

DETECTION ET IDENTIFICATION DES ARYTHMIES CARDIAQUES PAR APPLICATION DES RESEAUX DE NEURONES

N. Belgacem¹, M.A Chikh², F. Berekci Reguig

Laboratoire de Génie Biomédical. Département d'électronique. Faculté des Sciences de l'Ingénieur. Université
Abou Bekr Belkaïd. Tlemcen BP 230. 13000 Algérie.

Fax : (213) 043 28 56 85

Email: ¹n_belgacem@hotmail.com, ²c_wamine@yahoo.fr

RESUME- L'électrocardiographie explore l'activité électrique du cœur par enregistrement des variations des ondes électriques de l'activité de polarisation et de dépolarisation ventriculaire et auriculaires du cœur. L'activité cardiaque constitue l'un des plus importants paramètres déterminant l'état d'un sujet. Elle se traduit par l'apparition de plusieurs ondes sur le tracé de l'électrocardiogramme : c'est le signal cardiaque, l'électrocardiogramme : ECG. L'analyse du signal ECG et l'identification de ses paramètres constituent une étape primordiale pour le diagnostic. Cependant, des sources de bruits telles que les variations de la ligne de base, l'interférence électrique du réseau 50Hz, et d'autres artefacts, mettent en arène la mise en œuvre des techniques d'analyse et d'identification utilisées. Toutefois, un ensemble de méthodes et d'algorithmes sont développés compte tenu de l'importance de ce signal et son exploitation en routine clinique dans le diagnostic des cas pathologiques cardiaques. Cette étude s'inscrit dans ce problème et propose un classificateur des arythmies cardiaques par application des réseaux de neurones. Les résultats ont été validés par des signaux ECG des différents patients de la base de données « MIT BIH Arrhythmia Database ».

MOTS CLES - Signal ECG, Arythmies cardiaques, Classification, MIT BIH arrhythmia Database.

1. INTRODUCTION

Effectuer une classification, c'est mettre en évidence des relations entre des objets et entre ces objets et leurs paramètres. A partir de proximités ou de dissemblances, il s'agit de construire une partition de l'ensemble des objets en un ensemble de classes les plus homogènes possibles. Les travaux de recherches pour la classification du signal cardiaque remontent à 1957 où les premières approches étaient principalement basées sur l'utilisation de la méthode des arbres de décision et la méthode statistique [1]. Par la suite, de nouvelles approches ont été développées telles que l'approche syntaxique, les systèmes experts, la logique floue et les réseaux de neurones.

Dans cette optique, nous proposons de concevoir un classificateur des arythmies cardiaques, les classes de sortie sont :

- Normal (N).
- Extrasystole ventriculaire ou PVC (V).
- Fusion entre V et N (F).
- Extrasystole auriculaire (A).
- Ectopique (P).
- Non classé (Q).

Pour résoudre un problème de classification, nous disposons de toute une panoplie de méthodes qu'il faut utiliser en connaissant bien leurs capacités et surtout leurs limitations. Dans toute les expériences (théoriques et pratiques) effectuées par plusieurs

chercheurs [2], les réseaux de neurones conduisent à de bons résultats. Bien dimensionnés, ils obtiennent toujours les meilleurs taux de classification. Un grand nombre de paramètres tels que les variations de fréquence cardiaque, la largeur et la morphologie du complexe QRS et des ondes P et T de ce signal, sont nécessaires, et sont utilisés pour évaluer si le patient présente ou non des anomalies.

2. PREPARATION DES DONNEES

2.1. Chargement du signal ECG

Parce qu'il est un système interactif et convivial de calcul numérique et de visualisation graphique, Matlab 5.3 était l'environnement sous lequel nous avons développé notre logiciel de traitement du signal ECG [3]. Le chargement du signal cardiaque sous Matlab constitue l'étape initiale dans notre algorithme, il s'agit de convertir le signal ECG enregistré (codé) sous sa forme initiale (Le format 212 de MIT BIH Database) [4] en un autre format compréhensif par Matlab.

2.2. Prétraitement du signal cardiaque

Le signal ECG obtenu lors de l'enregistrement est généralement contaminé par différentes sources

de bruits qui peuvent perturber les caractéristiques de phase et d'amplitude du signal utile d'où la nécessité d'un bon filtrage.

Lo et al ont proposé un filtre passe bande capable d'éliminer les bruits causés par l'alimentation (50Hz), la respiration, les mouvements de muscles et la ligne de base [5]. Ce filtre est constitué par la combinaison d'un filtre passe bas et un autre passe haut. Les deux sont basés sur une fréquence d'échantillonnage de 360 Hz. La fonction de transfert de filtre passe bas est donnée par :


$$H_L(z) = \frac{1 - 2z^{-6} + z^{-12}}{1 - 2z^{-1} + z^{-2}}$$

Une fois le filtre passe bas a éliminé les bruits de fréquences hautes, le signal se présente à l'entrée d'un filtre passe haut de fonction de transfert :


$$H_H = z^{-127} \frac{1}{2^{14}} \frac{1 - 2z^{-128} + z^{-256}}{1 - 2z^{-1} + z^{-2}}$$

Où $\frac{1}{2^{14}}$ est un facteur de normalisation. La fréquence de coupure de ce filtre est 1Hz, le gain est unitaire.


Après filtrage, le signal est différencié pour faire apparaître les différents pics.



a- Signal ECG



b- Signal ECG après un filtre passe bas



c- Signal ECG après un filtre passe haut

Figure. 1: Filtrage de signal ECG.

2.3. Identification et détection des paramètres du signal ECG

Après calcul de la dérivée du signal ECG, les différentes ondes et leurs pics respectives sont identifiés et détectés [6], ainsi on procède à :

- Détecter le pic R (mesure de la fréquence cardiaque).
- Détecter les ondes Q et S (mesure de la durée du complexe QRS).
- Détecter l'onde T (calcul des intervalles QT et ST).
- Détecter l'onde P et sa morphologie (mesure de PP et PR).

2.4. Compression du signal ECG par prédiction linéaire

L'idée de base de la méthode d'extraction des caractéristiques du signal ECG est que les données peuvent être obtenues par une combinaison linéaire des données passées de ce signal. L'échantillon prédit \hat{y} est calculé à partir de échantillons passés par la relation :

$$\hat{Y}_n = \sum_{i=1}^p a_i y_{n-i}$$

Où a_i est le $i^{\text{ème}}$ coefficient de la prédiction linéaire (LPC : de Linear Prediction Coding) et p est son ordre.

Afin de réduire la taille du vecteur d'entrée du réseau de neurones, et utilisant les travaux de Lin et al [7], qui ont montré qu'un ordre de prédiction égal à deux (P=2) était suffisant pour l'analyse de signal ECG, nous avons implémenté cette méthode de compression. Le complexe QRS est compressé en deux coefficients (a1 et a2), ainsi que l'onde P (a3 et a4).

Une étude générale sur les travaux effectués sur la classification du signal ECG [8-11] nous a amené à choisir une meilleure représentation du complexe QRS et de l'onde P, à savoir :

Les coefficients (a1, a2) résultants de l'application de la LPC, plus l'intervalle RR et la largeur du complexe QRS sont les éléments du vecteur qui représente le complexe QRS de chaque cycle cardiaque. Pour l'onde P, les deux coefficients (a3, a4) de la LPC, sa largeur L(P), les intervalles PP et PR ont été choisis pour une meilleure description de cette onde. Les informations de chaque cycle sont représentées par un vecteur de quatre éléments pour le complexe QRS, et cinq composantes pour l'onde P. Les coefficients de la LPC représentent la morphologie des deux ondes, alors que les autres éléments sont les caractéristiques temporelles liées au cycle désigné.

3. IMPLEMENTATION SOFTWARE DU CLASSIFICATEUR

Le but de l'implémentation software du classificateur est de déterminer la taille et les paramètres du réseau de neurones, à savoir :

- Nombre de couches et le nombre de neurones pour chaque couche.
- Erreur atteinte.
- Nombre d'itération.

Ces paramètres permettent d'avoir les meilleures performances du réseau. Nous discutons dans cette section sur les conditions et méthode d'apprentissage, la base de données utilisée, la programmation et le dimensionnement du réseau.

3.1. Apprentissage

L'apprentissage vise à découvrir les relations et motifs cachés dans des collections des données brutes. Un système d'apprentissage prend en entrée un ensemble d'exemples (cycles cardiaques) dont il cherche une définition. Dans notre cas, le système cherche à apprendre les formes des arythmies cardiaques à partir des exemples fournis à son entrée. Ces exemples sont présentés sous forme de paramètres (éléments du vecteur d'entrée) qui représentent les caractéristiques temporelles et morphologiques des cycles cardiaques classés selon les arythmies auxquelles elles correspondent. L'algorithme d'apprentissage-la rétropropagation dans ce cas- assure que les classes produites permettent de discriminer aux mieux les exemples en entrée.

3.2. Algorithme de la rétropropagation

Les réseaux de neurones supervisés requièrent un apprentissage par essais/erreurs, en partant d'exemples donnés sous forme de paires (problème, solution à ce problème). La méthode numérique utilisée pour l'apprentissage et que nous avons adopté s'appelle le descente de gradient par rétropropagation.

L'idée de cet algorithme d'optimisation est que le gradient d'une fonction pointe toujours dans la direction où cette fonction croît le plus. Inversement, si nous multiplions le gradient par le scalaire -1, nous obtenons la direction de la plus grande décroissance de la fonction. La difficulté majeure est de choisir le pas d'apprentissage. En effet, si nous allons le choisir trop petit, nous allons converger vers un minimum local très lentement et si nous le choisissons trop grand, nous ne convergeons pas, car nous allons sauter d'un côté à l'autre.

Plusieurs méthodes et algorithmes d'optimisation ont été proposés pour résoudre ce problème [12-14]. Chaque méthode possède des avantages et des inconvénients. Bien entendu, aucune méthode ne

conduit à coup sûr au minimum global. Il convient donc de se placer dans des conditions où les minima locaux sont aussi peu nombreux que possible. Nous avons choisi la méthode de Levenberg-Marquardt qui consiste à modifier les paramètres selon la relation suivante :

$$\theta_k = \theta_{k-1} - [h_{k-1} + \lambda_{k-1} I]$$

Avec I : matrice identité.

Cette méthode est particulièrement astucieuse car elle s'adapte d'elle-même à la forme de la fonction coût. Elle effectue un compromis entre la direction de gradient et la direction par la méthode de Newton.

3.3. Base de données

Dans cette étude nous nous concentrons sur la classification des extrasystoles ventriculaires (PVC), les 48 enregistrements de "MIT BIH Database" sont utilisés pour le développement et l'évaluation des performances du classificateur. Chaque enregistrement de cette base de données est accompagné par un fichier d'annotation dans lequel chaque battement ECG (cycle cardiaque) a été identifié par des experts (cardiologues) [15]. Ces étiquettes (annotations) sont employées pour l'apprentissage du classificateur et l'évaluation de ces performances pendant la phase de test. Puisque cette étude vise à identifier l'extrasystole ventriculaire (PVC), certains enregistrements de la base de données sans PVC ont été exclus de l'étude, laissant 35 enregistrements d'intérêt.

Les cycles cardiaques utilisés pour l'apprentissage des différents cas pathologiques ont été choisis aléatoirement de plusieurs enregistrements. L'avantage est bien sur de construire une base de données incluant différentes formes de chaque arythmie cardiaque.

3.4. Programmation

Notre choix étant porté sur l'algorithme de la rétropropagation du gradient, un programme est écrit en Matlab pour l'implémentation software de cet algorithme. La fonction d'activation choisie est la fonction sigmoïde (Fig. 2).




Figure.2 : Fonction sigmoïde et sa première dérivée.

Une fonction sigmoïde est définie par f(x) donnée par :

$$f(x) = a \frac{e^{kx} - 1}{e^{kx} + 1}$$

En effet, elle tend vers a quand x tend vers $+\infty$ et tend vers $-a$ quand x tend vers $-\infty$. Le paramètre a régule alors la valeur de saturation ; le paramètre k sert à réguler la pente de la courbe en tout point hors saturation.

Dans notre modèle, nous utilisons les fonctions *logsig* et *tansig* implémentées sous Matlab comme fonction d'activation (transition) dans le réseau de neurones. Ces fonctions sigmoïdes sont continues et différentiables, elles sont également non décroissantes. Nous les appelons fonctions quasi-linéaires car elles sont presque linéaires dans l'intervalle d'intérêt. Comme le montre la figure.6 la fonction sigmoïde $f(x)$ et sa dérivée première $f'(x)$ sont toutes les deux des fonctions continues dans \mathbb{R} . ceci est fort utiles lors des manipulations mathématiques de ces fonctions.

3.5. Dimensionnement du réseau

Il n'existe pas de résultats théoriques, ni même de règles empiriques satisfaisantes, qui permettent de dimensionner correctement un réseau de neurones en fonction de problème à résoudre. La conception d'un réseau multicouche se fait de manière expérimentale, la difficulté se pose généralement au moment du choix du nombre de couches intermédiaires et du nombre de neurones dans chacune d'elles. Pour la couche d'entrée, elle contient autant de neurones que le nombre d'éléments du vecteur d'entrée. De même, pour la couche de sortie, elle contient autant de neurones que le nombre de classes à discriminer. De ce fait, la couche d'entrée est constituée de neuf neurones et la couche de sortie est constituée de six neurones.

Pour déterminer le nombre de neurones de la couche cachée, nous avons procédé de la manière suivante :

1. Préparer les cycles cardiaques correspondants aux arythmies choisies pour l'apprentissage.
2. Créer le réseau de neurones dont le nombre de la couche d'entrée (respectivement de sortie) est fixé suivant le vecteur d'entrée (respectivement classes en sortie)
3. désigner un nombre de neurones arbitraire dans la couche cachée.
4. Fixer une erreur de très faible valeur ainsi que le nombre d'itérations.
5. Lancer l'apprentissage.

Tant que le processus diverge, augmenter le nombre de neurones dans la couche cachée, si celui-ci est trop élevé augmenter le nombre de couches intermédiaires.

Il n'existe malheureusement pas de « super architecture neuronale », c'est à dire d'architecture

fixe pour laquelle il suffirait d'adapter les poids au problème afin d'obtenir les meilleures performances possibles. De manière générale, la taille et le type des connexions d'un réseau influent sur ses performances. Notons toutefois que cette architecture trouvée n'est pas unique, et qu'il existe souvent plusieurs architectures permettant d'obtenir la même performance. Dans notre cas, l'architecture optimale sera celle qui possède la plus petite taille, ou plus précisément celle qui nécessitera le moins de calculs pour réaliser la fonction demandée.

4. RESULTATS ET DISCUSSION

Les résultats présentés dans cette étude, pour la classification des signaux ECG ont été obtenus en appliquant à l'entrée de classificateur des signaux ECG de "MIT BIH Arrhythmia Database".

La sensibilité, spécificité et le taux de classification sont trois paramètres calculés pour chaque signal pour évaluer et comparer les résultats obtenus. Les performances du classificateur sont présentées dans le tableau 1.

Notre système de classification nous a permis d'obtenir un taux de reconnaissance de 95,84% en appliquant l'ensemble des signaux ECG de MIT BIH Database avec une spécificité de 96.49% et une sensibilité de 94.60%. Ces performances ont été obtenues principalement grâce à :

- L'exploitation des techniques neuronales, L'utilisation des procédures adéquates de traitement pour effectuer la détection et l'identification des différents paramètres d'un cycle cardiaque.
- La combinaison des caractéristiques des deux ondes (QRS et P) afin d'aider le classificateur à discriminer entre les différentes classes.
- L'utilisation d'une base de données réelle (MIT BIH Arrhythmias Database).

5. CONCLUSION

Le choix de variables d'un modèle ou d'un classificateur est bien souvent déterminant pour sa qualité. Dans cette étude, nous avons pu sélectionner les variables les plus représentatives d'un cycle cardiaque, cela était basé sur une étude générale des travaux antérieurs.

Si on compare nos résultats avec ceux obtenus dans les autres études[8-11], on constate non seulement que nous avons amélioré les performances du classificateur, mais aussi que celles-ci sont obtenues avec un réseau qui possède une architecture minimale vis à vis du nombre de classes en sortie. Ce point est très important, car cela permet de :

- Minimiser le temps de réponse du classificateur surtout si on désire avoir un classificateur temps réel.

- Faciliter la mise en œuvre du classificateur (réalisation pratique), car il nécessite un nombre réduit de neurones et donc moins de connexion.

Notons finalement, qu'il est possible d'obtenir des performances légèrement meilleures en utilisant plus de neurones en couche cachée. Nous avons toutefois conservé architecture afin de limiter la complexité algorithmique et le temps de réponse du classificateur.

Signaux	battements	Normal	SE	SP	CC
100	2272	2239	100	96.16	96.12
101	1864	1860	NaN	94.62	94.62
102	2186	99	100	100	100
103	2083	2082	NaN	97.35	97.35
104	2228	163	100	100	99.93
106	2026	1507	98.65	98.60	98.61
108	1762	0	100	99.36	99.37
112	2538	2536	NaN	98.26	98.26
113	1794	1789	NaN	99.27	99.27
117	1534	1534	NaN	100	100
119	1986	1543	100	99.54	99.64
121	1863	1861	100	99.68	99.08
123	1518	1515	100	100	100
200	2601	1743	82.18	97.88	92.84
210	2650	2423	87.62	84.48	84.71
221	2427	2031	73.38	99.35	93.48
228	2053	1688	80.96	99.88	95.95
230	2256	225	100	84.5	84.5
234	2753	2700	100	99.96	99.96

NaN : Not a Number.

Tableau -1 : Performances du classificateur en %.

REFERENCES

- [1] P.DEGOULET, M.FIESCHI, " Informatique médicale", 3^{ème} édition, édition Masson, 1998.
- [2] N.MAGALAVRAS,T.STAMKOPOULOS, K.DIAMANTARAS, C. PAPPAS, M.STRINTZIS, " ECG patern recognition and classification using non linear transformations and neural networks : a review", *Internationnal journal of medical informatics*.52, pp.191-208, 1998.
- [3] M. MOKHTARI ET A. MESBAH, "Apprendre et maîtriser MATLAB", édition Springer, 1997.
- [4] MIT BIH Arrhythmia Database Directory. *Third edition, Harvard MIT Division of Health Sciences and technology, Biomed. Eng. Center.* 1992.
- [5] T.Y.LO AND P.C.TANG, "A fast bandpass filter for ECG processing", *Proc. IEEE Eng. Med. Biol. Soc. 4th Annu. Int. Conf*, pp: 20-21,1982.
- [6] N. BELGACEM, M.A.CHIKH, F. MEGHNEFI, F.BEREKSI REGUIG, "Détection et identification des paramètres du signal ECG", *acte du Séminaire National sur l'Automatique et les Signaux SNAS'02*, Annaba :27-28 octobre 2002.
- [7] KANG PING LIN AND W.H.CHANG, " QRS feature extraction using linear prediction", *IEEE Transaction on Biomed. Eng.* vol 36, N°10, October 1989
- [8] VALENTINO X, J. TOMPKINS, TRUONG Q, SHEN LUO, "ECG beat detection using filter banks", *IEEE Transaction on Biomed. Eng.* vol 46, N°2, February 1999.
- [9] C.D.NUGENT, J.A.C.WEBB, N.D.BLACK, G.T.H.WRIGHT, M.MC INTYRE, "An intelligent framework for the classification of the 12 lead ECG", *Artificial Intelligence in Medecine*,16,pp.205-222, 1999.
- [10] YU HAN HU, S.PALREDDY AND W.J.TOMPKINS, "A patient adaptable ECG beat classifier using a mixture of experts approach", *IEEE Transaction on Biomed. Eng.* vol 44, N° 9, September 1997.
- [11] R.SILIPO, M.GORI, A.TDDEI, M.VARANINI AND C.MARCHSEI, "Classification of arrhythmic events in ambulatory ECG using artificial neural networks", *Computers and Biomed. Reseach*, n°28, pp.305-318, 1995.
- [12] J.A.HERTZ, A.S.KROGH AND R.G.PALMER, "Introduction to the theory of neural computation", *Artificial Intelligence.* 1993.
- [13] B.MULLER, J.REINHARDT, M.T.STRICKLAND, "Neural Networks : an introduction", édition Springer, 1995.
- [14] HERVE ABDI, "les réseaux de neurones", édition Press Université de Grenoble, 1994.
- [15] G.B.MOODY, "ECG Database Programmer's Guide" *Ninth edition, Harvard MIT Division of Health Sciences and technology, Biomed.Eng.Center*1997.