

DETECTION AUTOMATIQUE DE LA PRESENCE D'ANOMALIE SUR UNE MAMMOGRAPHIE PAR RESEAU DE NEURONES ARTIFICIELS

M. BOUKHOBZA & M .MIMI

Laboratoire Signaux et Applications. Département électronique.
Faculté des Sciences et de la Technologie
Université Abdelhamid Ibn Badis de Mostaganem l'UABM. Algérie.
elhabibmohamed1@gmail.com , mimi_malika2001@yahoo.fr

ABSTRACT

The breast cancer continues to be classified in the forefront of the public health problems. Proliferations of this disease push the researchers to develop techniques of assistance of diagnosis. The medical imagery constitutes an important technique for assured a better quality the clinical diagnosis. Remain the problem of the quality of the interpretation of the medical image. The tracing routines organized of the breast cancer led to an increase amongst medical image interpreted and the needs for quality as regards public health make compulsory the recourse to the Assistance Systems Diagnosis (ASD) by computer. In this article we propose a system containing network of artificial neurons able to detect the presence or not anomaly on a mammography.

KEYWORDS: Mammography, Detection, artificial Network of neurons, Assistance Systems Diagnosis.

RÉSUMÉ

Le cancer du sein continue de se classer au premier rang des problèmes de santé publique. La prolifération de cette maladie à pousser les chercheurs à développer des techniques d'aide au diagnostic. L'imagerie médicale constitue une technique importante pour assurer une qualité meilleure du diagnostic clinique. Reste le problème de la qualité de l'interprétation de l'image médicale. Les programmes de dépistage organisés du cancer du sein, conduit à une augmentation du nombre d'images médicales a interprété et les besoins de qualité en matière de santé publique rendent obligatoire le recours aux systèmes d'aide au diagnostic (SAD) par ordinateur. On propose dans cet article un système à base de réseau de neurones artificiels capables de détecter la présence ou non d'anomalie sur une mammographie.

MOTS-CLÉS: Mammographie, Détection, Réseau de neurones artificiel, Systèmes d'aide au diagnostic.

1 INTRODUCTION

Dans cet article, nous allons étudier la problématique de la détection de la présence ou non d'anomalie dans une mammographie en utilisant un modèle de calcul à base de réseau de neurones artificiels.

Le cancer du sein est la seconde cause de décès des femmes à travers le monde. Toute femme a une chance sur huit de développer un cancer du sein durant sa vie [1]. La mammographie est la méthode la plus efficace pour la détection précoce des maladies du sein [2].

La mammographie est une image radiographique du sein réalisée par un appareil spécifique appelé mammographe. La construction de l'image se fait par absorption de rayons X.

Les radiologues sont toujours obligés d'examiner très finement l'image pour faire un meilleur diagnostic. D'où l'importance des systèmes d'aide au diagnostic (SAD) par ordinateur développés durant ces vingt dernières années. Plusieurs techniques de traitement d'images ont été proposées. Ces méthodes se résument dans la plupart des cas en 3 étapes [3]. La première est la détection des anomalies. Plusieurs techniques sont utilisées pour réaliser cette étape parmi lesquelles nous citons la transformée en ondelette, la seconde étape est consacrée à l'extraction des paramètres de classification telle que la forme, la taille et la densité. La dernière étape est dédiée à l'interprétation des anomalies suspectes. Plusieurs techniques sont utilisées telles que celles basées sur les réseaux de neurones artificiels, celles basées sur la logique floue, celles basées

sur les machines à vecteur de supports et d'autres architectures hybrides qui intègrent ces outils. Bien que ces métaphores réalisent la tâche d'interprétation avec un certain succès [4]. Par contre, dans notre travail on cherche à utiliser les réseaux de neurones artificiels dans la détection de la présence d'anomalie dans une mammographie, ceci signifie la réalisation de la première étape par les réseaux de neurones artificiels.

2 RÉSEAUX DE NEURONES ARTIFICIELS (RNA)

Depuis une dizaine d'années, l'utilisation des réseaux de neurones artificiels (RNA) s'est développée dans de nombreuses disciplines (sciences économiques, écologie et environnement, biologie et médecine...). Ils sont notamment appliqués pour résoudre des problèmes de classification, de prédiction, de catégorisation, d'optimisation, de reconnaissance [5]. Les Réseaux de Neurones Artificiels (RNA) sont inspirés de la biologie et représentent un modèle mathématique du fonctionnement du neurone biologique [6]. Dans un réseau de neurones artificiels, chaque neurone est inter-connecté avec d'autres neurones pour former des couches dans le but est de résoudre un problème spécifique sur les données fournies en entrée du réseau [7]. Une fois le réseau formé on injecte des entrées et on lance l'apprentissage du réseau pour estimer ces paramètres [8]. Il existe essentiellement deux types d'apprentissage, l'apprentissage non supervisé et l'apprentissage supervisé. Pour l'apprentissage non supervisé, des exemples sont présentés au réseau qu'on laisse s'auto-organiser. Dans le cas de l'apprentissage supervisé, on cherche à imposer au réseau un fonctionnement donné. Les paramètres du réseau sont ajustés à partir des couples entrées sorties présentés [9].

Un RNA est composé de trois types de couche: La couche d'entrée est responsable de la saisie des données pour le réseau. La couche de sortie permet de restituer les résultats calculés par le réseau.

Entre l'entrée du réseau et sa sortie des couches intermédiaires peuvent se présenter, elles sont appelées des couches cachées. Le rôle de ces couches est de transformer les données d'entrée pour en extraire des caractéristiques qui seront par la suite utilisées par la couche de sortie.

Un RNA opère en deux phases consécutives: une phase de conception et une phase d'utilisation. La première phase consiste à choisir l'architecture du réseau et ses paramètres à savoir le nombre de neurones et le nombre de couches cachées et les fonctions de transfert de chaque couche. Une fois ces choix sont fixés, on peut entraîner le réseau. Au cours de cette phase, les poids des connexions du réseau et le seuil de chaque neurone seront modifiés pour pouvoir s'adapter à différentes conditions d'entrée.

Dans la phase d'apprentissage on utilise l'algorithme de LEVENBERG-MARQUARDT (LM)

On Initialiser μ a une valeur proposée 0.1, à l'itération i on applique les étapes suivantes :

- calculer $J(w(i))$ avec μ_i déterminé à l'étape précédente.
- si $J(w(i)) < J(w(i-1))$, alors accepter le changement des paramètres et multiplier μ_i par r .
- sinon récupérer $w(i-1)$ et diviser μ_i par r . Répéter cette dernière étape jusqu'à ce qu'une valeur de μ_i corresponde à une décroissance de J soit trouvé [7].

Tel que :

- $r > 1$ (un facteur généralement égal à 10).
- μ : pas d'apprentissage tel que $0 < \mu < 1$.
- W : vecteur des poids.
- J : la fonction de cout.

Une fois l'apprentissage du réseau est terminé, il passe en phase d'utilisation pour réaliser le travail pour lequel il a été conçu. Dans la plupart des travaux effectués, ils ont utilisé des réseaux multicouches à apprentissage supervisée [9].

3 BASE D'IMAGES

Mammographic Image Analysis Society (MIAS) [10] est un groupe de chercheurs britanniques qui s'intéressent à la compréhension de la mammographie. MIAS a généré une base de données de mammographies numérisées avec une résolution de 200 μm par pixel. Chaque image est de 1024 x 1024 pixels et chaque pixel est représenté avec un mot de 8 bits. On a utilisé 60 images réparties en 30 images normales et 30 images incluant des anomalies. Ces anomalies ont été identifiées par des radiologues experts.

4 CONCEPTION DU SYSTÈME

Dans ce travail on applique des techniques capables de détecter la présence ou non d'anomalie sur des mammographies, on a utilisé 60 images on les répartie en deux ensembles le premier ensemble d'images est utilisé pour l'apprentissage du système le deuxième ensemble sert au test du système. Voici les étapes à suivre pour la conception du système d'aide au diagnostic à base de réseau de neurones:

4.1 Etape 1 : Division de l'image en blocs

Au début on effectue un prétraitement, on subdivise chaque image en un ensemble de sous-images. On note le nombre de sous image par k . Cette subdivision nous permet de parcourir l'ensemble des pixels de chaque image.

On a divisé l'image en blocs de $n \times n$ pixels. Chacun de ces blocs représente une sous-image.

Dans notre étude on a choisi 3 tailles différentes, afin d'observer l'influence de la taille des sous-images sur la performance du système d'aide au diagnostic à base de réseau de neurones figure (1).

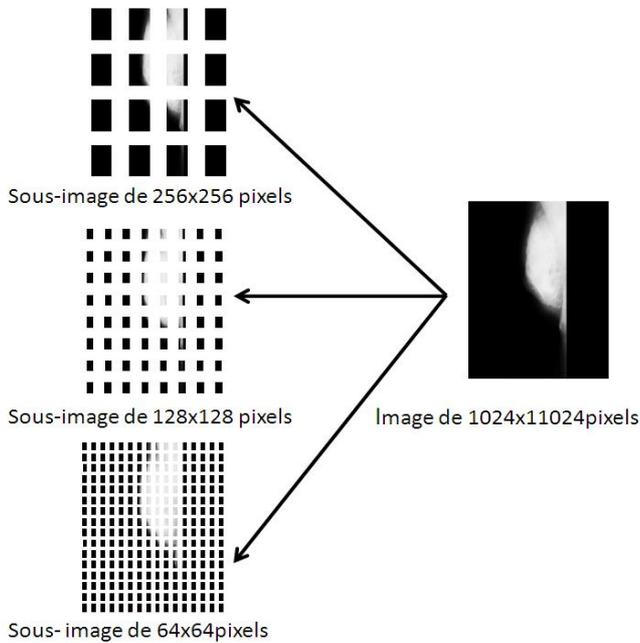


Figure1: mammographie subdiviser en sous-image

Chaque image possède les caractéristiques suivantes :

- Image de 1024 x 1024 pixels.
- Une résolution de 200 µm par pixel.

4.2 Etape 2. Calcul de la moyenne

Ensuite on effectue l'extraction des paramètres associés à cet ensemble de sous-images. À partir de chaque sous-image on calcule la valeur moyenne du niveau de gris \bar{I} .

$$\bar{I} = \frac{1}{l * c} \sum_{ij} I(i, j) \tag{1}$$

l et c représente respectivement le nombre de ligne et de colonne de chaque sous image $I(i, j)$ représente la valeur du niveau de gris du pixel (i, j) tel que i varie de 1 jusqu'à l et j varie de 1 jusqu'à c .

A ce niveau chaque image est divisée en un nombre k de sous-images. Et pour chaque sous image on calcule la valeur moyenne du niveau de gris, donc pour chaque image on obtient K paramètres descriptifs, ce nombre varie suivant la taille des sous-images utilisées.

Tableau 1 : Nombre de paramètres associé à chaque taille de sous-image

Taille des sous-images	K nombre de paramètres
256x256 pixels	16
128x128 pixels	64
64x64 pixels	256

L'augmentation de la valeur de k engendre l'augmentation des paramètres injectés dans le réseau de neurones artificiels.

4.3 Etape 3 : Configuration du réseau de neurones

La configuration du réseau de neurones a été l'étape cruciale dans l'élaboration de notre système. La recherche bibliographique sur les études menées dans ce domaine suggère l'adoption d'un réseau de neurones multicouches [3],[4]. Pour ne pas augmenter la complexité du réseau, nous avons décidé d'utiliser une seule couche cachée. Le réseau de neurones de notre application est composé de trois couches :

- une couche d'entrée.
- une couche cachée.
- une couche de sortie.

La couche d'entrée du réseau sert à intégrer des paramètres descriptifs extraits des mammographies, la couche de sortie permet d'identifier la présence ou non d'anomalie. Le rôle de la couche cachée est d'effectuer des traitements sur les données d'entrée en utilisant des fonctions de transfert et un nombre de neurones cachés nécessaires afin d'atteindre ou approcher l'objectif désire, ce traitement nous permet d'extraire des données qui seront par la suite utilisées par la couche de sortie. Le nombre de neurones en couche d'entrée dépend du nombre de paramètres descriptifs utilisé, puisqu'on a calculé la valeur moyenne du niveau de gris de chaque sous-image donc on doit utiliser k neurones d'entrées : $E1, \dots, Ek$. Le nombre de neurones de sortie est fixé à une seule sortie "S", puisqu'on cherche à détecter la présence ou non d'anomalie sur chaque image, tel que :

$S=1 \rightarrow$ Présence d'anomalie.

$S=0 \rightarrow$ Absence d'anomalie.

Le nombre de neurones en couche cachée et les fonctions d'activation ont été choisies expérimentalement ; on a opté pour le modèle le plus performant.

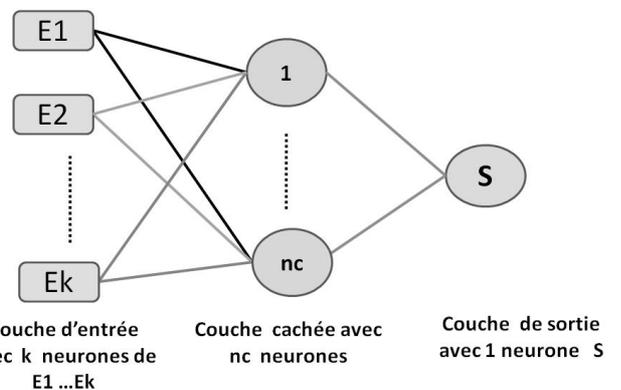


Figure 2: Conception du réseau de neurones spécialisé dans la détection d'anomalie sur une mammographie

"nc" indique le nombre de neurones en couche cachée. Le réseau a été expérimenté en variant "nc", figure (2).

Trois fonctions de transfert seront envisagées : deux fonctions sigmoïdes, l'une à sortie positive et négative 'tansig', figure (3). L'autre à sortie uniquement positive 'logsig', figure (4), et une fonction linéaire 'purelin', figure (5) telles que :

$$\text{Tansig} : a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (2)$$

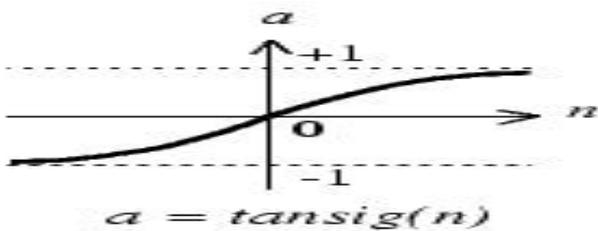


Figure 3: Fonction de transfert tansig

$$\text{Logsig} : a = \frac{1}{1 + e^{-n}} \quad (3)$$

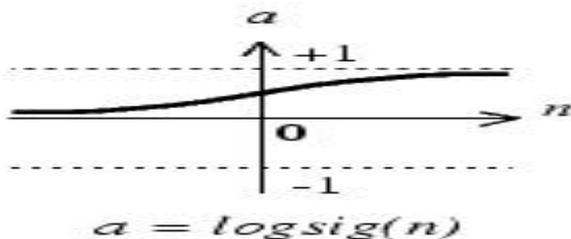


Figure 4: Fonction de transfert logsig.

Le choix des fonctions sigmoïdes est justifié puisque, les réseaux de neurones, notamment à fonction d'activation sigmoïde, sont d'autant plus avantageux que le nombre de variables est grand ; dans la majorité des cas « grand » signifie, en pratique et de manières empiriques, supérieures ou égales à 3 [8].

$$\text{Purelin} : a = n \quad (4)$$

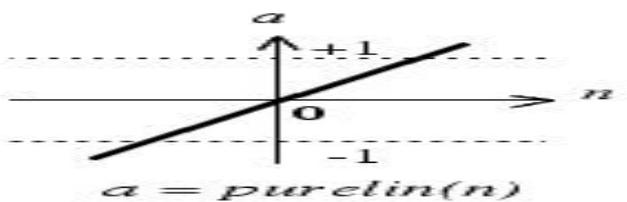


Figure 5 : Fonction de transfert purelin

4.4 Etape 4 : Critères de performance du réseau de neurones

Afin d'observer les performances de chaque réseau de neurones, on compare les états calculés par le réseau de neurones avec les états réels. La performance est calculée en pourcentage. Les tests sont faits sur 12 images, ces images ne doivent pas être les mêmes utilisées dans l'apprentissage. Le taux de reconnaissance est défini comme étant le rapport entre le nombre des cas reconnus correctement et le nombre des cas présentés pour le test du système [11].

$$\text{Taux de reconnaissance} = \frac{\text{Bonnes décisions}}{\text{Nombre total d'exemples}} * 100 \quad (5)$$

On choisit le réseau le moins complexe en cas d'égalité des performances.

4.5 Etape 5: Apprentissage du réseau par l'algorithme LM

On effectue un apprentissage supervisé par l'algorithme de LEVENBERG-MARQUARDT (LM) pour chaque configuration, avec les paramètres suivants :

- Nombre maximum d'itérations (Epochs) = 100.
- Gradient minimum = 1 e-10.

L'apprentissage est arrêté si l'une de ces conditions est satisfaite. On a utilisé 48 images pour l'apprentissage du réseau et 12 images pour le test du réseau.

4.6 Etape 6 : Résultat de la méthode

Le tableau suivant nous permet d'observer l'influence de la taille des sous-images sur la performance du système

Tableau 2: Taux de reconnaissance du système associé à chaque de sous-image

Taille des sous-images	Taux de reconnaissance
256x256 pixels	50 %
128x128 pixels	83.33 %
64x64 pixels	91.66 %

On observe du tableau 2 que la diminution de la taille des sous-images engendre une augmentation du taux de reconnaissance. Le meilleur taux de reconnaissance obtenue est de 91.66 % réalisés avec une taille de sous image de 64x64 pixels. Le réseau de neurones sélectionné possède les caractéristiques suivantes: 'purelin' en couche cachée et 'logsig' en sortie et avec 13 neurones cachés et 64 neurones d'entrées, 1 neurone de sortie ce qui justifie le choix du modèle de la figure (6).

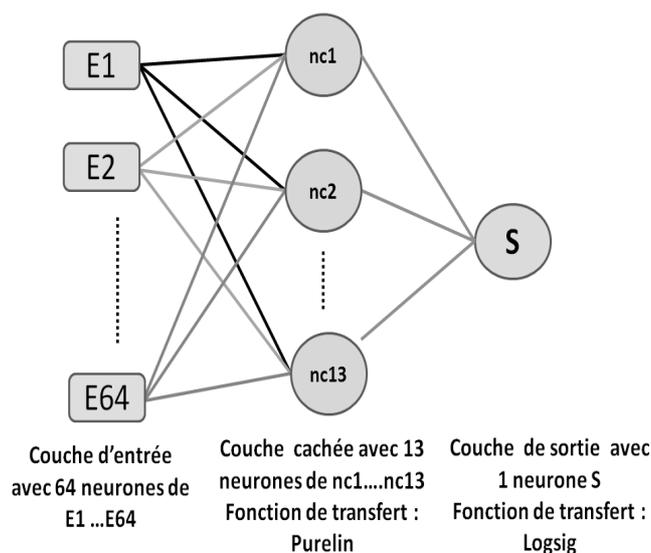


Figure 6: Réseau de neurone sélectionné

Dans la phase de test on a injecté au réseau sélectionné des paramètres associés aux images de l'ensemble test qui est constitué de 12 images non utilisées dans la phase d'apprentissage, pour voir l'aptitude du réseau à détecter la présence ou non d'anomalie sur les mammographies de l'ensemble test.

Pour l'ensemble de test on a utilisé 12 mammographies qui représentent les caractéristiques suivantes:

- 6 mammographies normales
- 6 mammographies présentent des anomalies avec un rayon approximatif du cercle entourant l'anomalie de 20 à 54 pixels.

Notre réseau est capable de détecter la présence de l'anomalie sans classification du type de l'anomalie.

Sur les 12 cas de test le réseau de neurones artificiels sélectionné a correctement reconnu 11 cas d'où un taux de réussite de 91.66 % et un taux d'échec de 8.34 %, figure (7).

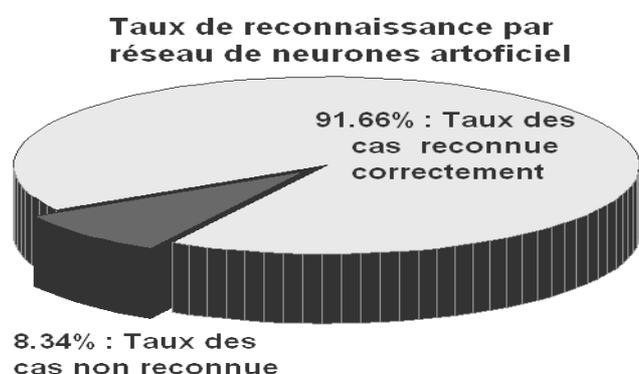


Figure 7: Taux de reconnaissance par le système d'aide au diagnostic à base de réseau de neurones.

L'essai du système avec une taille de sous-image inférieure à 64x64 pixels pénalise le délai de conception du réseau de neurones. Notre système à base de réseau de neurones artificiels possède les avantages suivants:

- Simplicité de l'extraction des paramètres descriptifs de chaque mammographie.
- Détection automatique et rapide de la présence ou non d'une anomalie sur une mammographie par le réseau de neurones artificiels.
- Possibilité d'adapter le système à d'autres images provenant de différentes bases médicales avec différentes résolutions.

Mais ce système à généré 8.34 % de cas d'échec sont essentiellement dû à la séparabilité interclasse plus ou moins faible puisqu'on veut séparer deux classes la première classe représente les états normaux et la deuxième classe, est celle des cas d'anomalie.

La base de données doit être également enrichie pour couvrir une vaste gamme de cas.

D'autre part, dans cette étude, nous avons utilisé toute l'image pour extraire des paramètres pour les employer comme vecteur entrée du réseau de neurones artificiel, or, une autre voie pourrait être suivie en limitons les zones de l'image à traiter et en appliquons d'autres techniques de traitement d'images, afin de réduire la taille du vecteur d'entrée, optimiser le temps de calcul et augmenter le taux de reconnaissance.

Les travaux accomplis dans ce domaine [3], [4] on effectuée un classement des types d'anomalie, mais notre étude nous a permis de développer un réseau de neurones capable de détecter la présence ou non d'anomalie avec un taux de réussite important, ce modèle représente un intérêt, en particulier dans les cas de dépistage systématique ce qui engendre un nombre important d'images à interpréter. Ce système permet au radiologue de concentrer son attention sur les cas les plus difficiles.

5 CONCLUSION

On a prouvé l'efficacité des RNA pour la détection de la présence ou non d'anomalie sur une mammographie avec un taux de reconnaissance correcte de 91.66 %.

De plus cette étude a démontré l'influence du choix de la taille des sous images et le nombre de neurones, les fonctions de transferts utilisées sur l'efficacité du réseau de neurones artificiels.

Les réseaux de neurones artificiels peuvent être utilisés pour la conception des Systèmes d'Aide au Diagnostic (SAD) par ordinateur.

Le principal avantage des réseaux de neurones artificiels résident dans:

Leur capacité d'apprentissage automatique, ce qui permet de résoudre des problèmes sans nécessiter d'écriture de règles complexes.

En perspective, nous comptons :

- Valider notre approche en utilisant des images provenant de diverses bases médicales avec différentes résolutions.
- Améliorer le taux de reconnaissance.

BIBLIOGRAPHIE

- [1] Al Mutaz M. Abdalla, Safaai Dress, Nazar Zaki , " Detection of Masses in Digital Mammogram Using Second Order Statistics and Artificial Neural Network", International Journal of Computer Science & Information Technology (IJCSIT), Vol 3, No 3, June 2011, pp. 176-186.
- [2] Liyakathunisa & C.N. Ravi Kumar, " A Novel and Efficient Lifting Scheme based Super Resolution Reconstruction for Early Detection of Cancer in Low Resolution Mammogram Images" ,International Journal of Biometrics and Bioinformatics (IJBB), Volume (5) : Issue (2) : 2011 , pp 53-75.
- [3] N.Ben Hamad, N. Benromdhane, K. Taouil, M.S. Bouhlel, " Réduction des Faux Positifs dans les Systèmes d'Aide au Diagnostic du Cancer du Sein", SETIT 2007 4th International Conference: Sciences of Electronic, Technologies of Information and Telecommunications, Tunisia ,2007.
- [4] H.Boufera, F. Bendella, " Interprétation automatique des anomalies de mammographie numérique", Département d'Informatique, USTO-MB-Algérie, journée Jeesi09, 2009.
- [5] Drew P.J.Monson (J.R.T), "Artificial neural networks, Surgery volume 127, 2000, pp. 3-11.
- [6] J-F. Jodouin, Les réseaux de neurones. Edition Hermès, Paris, 1994.
- [7] N. Benamrane, A. Aribi, L. Kraloua, A.Fréville, " Interprétation des images médicales par une approche neuro-flou-génétiques", In: 6^{ème} Conférence Francophone de Modélisation et Simulation. MOSIM06, Rabat, Maroc, 2006.
- [8] G.Dreyfus et autres, Réseaux de neurones méthodologie et application, édition EYROLLES, Paris, 2004.
- [9] P.Borne, M. Benrejeb, J. Haggege, Les réseaux de neurones présentation et application, édition TECHNIP, Paris, 2007.
- [10] <http://peipa.essex.ac.uk/info/mias.html>.
- [11] G.Tremblay, " Optimisation d'ensembles de classifieurs non paramétriques avec apprentissage par représentation partielle de l'information", Ecole de technologie supérieure.