

CLASSIFICATION DES SIGNAUX ECG BASEE SUR LA TRANSFORMEE EN ONDELETTES ET LES RESEAUX DE NEURONES A APPRENTISSAGE SUPERVISE ET NON SUPERVISE

Mounia Hendel¹, Abdelkader Benyettou¹, Hendel Fatiha², KHELIL Hiba¹.

¹ Université des Sciences et de Technologie d'Oran Département d'informatique, laboratoire de recherche SIMPA, BP 1505 El M'nouar, Oran Algérie

² Université des Sciences et de Technologie d'Oran Département d'électronique, laboratoire de recherche en systèmes intelligents ; El M'nouar BP 1505, Oran Algérie

Mounia_90@hotmail.com



RESUME. Dans cet article, nous proposons de mettre au point un système d'aide au diagnostic des anomalies des signaux cardiaques (ECG). Ce système est basé sur la transformée en ondelettes et la combinaison des réseaux de neurones artificiels à apprentissage supervisé et non supervisé. Le premier réseau est constitué d'une carte SOM (Self Organizing Map) qui permet d'effectuer une pré classification, il reçoit en entrée 15 paramètres statistiques calculés à partir des coefficients de la transformée en ondelettes, en plus de deux intervalles RR relatives au signal original. Le second réseau est de type MLP (Multi layer Perceptron) chargé de la classification finale, il reçoit en entrée les sorties de la carte de Kohonen. Quatre types d'arythmies sont considérées dans cette étude : Extrasystole Ventriculaire(EV), Extrasystole Auriculaire (EA), Bloc de Branche Droit (BBD), et Bloc de Branche Gauche (BBG), en plus du battement normal (N). Notre système a été validé sur des signaux ECG des différents patients extraits de la base de données «MITBIH ».

L'évaluation des performances du système proposé, est basée sur la sensibilité (SE), la spécificité (SP), la prédictivité (PP) et le taux de classification correcte (CC). Les résultats obtenus sont très satisfaisants.

ABSTRACT. In this paper, we propose to develop a system to aid in the diagnosis of anomalies' cardiac signals (ECG). This system is based on the wavelet transform and on the combination of artificial neural networks with supervised and unsupervised learning. The first network consists of a map SOM (Self Organizing Map) which allows the pre classification task, it receives as input 15 statistical parameters calculated from the coefficients of the wavelet transform, in addition to two intervals RR of original signal. The second stage is a MLP network (Multi Layer Perceptron) responsible of the final classification, it receives as input the outputs of the Kohonen map. Four types of arrhythmias are considered in this study: ventricular extrasystoles (VE), Premature ventricular fibrillation (EA), right bundle branch block (BBD), and left bundle branch block (LBBB), in addition to normal beat (N). Our system has been validated on various ECG signals extracted from the patient database "MITBIH.

The performance evaluation of the proposed system is based on the sensitivity (SE), specificity (SP) predictivity (PP) and the rate of correct classification (CC). The results obtained are very satisfactory.

MOTS-CLÉS: Electrocardiogramme (ECG), la transformée en ondelettes, MLP, LVQ, SOM, base de données MIT-BIH.

KEYWORDS: Electrocardiogram (ECG), MIT-BIH database, MLP, LVQ, SOM, Wavelet Transform (WT).

.....

1. Introduction

Un électrocardiogramme (ECG) est un enregistrement de l'activité électrique du cœur en fonction du temps. En raison de la rapidité à mettre en place, l'efficacité et surtout fiabilité pour le diagnostique, l'ECG joue un rôle important en surveillant et en diagnostiquant des patients aujourd'hui. Ce pendant l'ECG n'est performant que lorsqu'il est enregistré sur une longue durée, l'analyse d'un tel enregistrement nécessite des méthodes d'extraction des paramètres et de classification automatique des battements cardiaques, de plus en plus performantes et précises. Beaucoup de méthodes ont été proposées ces dernières années que ce soit pour l'extraction des paramètres ou pour la classification [1,2].

Les paramètres d'un battement cardiaque peuvent être extraits dans le domaine temporel [3,4], ou dans le domaine fréquentielle [5,6]. Bien que ces méthodes aient montré des résultats très intéressants dans quelques tâches de classification, cependant elles demeurent inefficaces pour détecter tous les types de battements ECG. La transformation en ondelette (DWT) ouvre une autre catégorie de méthodes qui représente le signal dans différentes translations et échelles (fréquentielle et temporelle). En outre, la DWT décompose un signal en signaux dans des intervalles de fréquences différentes. Les paramètres extraits à partir des coefficients de la transformé sont capables de représenter d'une manière pertinentes les caractéristiques du signal original. Dans cette étude nous avons appliqué la transformé en ondelette pour décomposer notre signal en cinq sous bandes, nous avons par la suite extraits trois paramètres statistiques relatives aux coefficients des trois derniers détails (D3- D5), la dernière approximation(A5) ainsi qu'au signal original. En plus de ces paramètres, la durée des intervalles RR est considérée comme étant un paramètre très important et sont utilité est justifiée dans le reste du papier.

Quant aux classificateurs, plusieurs types de classifieurs ont été testés : les séparateurs à vaste marge [7,8], les réseaux de neurones artificiels [6,1]... ; Parmi ces méthodes, la technique neuronale est l'outil qui a connu le plus de succès en raison de leurs propriétés remarquables [2,3] : capacité d'adaptation, apprentissage à partir d'exemples et généralisation, robustesse face au bruit, Ils sont intégrables dans des processus temps

réel embarqués et ils sont remarquablement efficaces pour l'apprentissage de processus difficilement modélisables.

Dans cette étude, et dans le but d'obtenir un système de classification efficace, nous proposons une structure neuronale hybride, combinant deux étages(Figure1) :

- Le premier étage est constitué d'une carte de Kohonen à apprentissage non supervisé, qui réalise une tâche de pré classification [9][10].

- Le deuxième étage est un réseau MLP (Multi layer Perceptron) à apprentissage supervisé et qui est chargé de la classification finale [11][12].

Dans la suite de ce papier, nous présenterons dans la section 2 les étapes suivies pour la préparation des données qui seront présenté comme entré de la carte SOM. Dans la section 3, nous détaillerons la méthodologie adoptée pour la mise au point de notre système de classification. Dans la section 4, nous présenterons les principaux résultats obtenus. Une conclusion et les perspectives concernant ce travail sont données dans la section 5.




Figure1: Schéma bloc du system de classification des battements cardiaque

2. Méthode

2.1. La transformé en ondelette discrète(DWT)

Les informations relative a l'état du cœur sont reflète par son activité électrique en fonction du temps et la fréquence ; Par conséquent, les études exigent des méthodes capables de décrire la variation qualitative du signal en temps et en fréquence. La transformée en ondelettes est une méthode puissante qui permet d'effectuer une analyse des structures locales d'un signal avec un zoom en fonction de l'échelle considérée.la transformé en ondelette d'un signal $x(t)$ est définie comme suit :

$$\psi_a x(b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad a > 0 \quad (1)$$

Où $\psi(t)$, a , $b \in \mathbf{R}$ et $a \neq 0$, sont l'ondelette mère, le facteur de dilatation et de translation, respectivement. Les facteurs de translation et de dilatation sont utilisés dans la transformée en ondelette afin d'obtenir une famille d'éléments temps-fréquence.

Chaque étage de la décomposition multirésolution d'un signal est donné par les fréquences les plus basses qui représentent les approximations et par les fréquences les plus élevées qui représentent les détails. Nous avons donc besoin d'un filtre passe-bas $h(x)$ pour obtenir l'approximation et d'un filtre passe haut $g(x)$ pour obtenir le détail. Les sorties des premiers filtres passe haut et passe bas fournissent le détail, $D1$ et l'approximation, $A1$, respectivement. La première approximation, $A1$ est encore décomposée et ce processus est continué.

Nous avons appliqué dans cette étude cinq niveaux de décompositions pour chaque battement cardiaque, ce dernier est centré sur le pic R et échantillonné sur 360 Hz. Ensuite nous avons gardé les trois derniers détails ($D3$ - $D5$) et la dernière approximation ($A5$).

2.2 Extraction des paramètres

On peut utiliser plusieurs paramètres pour caractériser les différentes décompositions ; dans cette étude nous avons opté pour les paramètres statistiques suivants : La variance, Variance de la fonction d'autocorrélation d'un signal, Amplitude Relative. (Pour plus de détails ce référait à [13]).

2.3 Normalisation des paramètres

Puisque les quantités des paramètres peuvent être très différentes, un procédé de normalisation est nécessaire pour normaliser tous les paramètres au même niveau. Nous avons appliqué la fonction transfert tansig (\cdot) de type hyperbolique, cette fonction a été appliquée pour représenter chaque paramètre du vecteur caractéristique dans l'intervalle $[-1, +1]$. [13]

3. Classification.

Dans cette étude, pour minimiser le risque d'erreur du diagnostique, nous proposons un réseau de neurones hybride similaire à celui utilisé dans [9].

3.1 Carte Auto-organisante de Kohonen

Les cartes SOM sont des réseaux neuromimétiques qui s'inspirent des modèles biologiques de perception [6][10], leur utilisation principale est la catégorisation et la projection non linéaire des données.

Le réseau simulé pour la classification des battements cardiaques est une SOM bidimensionnelle composée de $N \times N$ neurones artificiels.

- Le vecteur d'entrée $X=[x_1 \ x_2 \ \dots \ x_{17}]$ représente les 17 paramètres caractérisant un battement cardiaque, et il est lié à tous les neurones.
- Les connexions extérieures du neurone i avec le vecteur d'entrée X se matérialise par un vecteur poids synaptiques $M_i = [m_{i1} \ m_{i2} \ \dots \ m_{i17}]$.
- D'autre part, chaque neurone i de la carte est lié à tous les autres neurones de la carte : interaction entre neurones. Les poids des connexions internes w_{ik} du neurone i avec ses voisins sont donnés par la fonction dite du "chapeau mexicain ». Ces connexions dépendent de la distance entre neurones et sont invariants dans le temps.
- la sortie S_i du neurone i à l'instant t s'exprime par :

$$S_i(t) = \sigma \left[\sum_j m_{ij} * X_j + \sum_k w_{kj} * S_k(t-1) \right] \quad (6)$$

La sortie $S_i(t)$ à l'instant t du neurone i est donc fonction de deux termes, une entrée totale $\sum_j m_{ij} * X_j$, et une entrée interne résultante d'une somme pondérée (par l'importance des interactions latérales) des signaux émis aux sorties des neurones voisins à l'instant $(t-1)$: $\sum_k w_{kj} * S_k(t-1)$. La somme globale est évaluée par la fonction d'activation sigmoïde σ .

3.2 Réseau MLP

Pour la classification supervisée finale des battements ECG, nous avons opté pour un réseau MLP, qui est l'un des modèles connexionnistes le plus efficace et le plus utilisé pour les tâches de régression et de discrimination. Dans cette étude nous avons utilisé un MLP à trois couches [11] [12]:

- Une couche d'entrée recevant les sorties de la carte de Kohonen
- Une couche de sortie comportant 5 neurones représentant chacune une des classes prédéfinies.
- En ce qui concerne le nombre de neurones de la couche cachée, il n'existe pas de méthodes permettant de le déterminer, on procède en général d'une manière empirique en testant plusieurs valeurs. Dans notre cas, nous avons testé des réseaux ayant entre 5 et 20 neurones et nous retenons celui qui possède la meilleure capacité de généralisation.

L'apprentissage du réseau a été réalisé en utilisant l'algorithme de la rétro propagation du gradient [10] avec une base d'apprentissage comportant 10400 battements tirés de la base MIT-BIH et représentant les cinq classes (table 1).

3.3 Résultat expérimentaux

Préparation des bases de données: Les signaux cardiaques de la base de données MIT/BIH [1] sont la norme employée par beaucoup de chercheurs pour l'évaluation des détecteurs d'arythmies. Elle contient 48 enregistrements, chaque enregistrement a une durée de 30mn et une fréquence d'échantillonnage de 360HZ.

La base MIT a permis la création de deux bases de données : une pour l'apprentissage, l'autre pour le test, qui serviront pour l'entraînement et l'évaluation de notre classifieur. Les battements sélectionnés sont donnés dans la table 1.

Tableau 1 : patients et nombre de battements utilisés dans cette étude

Type	Patients	Apprentissage	Test
N	103,113,115,123,220,234	600*6	600*6
BBD	109,111,207,214	600*4	600*4
BBG	118,124,212,231	600*4	600*4
EA	119	200	200
	221	150	150
	200,233	400*2	400*2
EV	209	150	150
	222	100	100
	232	600	600
Total		10400	10400

Discussions des résultats : Une fois l'apprentissage des réseaux terminé, il est nécessaire de les tester sur une base de données différente de celles utilisées pour l'apprentissage.

Pour évaluer nos classificateurs nous avons utilisé quatre lois statistiques basés sur la reconnaissance des catégories mutuellement exclusive de TP (true positive), FP (false positive), TN (true négative), FN (false négative).

Ces lois sont définies comme suit : [10]

- La sensibilité : $SE = 100 \times TP / (TP + FN)$: c'est la fraction de cas réels visés correctement reconnus sur tous les cas réels visés.
- La spécificité : $SP = 100 \times TN / (TN + FP)$: c'est la fraction de cas réels non visés correctement rejeté
- La productivité : $PP = 100 \times TP / (TP + FP)$: c'est la fraction de cas réel visé sur tous les cas reconnus comme cas visé.
- La classification correcte : $CC = 100 \times (TP + TN) / (TN + TP + FN + FP)$: c'est le taux de classification correct (calculé par la méthode statistique).

Tableau 2 : taux de classification et matrice de confusion : 98.66%

	Taux de test	Matrice de confusion				
		N	BBD	BBG	EV	EA
N	99.58	3585	0	8	5	2
BBD	99.44	3	1790	5	1	1
BBG	99.25	5	4	2382	3	6
EV	97.39	5	5	8	1120	12
EA	97.64	2	8	17	3	830

Tableau 3 : Résultats d'application des lois statistiques

	N	BBD	BBG	EV	EA
SE	99.58	99.44	99.25	97.39	97.64
SP	99.75	99.78	99.48	99.86	99.76
PP	99.58	99.05	98.42	98.93	97.53
CC	99.69	99.72	99.94	99.57	99.48

Les tableaux ci-dessus illustrent la matrice de confusion et le résultat de l'application des quatre lois statistiques sur nos différentes classes. On remarque que notre système de classifications a donné de bons résultats sachant qu'il n'y a pas une perte d'information. On remarque aussi que la confusion entre les classes est faible ce qui démontre l'efficacité de la méthode proposée.

Comparaison des résultats : Le taux de généralisation obtenue avec se classifieur hybride sont nettement meilleur que se obtenus avec un classifieur a base de carte SOM[10], et sont comparable avec ce obtenue avec un MLP simple[11-12]. Cependant on a constaté que le taux des fausse alarme sont inférieurs par a port a l'MLP. d'un autre coté on aimtai insisté sur la taille de la base de données utilisé dans cette étude (10400exemple pour le test) qui est largement plus grande que celle utilisé dans les travaux précédant[10-12] (2500exemple pour le test).

L'architecture proposé dans cette article est similaire a celle proposé dans [9], mais les sorties du classifieur final ont étai déferment calculé. Nous avons considéré dans notre approche qu'un battement est correctement classé, si la probabilité de sa classe d'appartenance est supérieure à 0.75 sinon le battement est affecté à une classe rejet.

NB : tous les exemples utilisé dans cette approche ont été reconnus avec une probabilité d'appartenance supérieur a 0.75 d'où la justification de l'absence de la classe rejet.

4. Conclusion

Dans cet article, nous avons proposé un système de classification hybride qui combine deux réseaux de neurones a apprentissage supervisé et non supervisé, ce système permet de diagnostiquer quatre arythmies cardiaques très fréquentes.

- Les signaux sont tous d'abord décomposés en 5 sous bandes différentes (entre 0 et 360Hz) en utilisant la transformé en ondelettes.

- Ensuite, trois paramètres statistiques correspondant à la dernière approximation et les trois derniers détails, également l'intervalle RR et les paramètres statistiques du signal original sont utilisé pour représenter chaque vecteur caractéristique.

- Enfin nous avons implémenté un système de classification des battements cardiaques basé sur l'implémentation d'une carte SOM (Self Organizing Map) qui permet de faire une pré classification, et d'un réseau de type MLP) chargé de la classification finale.

Notre système a été validé sur des enregistrements extraits de la base de données MIT-BIH, les résultats obtenus montrent l'efficacité de la méthode. Cependant notre travail peut être amélioré et élargit par les éléments suivants : l'effet des bruits sur le

classifieur, et fusionner notre classifieur avec d'autres techniques de classification plus récents telque les séparateurs à vaste marge et les systèmes neuro flous.

BIBLIOGRAPHIE

- [1]: Ceylan R., Ozbay Y., (2007). Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network. *Expert Systems with Applications*, (33), pp: 286–295.
- [2]: Yu S.N., Chen Y.H., 2009. Noise-tolerant electrocardiogram beat classification based on higher order statistics of subband components. *Artificial intelligence in medicine*,(46), pp:165-178.
- [3]: Charllis R.E, Kittney R.I, 1990. Biomedical signal processing's(in four parts).Part1:time domain methods. *Med.Biog.Eng. Comput*, (28), pp:509-524.
- [4]: Hu Y.H, Palreddy, S, Tompkins .W, 1997. A patient adaptable ECG beat classifier using a mixture of experts approach. *IEEE trans. Biomed;Eng*,(44), pp:891-900.
- [5]: Khadra L., Al-Fahoum A., Binajjaj S. , 2005. A quantitative analysis approach for cardiac arrhythmia classification using higher order spectral techniques. *IEEE Trans Biomed Eng* 52(11),pp:1840-5.
- [6]: Minami K., Nakajima H., Toyoshima T., 1999.Real-time discrimination of ventricular tachyarrhythmia with Fourier- transform neural network. *IEEE Transactions on Biomedical Engineering* (46), pp:179-185.
- [7]: Elif Derya Übeyli, 2007. ECG beats classification using multiclass support vector machines with error correcting output codes *Digital Signal Processing* (17),pp:675–684.
- [8]: Maglogiannis I.,Loukis E., Zafiroopoulos E.,Stasis A.,2009. Support Vectors Machine-based identification of heart valve diseases using heart sounds. *computer methods and programs in biomedicine* (9 5),pp: 47–61
- [9]: Alexandre F., Kerkeni N., Ben Khalifa K., Bedoui M. H., Bougrain L., Dogui M. “Supervised Neural networks approachesfor EEG signal classification : experimental studies”, From *Proceeding* (544) *Artificial Intelligence and Soft Computing – 2006*.
- [10]: Hendel M. , Benyettou A., Khelil .H, March 22-26 ,2009”classification des arhythmies cardiaque par les réseaux de neurones artificiel”,5th international conference : science of electronic ,technologie of information and telecommunication Tunisie.
- [11]: Hendel M.,Benyettou A., Hendel F., Khilil H. 13, 14 et 15 Novembre 2008, ” Classification automatique des signaux ECG par les réseaux de neurones probabilistes ”, "Applications Médicales de l'Informatique : Nouvelles Approches" Monastir-Tunisie
- [12]:Hendel M., Benyettou A., Khelil H. , Iftene H., October 20-21, 2008 ” Système intelligent d'aide au diagnostic des anomalies des battements cardiaques ”.the international conference on electronics engineering. Algeria.
- [13]: Hendel M., Benyettou A., Hendel F., Khilil H, 2010.Automatic heartbeats classification based on discrete wavelet transform and a combination of probabilistic MLP Neural networks.*The International Journal of Applied Engineering Research (IJAER)*. Volume 1 Number 11 (2010) pp. 1925–1936.