intensité de la piste. Ce paramètre définit l'attractivité d'une partie du trajet global et change à chaque passage d'une fourmi. C'est, en quelque sorte, une mémoire globale du système, qui évolue par apprentissage. La règle de déplacement est la suivante :

$$p_{ij}^k = \frac{(\tau_{ij}(t))^\alpha (\eta_{ij})^\beta}{\sum_{l \in J_i^k} (\tau_{il}(t))^\alpha (\eta_{il})^\beta} j \in J_i^k \dots\dots\dots 2.1$$

Où α et β sont deux paramètres contrôlant l'importance relative de l'intensité de la piste, $\tau_{ij}(t)$, et de la visibilité, η_{ij} . Avec $\alpha = 0$, seule la visibilité de la ville est prise en compte ; la ville la plus proche est donc choisie à chaque pas. un compromis entre ces deux paramètres, jouant sur les comportements de diversification et d'intensification est nécessaire. Après un tour complet, chaque fourmi laisse une certaine quantité de phéromone $\Delta\tau_{ij}(t)$ sur l'ensemble de son parcours, quantité qui dépend de la qualité de la solution trouvée

$$\Delta\tau_{i,j}^k = \frac{Q}{L^k(t)}(i, j) \in T^k(t) \dots\dots\dots 2.2$$

où $T^k(t)$ est le trajet effectué par la fourmi k à l'itération t , $L^k(t)$ la longueur de la tournée et Q un paramètre fixée. L'algorithme ne serait pas complet sans le processus d'évaporation des pistes de phéromone. En effet, pour éviter d'être piégé dans des solutions sous-optimales, il est nécessaire de permettre au système « d'oublier » les mauvaises solutions. On contrebalance donc l'additivité des pistes par une décroissance constant

$$\tau(t + 1) = (1 - \rho) \cdot \tau_{ij}(t) + \sum_{k=1}^m \Delta\tau_{ij}(t) \dots \dots \dots 2.3$$

Où m est le nombre de fourmis et ρ le taux d'évaporation. La quantité initiale de phéromone sur les arêtes est une distribution uniforme d'une petite quantité $\rho_0 \geq 0$.

Algorithm 2 Algorithme Ant Système [DB02]..

- 1: Pour $t = 1, \dots, t_{max}$
 - 2: Pour chaque fourmi $k = 1, \dots, m$
 - 3: Choisir une ville au hasard
 - 4: Pour chaque ville non visitée i
 - 5: Choisir une ville j , dans la liste J_j^k des villes restantes, selon la formule 2.1
 - 6: Fin Pour
 - 7: Déposer une piste $\Delta\tau_{ij}(t)$ sur le trajet $T^k(t)$ conformément à l'équation 2.2
 - 8: Fin Pour
 - 9: Evaporer les pistes selon la formule 2.3
 - 10: Fin Pour
-

Optimisation par essais particuliers :

l'optimisation par essais particuliers (spo) est inventée par russel eberhart (ingénieur en électricité) et james kennedy (socio-psychologue) en 1995 . cette métaheuristique semble cependant mieux fonctionner pour des espaces en variables continues [TFA07]. l'origine de cette méthode vient des observations faites lors de vols groupés d'oiseaux et de bancs de poissons de reynold [cwr87], heppner et grenander [hg90]. Ces simulations ont mis en valeur la capacité des individus d'un groupe en mouvement à conserver une distance optimale entre eux et à suivre un mouvement global par rapport aux mouvements locaux de leur voisinage.

Dans PSO, une population de particules commence à se déplacer dans l'espace de recherche en suivant les particules actuelles optimales et en changeant les positions en vue de découvrir l'Optima globale. La position d'une particule se réfère à une solution possible de la fonction à optimiser. Évaluer la fonction par la position de la particule fournit l'aptitude de cette solution. Dans chaque itération, chaque particule est mis à jour sa position par la suite de la meilleure solution de la courante particule réalisés à ce jour (meilleure particule, \vec{p}) et la meilleur de la population le meilleur globale \vec{g} Quand une particule prend une partie de la population que ses voisins topologiques, la meilleure valeur est la meilleure locale.

la particules ont tendance à se déplacer vers les bonnes zones dans l'espace de recherche par le diffusion d'informations à l'essaim. La particule est déplacée vers une nouvelle position calculée par la vitesse mis à jour à chaque pas de temps. Cette nouvelle position est calculée comme la somme de la position précédente et la nouvelle vitesse par :

$$\vec{x}(t+1) = \vec{x}(t) + \vec{v}(t+1) \dots 2.4$$

La mise à jour de vitesse est effectué comme indiqué dans l'équation :

$$\vec{v}(t+1) = \omega \vec{v} + \phi_1 rand(0,1)(\vec{p}(t) - \vec{x}(t)) + \phi_2 rand(0,1)(\vec{p}(t) - \vec{x}(t)) \dots 2.5$$

Le paramètre ω est appelé inertie et $\vec{v}(t)$ contrôle de la grandeur de la vitesse ancien dans le calcul de la nouvelle vitesse, tandis que ϕ_1 et ϕ_2 déterminer l'importance des $\vec{p}(t)$ et $\vec{g}(t)$, respectivement. En outre, v_i , à tout moment de l'étape algorithme est limitée par le v_{max} paramètre. L'essaim dans PSO est initialisée en attribuant à chaque particule une position uniforme et choisi aléatoirement dans l'espace de recherche. Les vitesses sont initialisés de manière aléatoire entre les borne min et max de la vitess . Principales étapes de la procédure sont les suivantes :

Algorithm 3 Algorithme PSO

- 1: Initialisation de la population
 - 2: Répéter
 - 3: Calculer les valeurs de fitness des particules
 - 4: Modifier les meilleurs particules dans l'essaim
 - 5: Choisissez la meilleur de particule
 - 6: Calculer les vitesses des particules
 - 7: Mettre à jour les positions des particules
 - 8: jusqu'à ces exigences sont remplies
-

Les vitesses des particules sur chaque dimension sont ramenées à une vitesse maximale v_{max} . Si la somme des accélérations provoquerait la vitesse sur la dimension à dépasser v_{max} , qui est un paramètre spécifié par l'utilisateur, alors la vitesse de cette dimension est limitée à v_{max} [DB02]

Besoins d'utilisation des algorithmes d'optimisation :

Bonabeau a défini l'intelligence en essaim comme toute tentative visant à concevoir des algorithmes distribués ou de résolution de problèmes dispositifs inspirés par le comportement collectif des colonies d'insectes sociaux et des sociétés d'autres animaux [BDT99]. bonabeau et al. ont concentré leur point de vue sur les insectes sociaux à elles seules comme les termites, les abeilles, les guêpes et les espèces de fourmis différentes. [DB02] les chercheurs ont mis au point un essaim des systèmes en réponse à la réussite observée et l'efficacité des essais dans la nature pour résoudre des problèmes difficiles.

Dans la dernière décennie un nombre croissant des demandes retenues de l'intelligence en essaim utilisé pour divers problèmes d'optimisation, telles que le routage des paquets à travers des réseaux (caro et dorigo 1998), le problème du voyageur de commerce (dorigo et al. 1996), l'ordonnancement (blum, 2005a), la robotique (dorigo 2009) et l'exploration de données, le sujet de cette enquête. la figure 2.5. montre que le nombre d'articles publiés sur ces sujets (comme indexé par web de science2) montre une forte augmentation depuis début 2000. bien que le nombre de pages indiquent que pso semble le plus populaire, l'aco est également en augmentation en popularité.

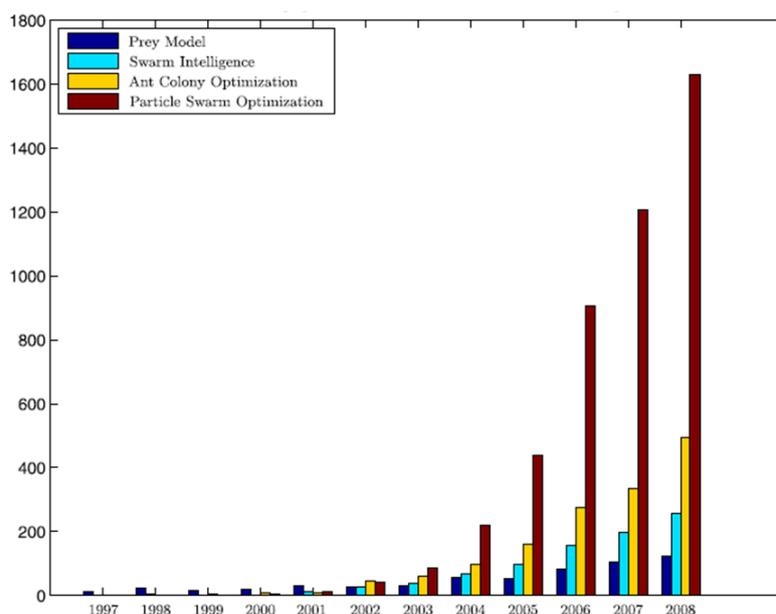


FIGURE 2.5 – Nombre de documents écrits sur le sujet, à partir de web of science

2.4 algorithmes de la colonie d'abeille :

Cette section décrit la biologie des abeilles, en se concentrant sur les aspects pertinente à des algorithmes d'optimisation.

Accouplement :

Colonies d'abeilles domestiques contiennent une seule reine accouplée à un grand nombre de mâles et de des milliers de travailleurs. La reine est normalement le seul individu qui se reproduit dans la colonie, tandis que les travailleurs nettoyer le nid, occupe du fourrage pour l'alimentation et nourrir les couvains. En raison de l'accouplement multiple par la reine, des ouvrières dans une colonie diffèrent génétiquement. Lorsque les travailleurs qui ne partagent pas le même père différent dans leur seuil de la tâche, des résultats de spécialisation des tâches basées sur la génétique. Les travailleurs issus du père A seront les premiers à démarrer la recherche de nourriture pour le pollen quand les réserves de pollen sont

faibles. Parce qu'ils vont récolter le pollen avant la recherche du pollen lorsque seuil de travailleurs d'autres est atteint (par exemple, ceux qui n'ont pas désiré par le père de A), la majorité des butineuses de pollen seront des travailleurs qui partagent le même père. Cette diversité génétique est pensée pour permettre une colonie de répondre élastiquement à des changements dans l'environnement [OF07]. Les travaux empiriques ont montré que les colonies d'abeilles comprenant une main-d'œuvre diversifiée génétiquement a des résultats meilleurs [MS07]

Comportement de butinage :

Les travailleurs non uniquement fourragent pour le pollen, ils ont aussi recueillir le nectar qui est stocké dans la colonie et devient miel. Alors que le pollen est utilisé assez rapidement car il est alimenté à le couvain en développement, le nectar est stocké afin de permettre à la colonie de survivre à des périodes lorsque le fourrage n'est pas disponible. les abeilles ont développé un mécanisme unique qui leur permet de recruter des membres de la colonie aux sources de nourriture trouvés et ça grâce à : le langage de la danse [kF67]. L'utilisation du langage de danse permet une colonie d'exploiter rapidement et de monopoliser les sources de nourriture rentables, tout en ignorant presque ceux qui sont de qualité médiocre [Jan93] La danse des abeilles encode l'information sur la direction et la distance de la source de nourriture trouvée [PGA07], les recrues potentielles, sont capables d'extraire cette information sur laquelle ils quittent la colonie et tenter de localiser la source nourriture annoncé. Au cours d'une danse typique des progrès danseur avant de secouer vigoureusement son corps de droite à gauche [TYT07]. Ceci est connu comme la «phase frétilante " de la danse. Après la phase de frétillement de l'abeille fait un virage brusque vers la gauche ou la droite, encerclant retour au début de la phase oscillante à nouveau. Ceci est connu comme la «phase retour danse frétilante'». À la fin de la seconde frétilante, l'abeille tourne dans le sens opposé, de sorte qu'à chaque deuxième circuit de la danse, elle aura tracé le fameux chiffre de motif huit de la danse frétilante [kF67] voila figure 2.6 qui montre cette danse :

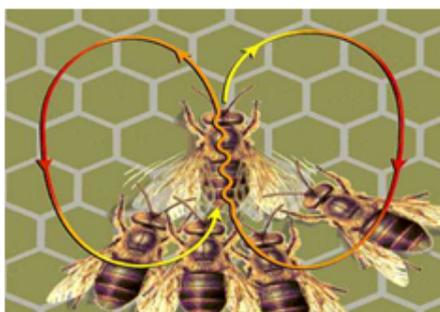


FIGURE 2.6 – Danse frétilante des abeilles

La phase la plus riche en information de la danse est la phase oscillante. Pendant la phase oscillante l'abeille aligne son corps de telle sorte que l'angle de déviation de la verticale est similaire à l'angle de l'objectif de l'azimut actuel du soleil. la figure2.7 montre cette cette notion sur direction :

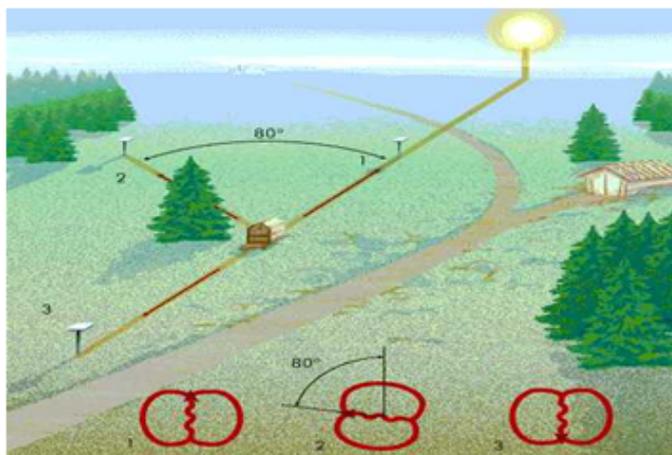


FIGURE 2.7 – :Direction du fourage chez les abeilles

L'information de distance est codées dans la durée de la phase oscillante. Danses pour les cibles proches ont des phases courtes frétilante tandis que des danses pour les cibles éloignées ont des phases frétilante prolongées. la figure 2.8 montre relation entre nombre du tour et distance

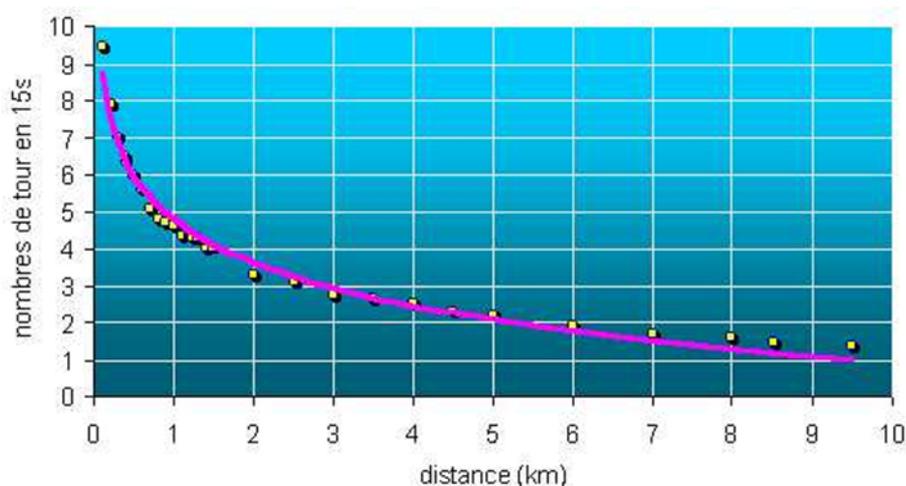


FIGURE 2.8 – : Distance de la nourriture par apport au nombre de tour de danse

Les abeilles mellifères moduler leur danse frétilante en fonction de la rentabilité de la source de nourriture trouvée. la source de nourriture La plus rentable [TRS96]. En conséquence, les abeilles dansent pour les sites très rentables à attirer des disciples de danse plus que ceux que la danse pour les sites médiocres. Le langage de la danse permet à une colonie d'abeilles de suivre les conditions sans cesse changeantes de recherche de nourriture [BR00]

modèle de comportement de butinage :

Tereshko développe un modèle de comportement de butinage d'une colonie

d'abeilles sur la base des équations de réaction-diffusion [Ter00] Ce modèle minimal de la sélection du fourrage qui conduit à l'émergence de l'intelligence collective des essaims d'abeilles se compose de trois éléments essentiels : les sources de nourriture, employés butineurs et les non employés butineurs et le modèle définit deux modes principaux du comportement : le recrutement d'une source de nectar et de l'abandon d'une source.

i) Sources alimentaires :

La valeur d'une source de nourriture dépend de nombreux facteurs tels que sa proximité avec le nid, sa richesse, le goût de son nectar ou de la concentration de son énergie et la facilité d'extraction de cette énergie. Par souci de simplicité la «rentabilité » d'une source de nourriture peut être représentée par une seule quantité [See95].

ii) Employés butineurs :

Elles sont associées à une source de nourriture particulière dont ils sont actuellement exploitant ou qui sont «employés» là dans. Ils transportent avec eux des informations à propos de cette source particulière, sa distance et la direction du nid, la rentabilité de la source et de partager cette information avec une certaine probabilité.

iii) non employés butineurs :

Ils sont sans cesse à regarder pour une source de nourriture à exploiter. Il existe deux types de non employé butineur : les scouts qui recherchent dans l'environnement du milieu de nid pour nouvelles sources de nourriture et des spectateurs qui attendent dans le nid d'établir une source de nourriture par le biais de l'information partagée par les employés butineurs. [See95].

L'échange d'informations entre les abeilles est l'événement le plus important dans la formation de la connaissance collective. La partie la plus importante de la ruche à l'égard de l'échange d'informations est la piste de danse. La communication entre les abeilles liés à la qualité des sources de nourriture a lieu dans la région de la danse. Cette danse s'appelle un la danse frétille.

Depuis des informations sur toutes les sources de nourriture autour du riche est disponible pour un spectateur sur la piste de danse, probablement il peut assister à des danses de nombreuses employeurs et décide de se recruter à la source la plus rentable. Il ya une plus grande probabilité de assistant qui choisissent des sources les plus rentables depuis plus d'information est distribué sur les sources les plus rentables. Employés Butineurs partagent leurs informations avec une probabilité proportionnelle à la rentabilité de la source de nourriture, et le partage de cette information à travers la danse frétille est plus longue dans la durée. Par conséquent, le recrutement est proportionnelle à la rentabilité de la source [TL] des aliments. Afin de comprendre les caractéristiques de comportement de base de butineurs, nous allons examiner la figure 1. Suppo-

sons qu'il existe deux sources de nourriture découvertes : A et B. Au tout début, un butineur potentielle commencera comme butineur chômeurs. Cette abeille n'a aucune connaissance sur les sources de nourriture autour du nid. Il ya deux options possibles pour une telle abeille : i) Il peut être un éclaireur et commence à chercher autour du nid spontanément pour un aliment en raison de certaines de motivation interne ou indice externe possible (S sur la figure 2.9.

ii) Il peut être une recrue après avoir regardé les danses frétilante et commence à chercher une source d'aliment. (R sur la figure 2.9.

Après avoir localisé la source de nourriture, l'abeille utilise sa propre capacité à mémoriser l'emplacement et commence alors immédiatement à l'exploiter. Ainsi, l'abeille va devenir une « butineuse travailleuse ». La butineuse prend une charge de nectar de la source et retourne à la ruche et décharge dans magasin d'alimentation. Après le déchargement de la nourriture, l'abeille a les trois options suivantes :

i) Il devient un suiveur engagé après l'abandon de la source de nourriture (UF).

ii) Il danse, puis recrute camarades du nids avant de revenir à la même source alimentaire (EF1).

iii) Il continue de fourrage à la source de nourriture sans faire appel à d'autres abeilles (EF2).

Il est important de noter que pas tous les abeilles commencent butinage simultanément.les expériences confirment que les nouvelles abeilles butinent commencent à un taux proportionnel à la différence entre le nombre total d'abeilles et le nombre de nourriture présente.

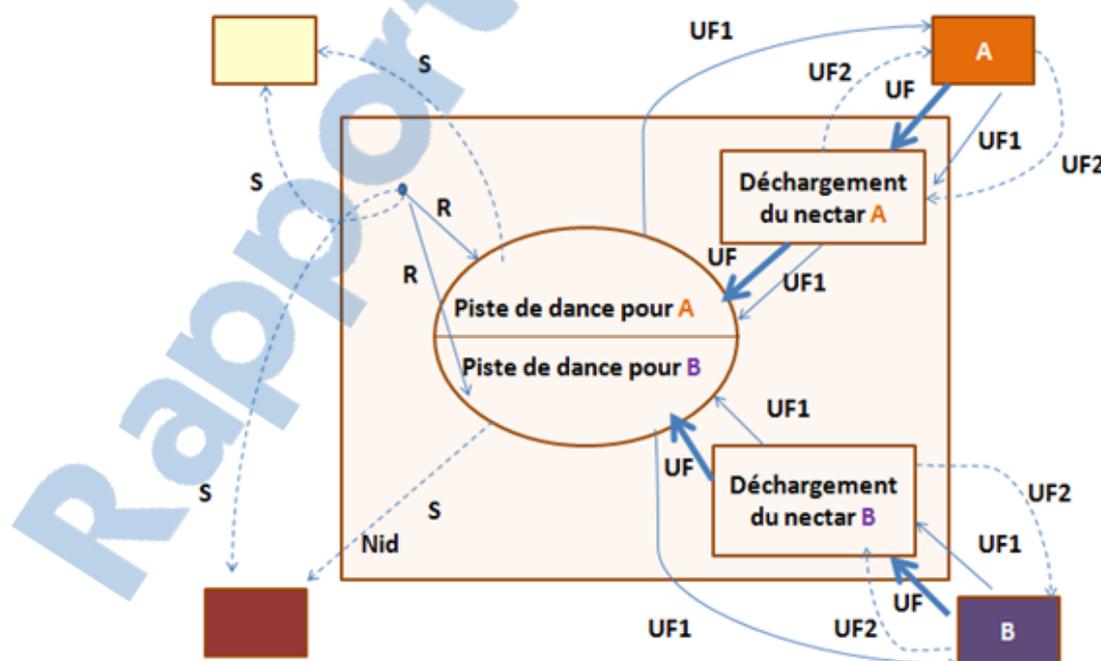


FIGURE 2.9 – : Comportement des abeilles mellifères butinent le nectar

Algorithmes d'inspiration d'abeilles :

Comme il est indiqué , les approches actuelles d'optimisation d'inspiration des abeilles sont basées sur l'un des deux comportements trouvés chez les abeilles : butinages ou de l'accouplement. Cette section décrit certains des algorithmes existants basés sur ces comportements.

a-Algorithmes d'optimisation à base d'accouplement :

Algorithmes d'optimisation basés sur accouplement puisent leur inspiration sur l'accouplement du comportement des reines des abeilles, la paternité mixte a été montré qu'elle améliorer performances d'une colonie, les chercheurs ont été inspirés pour développer algorithmes d'optimisation qui exploitent les principes qui sous-tendent le comportement d'accouplement de la reine. Ces algorithmes sont également liés à la région de l'informatique évolutive car ils s'appuyer sur les principes de sélection, de croisement et la mutation.

b-Algorithmes à base Comportement de butinage :

Des approches basées sur le Comportement de butinage s'inspirer des mécanismes sous-jacents au processus de butinage chez les abeilles. Outre les études expérimentales montre plusieurs support de modèles théoriques et de l'efficacité en contour le processus décisionnel décentralisée de l'abeille lors la recherche de nourriture [Bee08] Sherman et Visscher [TM] ont étudié quand la danse-frétille de recrutement est bénéfique ; Les résultats suggèrent que ce recrutement augmente la quantité de nourriture d'une colonie lorsque les ressources sont rares. Beekman et Lew [Bee08] ont trouvé que le recrutement est le plus bénéfique si le succès moyen de localiser les correctifs nouveaux aliments tombe en dessous de la réussite moyen des recrues . En outre, ils ont montré que la communication facilite l'exploitation rapide des sources de nourriture très rentables lorsque les sources alimentaires de plusieurs qualité différente sont présents. Ainsi, la danse de communication des abeilles régleme le compromis entre l'exploitation et l'exploration. Ces études soulignent l'utilité de comportement de butinage des abeilles en termes d'optimisation dans un environnement dynamique dans lequel les ressources sont rares et se distinguent de la qualité, comme c'est le cas dans de nombreux domaines problématiques d'optimisation. Inspiré par ces résultats des études du comportement du transfert d'information directe joue un rôle important dans des algorithmes basés sur la recherche de nourriture des abeilles qui sont exposées ci-dessous. Ceci est en contraste à des algorithmes d'optimisation de colonies de fourmis qui reposent sur communication indirecte par l'intermédiaire des phéromones artificielles [Bee08].

Algorithme de colonie d'abeilles artificiels :

L'algorithme de colonie d'abeille artificielle (ABC) a été introduit par Karaboga [Kar05] pour l'optimisation de fonction. Chaque solution représente Une position de nourriture potentielle dans l'espace de recherche et la qualité de la solution correspond à la qualité de la position alimentaire. Agents (abeilles artifi-

Année	Auteurs	Algorithmes	Problème étudié
1997	Sato and Hagiwara	Bee System (BS)	Amélioration Algorithme Génétique
2001	Lucic and Teodorovic	BCO	Problème de Voyageur de commerce
2001	Abbas	MBO	Problèmes de satisfiabilité propositionnelle
2004	Wedde, Farooq, and Zhang	BeeHive	Protocoles de routage
2005	Karaboga	ABC	optimisation numérique
2005	Yang	(VBA)	Optimisations de fonction avec l'application dans les problèmes d'ingénierie
2005	Benatchba, Admane, and Koudil	MBO	Max-Sat problème
2006	Basturk and Karaboga	ABC	Optimisation de la fonction numérique
2006	Navrat	Bee Hive Model	recherche Web
2007	Koudil, Benatchba, Tarabetand, and El Batou	MBO	Partitionnement et des difficultés de programmation
2007	Quijano and Passino	Honey Bee Social Foraging Algorithm	Résoudre les problèmes d'allocation des ressources optimales
2007	Markovic, Teodorovic, and Acimovic-Raspopovic	BCO	Routage et affectation de longueur d'onde dans les réseaux entièrement optiques
2007	Karaboga and Basturk	ABC	Tests ABC algorithme sur un ensemble de problèmes multidimensionnels d'optimisation numérique
2007	Karaboga, Akay and Ozturk	ABC	Feed-forward de formation réseaux de neurones

TABLE 2.1 – Algorithmes inspiré du comportement des abeilles

cielles) recherche d'exploiter les sources de nourriture dans l'espace de recherche. L'ABC utilise trois types d'agents : les abeilles employées, les abeilles spectateur, et les scouts. Abeilles employé (EB) sont associés à des solutions actuelles de l'algorithme. À chaque étape de l'algorithme un EB tente d'améliorer la solution, il représente en utilisant une étape de recherche locale, après il va essayer de recruter des abeilles spectateur (OBs) pour sa position actuelle. OBs choisissent parmi les postes promus en fonction de leur qualité, ce qui signifie que de meilleures solutions attirera plus OBs. Une fois un OB a choisi un EB et donc une solution, il cherche à optimiser la position de l'EB par une étape de recherche locale. EB mise à jour sa position si un OB recruté était en mesure de repérer une meilleure position, sinon il reste sur sa position actuelle. En outre, un EB va abandonner sa position si elle n'était pas en mesure d'améliorer sa position pour certain nombre d'étapes. Quand un EB abandonne sa position, il devient un éclaireur, ce qui signifie qu'il sélectionne une position aléatoire dans l'espace de recherche et devient l'employé à cette position. L'algorithme peut être décrit plus en détail comme suit : étant donné une dimension dim fonction F et une population de n agents, $n_e = n / 2$ EBS et

$n_o = n / 2$ OBs. L'algorithme est initialisé en plaçant EB i ($i \in n_e$) sur un emplacement aléatoire θ_i dans l'espace de recherche. $F(\theta_i)$ est ensuite la qualité de la position de EB $_i$. Dans chaque itération, chaque EB tente d'améliorer sa situation en utilisant étape une recherche locale. Premièrement, EB $_i$ calcule une nouvelle solution candidate.

$$\theta_i^* = \theta_i + rand(0, 1)(\theta_i - \theta_k) \dots \dots \dots 2.6$$

où θ_k correspond à la position d'un autre EB choisi au hasard d'indice k - différent de i - et $rand(-1, 1)$ constitue un nombre aléatoire entre -1 et 1 établi à partir d'une répartition uniforme. Après une solution candidat nouvelle est calculé un mécanisme de sélection gourmande est utilisé afin de décider si θ_i devrait la écarté.

$$\theta_i = \begin{cases} \theta_i & \text{si } F(\theta_i) < F(\theta_i^*) \\ \theta_i^* & \text{sinon} \end{cases} \dots \dots \dots 2.7$$

est utilisé, et les meilleures solutions attire plus des OBs. Après avoir choisi une solution un OB essaie d'améliorer la solution en utilisant le même mécanisme que décrit dans l'équation. 2. Le EB qui correspond à cette solution met à jour sa position si une meilleure position est trouvé par l'OB. L'algorithme garde trace du nombre de mesures que l'EB a été à la même Solution. Si le nombre d'étapes consacrées à la même position atteint un certain valeur limite l'EB abandonne sa position et devient éclaireur d'une nouvelle position, qui correspond à choisir une position aléatoire dans l'espace de recherche. Le paramètre ainsi contrôle du taux d'exploitation / exploration du système. C'est à la fois que la taille de la population et le rapport OB / EB dépendent de l'objectifs d'optimisation. Pour une meilleure compréhension de l'algorithme ABC est décrite dans l'algorithme 1.

Algorithm 4 Algorithme de colonie d'abeille artificielle (ABC).

- 1: Paramètres : n, limite
- 2: la fonction objectif $f(x)$, $x = [x_1, x_2, \dots, x_d]^T$
- 3: Initialiser les positions alimentaires aléatoirement x_i $i = 1, 2, \dots, n$
- 4: Initialiser les positions alimentaires aléatoirement x_i $i = 1, 2, \dots, n$
- 5: évaluer fitness $f(x_i)$ des individus
- 6: tant que condition d'arrêt n'est pas satisfait faire
- 7: phase employé :
- 8: Produire de nouvelles solutions avec k, j et ϕ aléatoirement
- 9:

$$v_i^j = x_i^j + \phi i_i^j * (x_i^j - x_k^j) \quad k \in 1, 2, \dots, n, j \in 1, 2, \dots, d, k \neq j, \phi \in [0, 1]$$
- 10: Évaluer les solutions
- 11: Appliquer le processus de sélection gourmande pour les abeilles employeuses.
- 12: phase spectateur :
- 13: Calcul des valeurs de probabilité pour des x_i solutions
- 14:

$$P_i = \frac{f_i}{\sum_{i=1}^n f_j} \quad 2.8$$
- 15: Produire de nouvelles solutions de x_i sélectionné à l'aide P_i
- 16: Évaluer les solutions
- 17: Appliquer la sélection gourmande pour les spectateurs
- 18: phase de scout :
- 19: Trouver une solution abandonnée : Si la limite est dépassée, le remplacer par une nouvelle solution aléatoire.
- 20: Mémorisez la meilleure solution achevé
- 21: fin tant que
- 22: post-traitement des résultats et de visualisation

3 Conclusion

Un des enjeux de la conception des méta heuristiques est donc de faciliter le choix d'une méthode et de simplifier son réglage pour l'adapter à un problème donné. Du fait du foisonnement de la recherche, un grand nombre de classes de méta heuristiques existent.

Algorithme de colonies des abeilles Artificielle (ABC) est l'un des plus récemment introduit dans la base des Algorithmes des essaim base algorithmes. ABC simule le comportement intelligent de recherche de nourriture d'un essaim d'abeilles. Les résultats montrent que la performance de l'ABC est meilleure que ou similaires à ceux d'autres algorithmes basés sur la population avec l'avantage d'employer moins de paramètres de contrôle.

Chapitre 3

Expérimentations, Résultats et Interprétations

1 Introduction

La résolution des problèmes de classification des pathologies dans le domaine médical est une technique d'apprentissage supervisée qui prend « un ensemble d'échantillons afin de générer un modèle (Classifieur) qui classe les échantillons de nouvelles données dans des groupes prédéfinis ou des classes qui sont susceptibles de partager certains facteurs pathologiques. Ce problème de classification peut être facilement résolu par le système d'inférence flou.

En général, dans la conception des applications d'aide au diagnostic médical les règles et les fonctions d'appartenance sont données par des experts humains en se basant sur leurs expériences. Avec un nombre croissant de variables, le nombre possible de règles augmente de façon exponentielle, ce qui rend difficile pour les experts de définir un ensemble de règles complet pour la performance du bon système. Piloté par les données, des approches ont été proposées pour le développement du système de classification flou à partir des données numériques, sans experts du domaine.

La conception d'un système de classification flou peut être formulée comme un problème de recherche dans un espace de haute dimension, où chaque point représente un ensemble de règles et des fonctions d'appartenance. Pour développer le système, un ensemble de solutions seront évoluées après un certain nombre d'itérations où chaque solution permet de coder un ensemble de règles et des fonctions d'appartenance floues comme des sources de nourriture en utilisant l'Algorithme de colonie d'abeille ABC. Développer le système optimal flou est équivalent à trouver la source de nourriture la plus importante dans la piste de recherche. Cela se fait grâce à des algorithmes d'intelligence évolutive où ABC présente un meilleur candidat pour la conception de ce classifieur flou. Le système de classification flou à base ABC est très simple et produit un ensemble de règles compactes avec un taux de classification important en comparant avec les résultats rapportés dans la littérature.

2 Description de la base de données utilisée

Dans ce mémoire nous avons utilisé la base Pima Indian Diabetes (PID), Cette base est une collection de rapports de diagnostic médicaux des patientes des indiennes dont 768 femmes âgé de plus de 21 ans . Onze mille patients qui sont des membres de la réserve indienne PIMA ont participé à 30 ans de recherche des instituts qui aideront les gens afin d'éviter le diabète.

2.1 L'intérêt de la base de données :

De nombreuses familles Pima ont vécu dans la Communauté indienne PIMA de Gila River depuis des générations. Pour cette raison, les scientifiques peuvent rechercher les causes profondes de la maladie à travers plusieurs générations de nombreuses familles. La durée des études NIDDK et le nombre de familles concernées permet aux scientifiques une perspective inestimable sur la façon dont la maladie progresse. Plus des générations étudié, permet de mieux comprendre comment le diabète affecte les gens, et plus la possibilité de développer des médicaments ou la thérapie génétique, mode de vie ou de changements qui vont ralentir ou empêcher la venue de la maladie, La recherche prend tellement de temps, parce que les maladies comme le diabète sont si difficile à comprendre. Des études ont montré que les Indiens Pima d'Arizona, ont un taux de diabète de type 2 beaucoup plus élevé que la moyenne nationale, ce qui les rend le groupe le plus prédisposé au diabète dans le monde, elle atteint 70% pour les personnes âgées entre 55 et 64 ans. les Indiens Pimas, comparés aux autres populations, présentent une résistance à l'action de l'insuline. Cette caractéristique est certainement en partie génétiquement déterminée [PIM]

2.2 Base de données utilisées

La base Pima Indian Diabetes est constituée de 768 cas dont 268 sont diabétiques et 500 non diabétiques. Quelques valeurs nulles de fonctionnalités sont éliminées, Après l'élimination de ces modèles avec les données physiques illogiques le nombre total de modèles est de 392, où 262 sont des cas normaux et 130 sont des cas de diabète Chaque cas est formé de 9 attributs, dont 8 représentent des facteurs de risque et le 9eme représente la classe du patient, le tableau 3.1 présente une description de ces attributs :

N° Attribut	Description attribut	Moyenne	Déviati on standard	Max	Min
1	Nombre de grossesses (Ngross)	3.8	3.4	0	17
2	Glu concentration plasmatique de glucose (mg/dl)	120.9	32.0	56	198
3	Pression artérielle diastolique (mm/ Hg) (PAD)	69.1	19.4	24	110
4	Epaisseur de la peau au niveau du triceps (mm) (Epai)	20.5	16.0	7	63
5	Taux d'insuline au bout de 2 heures (mu U / ml) (INS)	79.8	115.2	14	846
6	Indice de masse corporelle (poids en kg/ m ²) (IMC)	32.0	7.9	18.2	67.1
7	Fonction pédigrée du diabète (Ped)	0.50	0.3	0.085	2.42
8	Age (années)	33.20	11.8	21	81

TABLE 3.1 – Tables de multiplication

3 Le raisonnement flou

Le but de notre système de classification est de générer une base de règles compacte avec un taux de classification élevé. Dans ce travail les règles « si-alors » peuvent être exprimées comme suit : R_j :si x_{p1} est A_{j1} et x_{p2} est A_{j2} etet x_{pn} est A_{jn} Alors (x_{p1}, \dots, x_{pn}) Partition à la classe $C_j=1 \dots N, \dots, \dots, \dots, 1$ (x_{p1}, \dots, x_{pn}) ($p=1, 2, \dots, m$) est le vecteur d'entrée, R_j est le label de la j^{me} règle' si -alors', A_{j1}, \dots, A_{jn} représentent les sous-ensembles flous définis par des fonctions d'appartenance $\mu_{A_{ji}}(x_{ji})$ ou le degré d'appartenance de chaque entrée est exprimé par un nombre entre 0 et 1., $C=C_1, C_2, \dots, C_m$ représentent les classes de sortie de la j^{me} règle. Nous utilisons dans ce mémoire des fonctions d'appartenance de type trapézoïde définies par quatre points $a < b < c < d$:

$$\mu_A(x) = \begin{cases} 0 & (x < a) \text{ ou } (x > d) \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & b \leq x \leq c \\ \frac{d-x}{d-c} & c \leq x \leq d \end{cases}$$

Selon une base de règle donnée et composée de N règles, un échantillon d'entrée est classifié en fonction de la classe conséquente de la règle gagnante R_w . la règle gagnante a la valeur maximale du produit de degré d'appartenance qui est spécifié comme suit :

$$w = \operatorname{argmax}\{\mu_j(x_p) | j = 1, \dots, N\}$$

4 Apprentissage classificateur flou basé sur l’algorithme de la colonie d’abeille :

L’objectif principal de ce mémoire est de développer une approche efficace qui peut améliorer les performances médicales pour le diagnostic de la maladie du diabète. La nouveauté de notre approche consiste à utiliser l’algorithme de la colonie d’abeille dans le but de créer un classifieur optimal flou avec un petit nombre de règles qui sont simples et compréhensibles par les médecins.

4.1 Représentation de la solution :

Dans ce travail nous avons utilisé deux ensembles flous (basse (L) et haute (H)) pour chaque attribut avec la fonction d’appartenance trapézoïdale. Ces ensembles flous sont définis par six valeurs réelles $P_0, P_1, P_2, P_3, P_4, P_5$ comme illustré dans la Figure 3.1.

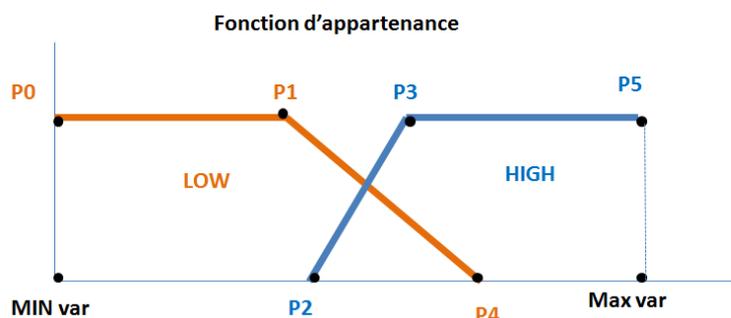


FIGURE 3.1 – Schéma de fonctions d’appartenance pour chaque variable d’entrée.

P_0 et P_5 sont fixes et représentent la valeur minimale et la valeur maximale de la variable d’entrée respectivement. Les valeurs P_0, P_1, P_2, P_3, P_4 , sont utilisées pour la création des fonctions d’appartenance et chacune d’eux a ses propres limites telles que P_1 entre $[P_0, P_5]$, P_2 entre $[P_0, P_1]$, P_3 entre $[P_1, P_5]$, P_4 entre $[P_2, P_5]$. Cependant, chaque solution représente une base de règles (BR) et chaque règle est caractérisée par les paramètres de la partie prémisse et les étiquettes de la sélection des règles, afin de créer et d’obtenir un classificateur flou avec une base de règles optimale. la Figure 3.2 montre la codification des solutions ou la i ème solution est représentée par un vecteur qui comprend les paramètres de la partie prémisse et l’étiquette l_j . Les paramètres de la partie prémisse sont codés par quatre valeurs réelles $[P_1, P_2, P_3, P_4]$ et une valeur attribuée à l’ensemble $\{1, 2\}$ spécifiant le type de fonction d’appartenance {faible, haute}, respectivement. L’étiquette l_j est représentée par un bit qui prend soit la valeur 0 ou 1, cela signifie que si $l_j = 0$, la règle est rejetée de la base de règles, sinon, la règle est acceptée. Après la création des parties prémisses, nous sélectionnons pour chaque partie antécédente une partie conséquente formulé par la procédure suivante [21] : Etape 1 : calculer la degré d’activation de la jème règle floue pour chaque échantillon d’apprentissage $x_p(x_{p1}, \dots, x_{pn})$ par :

$$\mu_j(x_p) = \mu_{j1}(x_{p1}) * \mu_{j2}(x_{p2}) * \dots * \mu_{jn}(x_{pn}) \cdot p = 1 \dots n \dots \dots \dots 3.1$$

- Etape 2 : pour chaque classe C (C = 1 ... M) calculer la somme des degrés d'activation relatifs aux classes de la jeme règle

$$\alpha_{class}(R_j) = \sum_{x \in class} \mu(x_p) \dots \dots \dots 3.2.$$

- Etape 3 : trouver la classe C de la jeme règle avec la valeur maximale de

$$\alpha_{class}(R_j) = argmax\{\alpha_{class}(R_j) | i = 1, \dots, M\} \dots \dots 3.3$$

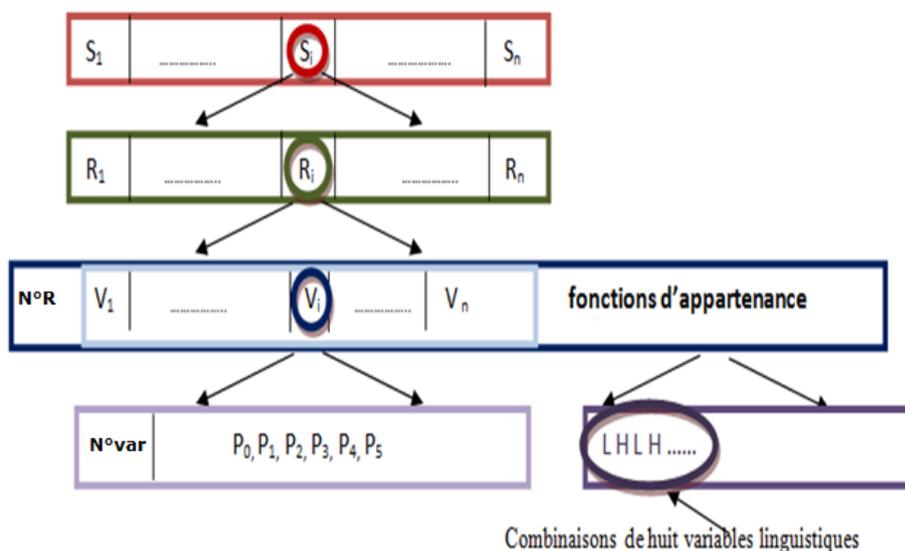


FIGURE 3.2 -- Présentations de paramètres de solutions (Le codage de la solution).

4.2 Fonction objective (fitness)

Pour utiliser un algorithme de clonie d'abeille, on doit disposer d'une fonction objective permettant d'évaluer la qualité d'un individu-solution afin d'identifier le meilleurs individus vis-à-vis du problème donné. La fonction objective dans n'autre cas est de maximiser le nombre d'échantillons correctement classés (NPCC) par la base de règles floues codée dans la ieme solution correspondante :

$$fitnessfunction(U_i) = NPCC(U_i) \dots \dots \dots 3.4$$

Comme condition d'arrêt, nous avons utilisé un nombre maximum de générations. La base de règles est représentée par la meilleure solution avec la meilleure valeur de la fonction objective dans la dernière génération.

4.3 les différents paramètres

les différents paramètres utilisés dans l'algorithme Flou-ABC sont présentés dans le tableau suivant :

Spécification des Paramètres	Valeurs
nombre de règles dans chaque solutions	150
Nombre de sources de nourriture , les abeilles employeurs et spectateurs	300
Nombre maximum des cycles C	10

TABLE 3.2 – Spécification des Paramètres utilisé dans l'application

5 Phase de test et évaluation

Cette phase permet d'affecter un nouveau objet à une classe au moyen d'une règle de décision obtenue durant la phase d'apprentissage. Pour évaluer le classificateur on utilise le critère classique comme

$$Tauxdeclassification = 100 * \frac{(TP + TN)}{Ntotal}$$

Sensibilité : on appelle sensibilité (Se) du test sa capacité de donner un résultat positif quand la maladie est présente. Dans le langage des probabilités, la sensibilité mesure la probabilité conventionnelle que le test soit positif lorsque la maladie est présente. La sensibilité est estimée par la proportion de résultats positifs par suite de l'application du test à un groupe d'individus reconnus comme ayant la maladie.

$$Se = 100 * \frac{VP}{VP + FN}$$

Spécificité : on appelle spécificité (Sp) du test cette capacité de donner un résultat négatif quand la maladie est absente. Dans le langage des probabilités, la spécificité mesure la probabilité conventionnelle que le test soit négatif lorsque la maladie est absente. La spécificité est estimée par la proportion de résultats négatifs conséquemment à l'application du test à un groupe d'individus reconnus comme n'ayant pas la maladie.

$$Sp = 100 * \frac{VN}{VN + FP}$$

Où TP, TN, FP et FN sont notés respectivement :

- TP : diabétique classé diabétique ;
- FP : non diabétique classé diabétique ;

- TN : non diabétique classé non diabétique ;
- FN : diabétique classé non diabétique.

6 les Résultats de l'approche flou-ABC :

La qualité de l'apprentissage augmente avec la taille de l'ensemble d'apprentissage, de même, la précision de l'estimation augmente avec la taille de l'ensemble de test. Mais, dans la pratique, la taille de l'ensemble d'échantillon est limitée. Cette méthode donne de bons résultats lorsque l'ensemble échantillon est "assez" grand. Il existe peu de résultats théoriques sur les tailles d'échantillon nécessaires pour utiliser cette méthode, nous ne disposons que de résultats empiriques qui dépendent du problème (souvent, un centaines d'exemples). La répartition de l'ensemble d'échantillon se fait en général dans des proportions 1/2, 1/2 pour l'ensemble d'apprentissage et de test ou 2/3 pour l'ensemble d'apprentissage et 1/3 pour l'ensemble test. Dans ce qui suit, nous allons présenter les résultats obtenus selon deux modes de partitionnement de la base. Premièrement, nous consacrons deux tiers des échantillons de la base de données à la phase d'apprentissage, et le tiers restant à la phase de test. Ensuite, nous utiliserons une méthode, qui est devenu, très utiles dans les dernières années, c'est la méthode de validation croisée.

6.1 Résultats obtenus

Afin de déterminer la meilleure base de règles, nous avons mené plusieurs exécutions en changeant la fonction d'évaluation et le mode de partitionnement de la base. Pour chaque expérience, la classification a été effectuée avec les mêmes paramètres de l'algorithme de la colonie d'abeille.

Expérimentation 1

Nous utilisons 2/3 de la base pour l'apprentissage et 1/3 pour le test, le taux de classification est utilisé comme fonction d'évaluation la figure 3.3, Les résultats d'apprentissage sont résumés dans le tableau ci-dessous :

Paramètre	Nombre de règles	Taux de classification(%)	Se(%)	Sp(%)
Cycle1	12	74.23	60.43	81.65
Cycle2	12	74.23	60.43	61.65
Cycle3	10	75.0	61.53	82.24
Cycle 4	10	75.0	61.53	82.24
Cycle 5	14	77.69	67.03	83.43
Cycle 6	14	77.69	67.03	83.43
Cycle 7	14	77.69	67.03	83.43
Cycle 8	14	77.69	67.03	83.43
Cycle 9	14	77.69	67.03	83.43
Cycle 10	14	77.69	67.03	83.43

TABLE 3.3 – Résultats d’ Apprentissage - Expérimentation 1-

Les résultats obtenus dans la phase de test sont présentés dans le tableau suivant :

Nombre de règles	Taux de classification (%)	Se(%)	Sp(%)
11	80.30	69.23	84.94

TABLE 3.4 – Résultats du meilleur Taux de classification du Test - Expérimentation 1-

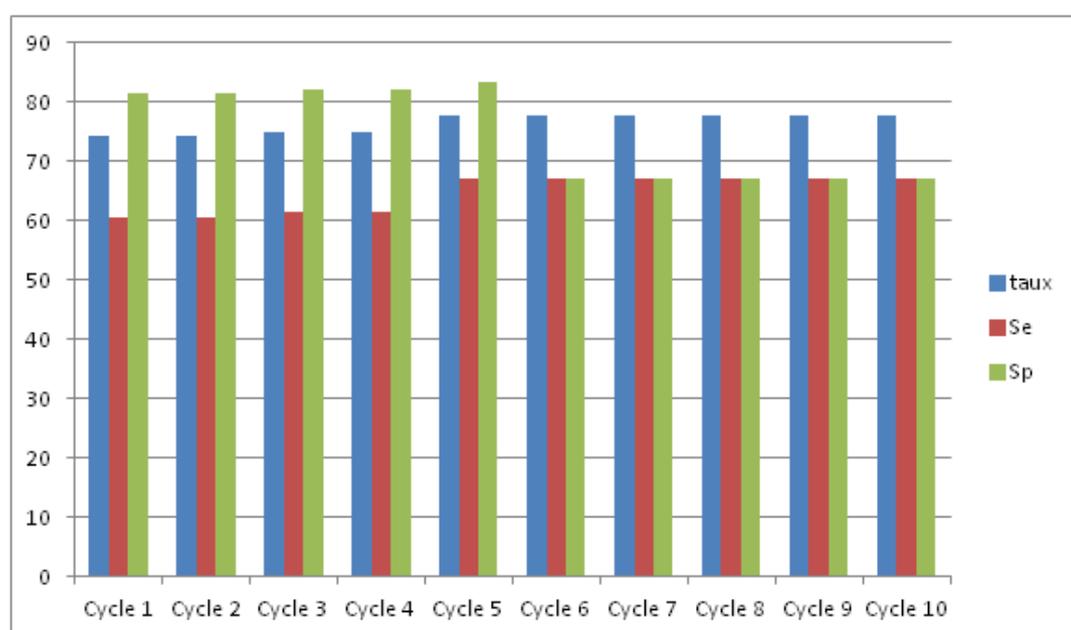


FIGURE 3.3 – - Histogramme des taux obtenus - Expérimentation 1-

Expérimentation 2

Dans cette expérimentation Nous utilisons 2/3 de la base pour l'apprentissage et 1/3 pour le test et en prend en considération le taux de classification et la sensibilité comme fonction d'évaluation la figure 3.4 . Les résultats d'apprentissage (2/3) sont résumés dans le tableau ci-dessous 3.5

Paramètre	Nombre des règles	Taux de classification(%)	Se(%)	Sp(%)
Cycle 1	10	73.07	63.73	78.10
Cycle 2	10	72.30	64.83	76.33
Cycle 3	16	73.07	65.93	76.92
Cycle 4	8	73.08	68.13	75.73
Cycle 5	8	73.08	68.13	75.73
Cycle 6	16	65.38	69.23	63.31
Cycle 7	11	73.46	70.32	75.14
Cycle 8	12	75.76	71.42	78.10
Cycle 9	12	75.76	71.42	78.10
Cycle 10	8	70.0	72.52	68.63

TABLE 3.5 – Résultats d' Apprentissage Expérimentation 2

Les résultats obtenus dans la phase de test sont présentés dans le tableau 3.6

Nombre de règles	Taux de classification(%)	Se(%)	Sp(%)
8	83.33	84.61	82.79

TABLE 3.6 – Résultat meilleur Taux de classification Test - Expérimentation 2 -

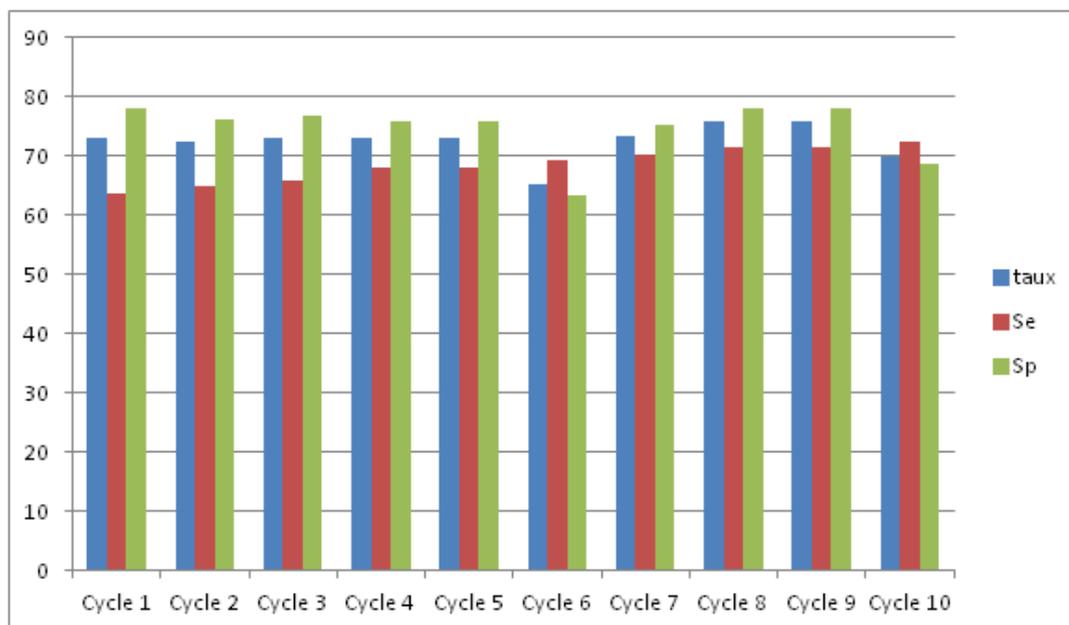


FIGURE 3.4 – Histogramme des taux obtenus Expérimentation 2.

La connaissance extraite du modèle flou-ABC

Le classifieur Flou-ABC génère la meilleure base de connaissances dans la deuxième expérimentation avec 8 règles et un taux de classification de 83.33%. les 8 règles sont :

Règle 1 : Si (Ngross est H) et (Glu est H) et (PAD est L) et (Skin est L) Et (Insulin est L) et(IMC est L) et (PED est L) et (Age est L) Alors (Class est Diabétique)

Règle 2 : Si (Ngross est L) et (Glu est H) et (PAD est L) et (Skin est L) Et (Insulin est H) et(IMC est L) et (PED est L) et (Age est L) Alors (Class est Diabétique)

Règle 3 : Si (Ngross est L) et (Glu est L) et (PAD est L) et (Skin est L) Et (Insulin est L) et(IMC est L) et (PED est L) et (Age est L) Alors (Class est non Diabétique)

Règle 4 : Si (Ngross est L) et (Glu est H) et (PAD est H) et (Skin est L) Et (Insulin est L) et(IMC est L) et (PED est L) et (Age est L) Alors (Class est non Diabétique)

Règle 5 : Si (Ngross est L) et (Glu est H) et (PAD est H) et (Skin est L) Et (Insulin est L) et(IMC est H) et (PED est L) et (Age est L) Alors (Class est Diabétique)

Règle 6 : Si (Ngross est L) et (Glu est H) et (PAD est L) et (Skin est H) Et (Insulin est L) et(IMC est L) et (PED est L) et (Age est L) Alors (Class est Diabétique)

Règle 7 : Si (Ngross est L) et (Glu est H) et (PAD est L) et (Skin est L) Et (Insulin est L) et(IMC est L) et (PED est L) et (Age est H) Alors (Class est non Diabétique)

Règle 8 : Si (Ngross est L) et (Glu est H) et (PAD est L) et (Skin est L) Et (Insulin

est L) et (IMC est L) et (PED est H) et (Age est L) Alors (Class est non Diabétique)

Expérimentation 3

Les meilleurs résultats obtenus avec la 10-Fold Cross Validation. Dans cette méthode la base est divisée en 10 ensembles. Nous utiliserons à chaque fois 9 ensembles pour apprentissage et un ensemble pour test, et à chaque fois on change les ensembles. Le tableau 3.7 illustre ces résultats

Paramètres	Taux de classification (%)
1	74.64
2	79.48
3	82.05
4	74.35
5	74.35
6	79.48
7	82.05
8	76.92
9	77.20
10	76.92
Moyenne	77.75

TABLE 3.7 – Résultats du 10-cross-validations

Nous avons analysé nos expérimentations sur trois aspects :

*Le premier aspect concerne le nombre de règles et en même temps le taux de classification. Ce processus permet de générer un nombre de règles qui varie entre 12 à 14 règles, nous remarquons que le taux de classification varie entre 74% et 77%. Le meilleur cycle qui a obtenu le meilleur taux de classification est le cycle 5(77.69%) sachant qu'il n'y a pas d'amélioration des résultats après ce cycle jusqu'au cycle 10.

*Le deuxième aspect concerne le nombre de règles et en même temps la sensibilité. Ce processus permet de générer un nombre de règles qui varie entre 65% à 75.46% , nous remarquons que la sensibilité varie entre 63% et 72%. Le meilleur cycle qui a obtenu la meilleure sensibilité est le cycle 10(72.62%) sachant même que d'autres cycles comme : cycle 7 et cycle 8 ont donné un taux de classification acceptable.

*Le troisième aspect concerne dix validation croisé, le taux de classification moyen obtenu est 77,75%

*La base de règles extraite par notre approche se compose des règles simples et très conforme avec le raisonnement du médecin.

7 Comparaison des résultats avec l'état de l'art

Comparaison des résultats avec l'état de l'art Les travaux menés sur la classification du diabète, utilisent la base Pima Indian Diabetes, sont présentés et comparés avec notre méthode dans le tableau suivant qui présente le taux de classification obtenu par différents classifieurs.

Methodes	Taux de classification (%)	Auteurs
Fuzzy-AIRS [PG07]	75.87	Polat et al. (2007)
GDA-LSSVM [KPA08]	79.16	Polat et al. (2008)
Fuzzy Modeling [GL08]	77.65	Ghazavi et al. (2008)
BGA-Fuzzy-KNN [TT09]	81.6	Tand et al. (2009)
RGA-Fuzzy-KNN [TT09]	82	Tand et al. (2009)
ML-NN [HTT09]	79.62	Temurtas et al. (2009)
PNN [HTT09]	78.05	Temurtas et al. (2009)
GA-Fuzzy classifieur [GA11]	71.49	Guzaitis et al. (2009)
ACO-Fuzzy classifieur [GA11]	79.48	Ganji et al. (2011)
PSO-Fuzzy classifieur	80.76	Beloufa et al. (2012)
ABC-Fuzzy classifieur	83,33	Notre méthode

TABLE 3.8 – Taux de classification obtenus avec notre modèle et autres classifieurs de la littérature

8 Conclusion

Cette étude présente un modèle de classification flou du diabète où l'ABC a été utilisé comme un algorithme évolutionnaire pour générer le nombre approprié de règles floues optimisé. Les résultats obtenus indiquent une très bonne performance de l'hybridation ABC-Flou. La méthode proposée a été comparée avec d'autres méthodes dans la littérature. Le taux de reconnaissance que nous avons obtenu est compétitif voir meilleur que ceux obtenus dans plusieurs travaux de recherche.

Conclusion générale et perspectives

Le diabète est l'une des maladies les plus dangereuses et les plus répandus dans le monde, connu aussi avec le nom de "tueur silencieux". C'est une maladie chronique incurable causée par une carence ou un défaut d'utilisation de l'insuline entraînant un excès de sucre dans le sang.

Ce travail présente une nouvelle méthode dite hybride flou-évolutionnaire pour la classification et la reconnaissance des patients qui présente des cas diabétiques. Cette technique hybride que nous avons implémenté est une méthode qui combine les systèmes d'inférence floue et l'algorithme de colonie d'abeilles dans un même système pour tirer les points forts de chaque méthode (la capacité d'optimisation des modèles évolutionnaire et la facilité d'interprétation de la logique floue).

Le modèle implémenté a donné des résultats très satisfaisants en comparant avec d'autres travaux cités avant, avec un taux de classification globale estimé à 83,33 %.

La validation de nos résultats a été faite en utilisant la base de données universelle PID (Pima Indian Diabete). Toutefois, cette technique floue-évolutionnaire permet de générer une base de connaissances (Base de règles) pour justifier la réussite ou l'échec de la classification, ce qui constitue un avantage de marque par rapport aux classifieurs de type boîte noire comme les réseaux de neurones.

Les résultats obtenus sont très prometteurs car les règles extraites sont très conformes avec le raisonnement du médecin, et confirment que cette méthode hybride a permis d'exploiter les capacités d'apprentissage et d'optimisation des méthodes évolutionnaires d'une part, ainsi que l'interprétation des connaissances des systèmes d'inférence floue.

Comme perspectives à ce travail, nous proposons :

- D'élargir la base de données pour englober d'autres types de cas diabétiques pour augmenter la qualité d'apprentissage.
- Constituer une base de données 100 % locale pour faire des études destinées à être exploitées par notre équipe de recherche en génie biomédical.
- Intégrer de nouveaux paramètres représentatifs pour avoir une bonne caractérisation du diabète.

Et pour avoir une caractérisation représentative, pertinente et plus proche du langage du médecin il faut :

- Utiliser d'autres sources de données physiologiques en relation avec le diabète (comme la tension artérielle ou la température).
- Intégrer des connaissances humaines (par exemple les remarques prises par le

médecin lors du discussion avec le patient) dans la base de connaissance extraite automatiquement pour améliorer le diagnostic.

Bibliographie

- [AA04] A.Idri and A. Abran. La logique floue appliquée aux modèles d'estimation d'effort de développement de logiciels-cas du modèle coco-mo'81. *Presses polytechniques et universitaires romandes, Lausannel, 2004.*
- [AM04] Coloni A and Dorigo ANDV. Maniezzo M. *The Ant System : Optimization by a colony of cooperating agents. Transactions on Systems.* 2004.
- [BDT99] E Bonabeau, M Dorigo, and G Theraulaz. *Swarm intelligence : From natural to artificial systems. Oxford University Press, NY, 1999.*
- [Bee08] Lew J.B. Beekman, M. Foraging in honeybees when does it pay to dance. *Behavioral Ecology* 19, page 255–262, 2008.
- [BR00] M Beekman and F.L.W. Ratnieks. Long range foraging by the honeybee *apis mellifera*. *Functional Ecology*, page 490–496, 2000.
- [cgw97] d charles, p gueye, and wade.b. le diabète du sujet age a propos de 52 observations consécutives. *Médecine d'Afrique Noire*, 1997.
- [cwr87] craig w. reynolds. a distributed behavioral model. *computer graphics*, page 21(4) :25–34, 1987.
- [DB02] Karaboga Dervis and Akay Bahriye. *A comparative study of Artificial Bee Colony algorithm.* PhD thesis, Erciyes University, The Department of Computer Engineering, Melikgazi, 38039 Kayseri, Turkey, 2002.
- [Dia02] OMS Diabète. Le coût du diabète. *Technical report, Aide-mémoire*, page No.236, 2002.
- [GA11] M.F. Ganji and M.S. Abadeh. A fuzzy classification system based on ant colony optimization for diabetes disease diagnosis. *Expert System with Application* 38, pages 14650–14659, 2011.
- [GL08] S.N. Ghazavi and T.W. Liao. Medical data mining by fuzzy modeling with selected features. *Artificial Intelligence in Medicine*, pages 195–206, 2008.
- [God99] J. Godjevac. *Idées nettes sur la logique floue. Presses polytechniques et universitaires romandes, Lausannel, 1999.*
- [Gol89] D. E. Goldberg. *Genetic Algorithms.* Adison-Wesley, 1989.
- [hg90] f heppner and u grenande. a stochastic nonlinear odel for coordinated bird flocks. *aaas publication, washington*, page 21(4) :25–34, 1990.
- [Hol92] J. H. Holland. *Adaptation in natural and artificial systems.* MIT Press, 1992.

- [HTT09] N. Yumusak H. Temurtas and F. Temurtas. A comparative study on diabetes disease diagnosis using neural networks,. *Expert systems with applications*, pages 8610– 8615, 2009.
- [Hue03] . Huet. *Les métaheuristiques inspirées du vivant*. Ingénieur CNAM. PhD thesis, Clermont Ferrand. France, 2003.
- [HYT09] N H.Temurtas, F Yumusak, and A Temurtas. A comparative study on diabetes disease diagnosis using neural networks. expert systems with applications. *Expert Systems with Applications*, pages 36,8610–8615., 2009.
- [J] Hopfield J. Neural networks and physical systems with emergent collective computational abilities. *l'Université Abou Bekr Belkaid -Tlemcen- , Faculté des sciences de l'ingénieur Electronique biomédicale*.
- [Jan93] J.R. Jang. "anfis : adaptive-netwok-based fuzzy inference system. *IEEE Trans,Syst., Man, Cybern*, pages 3, pp. 665–685, 1993.
- [JC95] Jang J.S.R and Sun C.T. "neuro-fuzzy modeling and control. *Proc. IEEE, vol*, 1995.
- [Kar05] D. Karaboga. An idea based on honey bee swarm for numerical optimization. *Technical Report TR06, Erciyes University, Engineering Faculty, Computer Engineering Department*, 2005.
- [kF67] k.von Frisch. The dance language and orientation of bees. *Harvard University Press*, 1967.
- [Kos92] B. Kosko. Neural networks and fuzzy systems : A dynamical systems approach. *Englewood Cliffs, NJ : Prentice Hall*, 1992.
- [KPA08] S. Gunes K. Polat and A. Arslan. A cascade learning system for classification of diabetes disease : Generalized discriminant analysis and least square suport vector machine. *Expert Systems with Applications*, pages 482–487, 2008.
- [KS98] Passino K.M and Yurkovich S. Fuzzy control. *Addison-Wesley Longman Inc*, 1998.
- [Lan04] Guillaume Lange. L'âge moyen de découverte du diabète de type 2 diffère significativement selon la catégorie sociale. *Thèse pour le doctorat en médecine (diplôme d'état). Université paris 7 – Denis Diderot. Faculté de médecine Xavier Bichat*, page 22, 2004.
- [L.X94] Wang L.X. Adaptive fuzzy systems and control : Design and stability analysis. *Prentice-Hall, Englewood Clifs, NJ*, 1994.
- [Men95] J. M. Mende. Fuzzy systems for engineering :. *Proc. IEEE*, pages 347–377, 1995.
- [Mer04] SAIDI Meryem. Traitement de données médicales par un système immunitaire artificiel reconnaissance automatique du diabète. *Revue Française pour une soutenance de thèse bien arro... réussie*, 2004.
- [MFMS11] Ganji Mostafa Fathi and Abadeh Mohammad Saniee. *A fuzzy classification system based on Ant Colony Optimization for diabetes disease diagnosis*. PhD thesis, a Faculty of Electrical and Computer Engineering, Tarbiat Modares University (TMU), Iran, Jalal Ale Ahmad, 2011.

- [MS07] H.R Mattila and T.D. : Seeley. Genetic diversity in honey bee colonies enhances productivity and fitness. *Science* 1, pages 317, 362–364, 2007.
- [OF07] B.P Oldroyd and J.H Fewell. *Genetic diversity promotes homeostasis in insect colonies*. Trends in Ecology and Evolution, 2007.
- [PG07] K. Polat and S. Gunes. An improved approach to medical data sets classification : artificial immune recognition system with fuzzy resource allocation mechanism. *Expert Systems with Applications*, pages 252–270, 2007.
- [PGA07] K.]Polat, S Gunes, and A. Arslan. cascade learning system for classification of diabetes disease : Generalized discriminate analysis and least square support vector machine. *Expert Systems with Applications*, 34, 482–487., 2007.
- [PIM] PIMA. The pima indian pathfinders for health. <http://diabetes.niddk.nih.gov/dm/pubs/pima/index.htm>.
- [R] Benali R. Modèle hybride neuro-flou pour la reconnaissance des arythmies cardiaques. *l'Université Abou Bekr Belkaid -Tlemcen-, Faculté des sciences de l'ingénieur Electronique biomédicale*.
- [S98] Labiod S. Commande adaptative par systèmes flous : application aux robots manipulateurs. *Thèse de Magister*, 1998.
- [S04] LABIOD S. ontribution à la commande adaptative floue des systèmes non linéaires. *docteur en Automatique de l'ENP*, 2004.
- [See95] T. D. Seeley. The wisdom of the hive. *Harvard University Press, Cambridge, MA*, 1995.
- [Ter00] V. Tereshko. Reaction–diffusion model of a honeybee colony's foraging behaviour. *Lecture Notes in Computer Science*, page 807–816, 2000.
- [TFA07] Walid TFAILI. *Conception d'un algorithme de colonie de fourmis pour l'optimisation continue dynamique*. PhD thesis, L'UNIVERSITÉ PARIS 12-VAL DE MARNE UFR de Sciences et Technologie, 2007.
- [TL] V Tereshko and A Loengarov. Collective decision-making in honey bee foraging dynamics. *Computing and Information Systems Journal*, pages 1352–9404.
- [TM] Takagi T. and Sugeno M. Fuzzy identification of systems and its applications to modelling and control, *iee trans. syst., man, cybern.*
- [TRS96] J Tautz, K Rohrseitz, and Sandeman. D.c. : One-strided waggle dance in bees. *Nature*, page 32, 1996.
- [TT09] P.H. Tand and M.H. Tseng. Medical data mining using bga and rga for weighting of features in fuzzy k-nn classification. *Proceedings of the Eighth International Conference on Machine Learning and Cybernetics*, pages 3070–3075, 2009.
- [TYT07] H Temurtas, N Yumusak, and F. Temurtas. A comparative study on diabetes disease diagnosis using neural networks. *Expert Systems with Applications*, ., 2007.
- [Zad65] L.A. Zadeh. Fuzzy sets. *Information and Contro*, (69) :338–353l, 1965.