

Application des réseaux de neurones dans la reconnaissance des arythmies cardiaques

R.Kaoulal, N. Hedeili, M.A.Chikh ,F.Baroudi

Laboratoire de Génie Biomédical - G.B.M-,Département d'Electronique,Faculté des Sciences de l'ingénieur,Université de Abou bekr Belkaid,Tlemcen B.P 230 pole Chetouane,13000 Algérie
Email : R_Kaoulal @mail.univ-tlemcen.dz

Résumé : On propose dans ce papier deux modèles de classificateurs neuronaux destinés a l'identification de la pathologie cardiaque extrasystole ventriculaire "ESV" ,dont le premier classificateur est un réseau de kohonen (la méthode LVQ "Learning Vector Quantization"),et le deuxième est un réseau de neurones multicouches (la méthode de rétropropagation de gradient). Notre but principal est d'avoir un meilleur taux de classification avec une architecture minimale, nous avons appliqué la méthode LPC (Linear Prédicative Coding) afin d'avoir un vecteur d'entré réduit .Notons que les signaux ECG exploités pendant les différentes phases (phase d'apprentissage, phase de validation) de cette étude sont tous extraits de la base de données (MIT-BIH).

Mots clés :

Signaux ECG, MIT-BIH, classificateur neuronal, LPC, LVQ, rétropropagation de gradient.

I. Introduction :

L'analyse du signal ECG et l'identification de ses paramètres et ondes (P, QRS, T, U) constituent une étape primordiale pour le diagnostic des cas pathologiques cardiaques car il traduit l'activité électrique du cœur (voir figure 01).

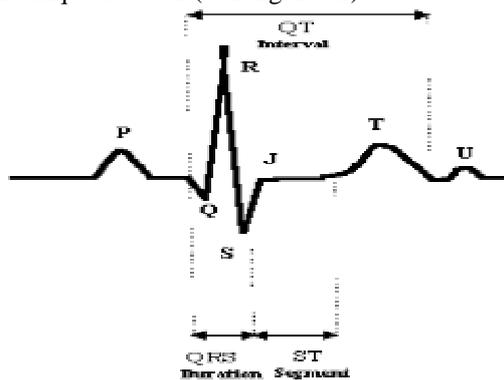


Figure 01 : Electrocardiogramme normale [1]

L'interprétation du signal (ECG) était principalement basée sur l'utilisation de la méthode des arbres de décision et la méthode statistique (se sont les premiers approches en 1957) [2], 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 notre étude nous appliquons une de ces approches, celle des réseaux de neurones ; nous envisageons de simuler deux classificateurs neuronaux des arythmies cardiaques destinés à reconnaître deux types de signaux ECG :

⇒ECG normal.

⇒ECG anormal caractérisant la maladie d' Extrasystole Ventriculaire" ESV" ; notons que les ESV sont des battements ventriculaires caractérisées par un large QRS et une onde T souvent inversés, avec une absence de l'onde P, et un intervalle RR plus court que la moyenne, suivie d'une pause, et une amplitude différente des battements normaux [3].

Nous avons ciblés ces deux classes pour les raisons suivantes :

⇒Le risque d'une mort soudaine pour des patients atteints d'une insuffisance cardiaque augmente sensiblement, avec l'augmentation de la fréquence d'apparition d'extrasystole ventriculaire (ESV).

⇒La détermination de la fréquence d'apparition de ESV, aide à évaluer la régularité de dépolarisation des ventricules et à diagnostiquer une tachycardie ventriculaire (TV).

⇒Ce sont des cas pathologiques qui présentent des caractéristiques communes, ce qui rend la tâche de prise de décision chez le médecin difficile.

⇒En plus l'extrasystole ventriculaire est souvent rencontrée au niveau de CHU de Tlemcen.

Le type d'apprentissage des deux classificateurs est supervisé, mais puisque leurs topologies sont différentes, le premier est un réseau de kohonen, et le deuxième est un réseau de neurones multicouches, nous utilisons pour l'un l'algorithme LVQ et pour l'autre l'algorithme de rétropropagation du gradient.

II.conception des classificateurs a deux classes :

1. Préparation des données :

Dans ce travail nous nous intéressons a la classification des battements cardiaques normaux et anormaux" ESV". Nous allons utilisés des enregistrements ECG d'une durée de 30 minutes pour 8 patients, qui ont été sélectionnés de la base de données MIT-BIH (voir tableau 01). La fréquence d'échantillonnage des signaux d'ECG dans la base de données est : $f_e = 360\text{Hz}$.

ENREGISREMENTS	N	ESV
105	25-	1
106	15ž	5-
116	2302	109
119	1542	444
205	25	71
215	31	164
219	20	6
221	20	396
228	16	36ž

Tableau N° 01: La description des enregistrements utilisées

. Filtrage et modélisation :

.1 Filtrage du signal ECG :

Les signaux ECG que nous allons utiliser sont déjà filtrés à la maison MIT, mais pour avoir des bons résultats, nous avons effectué un autre filtrage (afin d'éliminer les bruits restants), en appliquant un filtre passe bas en cascade avec un filtre passe haut, qui jouent le rôle d'un filtre passe bande avec une bande passante [1 27]Hz, qui va vous servir à éliminer les bruits des muscles (0.2Hz) et la fréquence de secteur (60Hz). Les fonctions de transfert de ces deux filtres sont données ci-dessous :

⇒ La fonction de transfert du filtre passe bas est donnée par :

$$L(z) = (1 - z^{-6}) / (1 - z^{-1}) \quad [4]$$

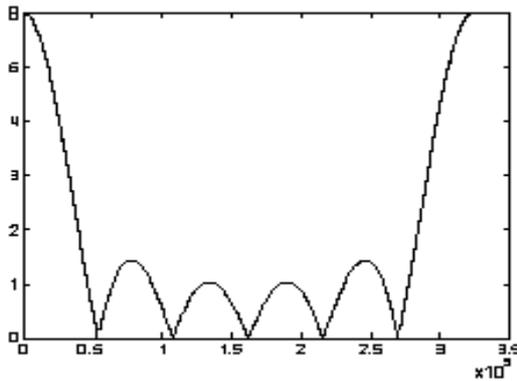


Figure 02 : Graphe du filtre passe bas

⇒ La fonction de transfert du filtre passe-haut est donnée par :

$$H(z) = z^{-127} \frac{(1 - 2z^{-128} + z^{-256})}{2^{14}(1 - 2z^{-1}z^{-2})} \quad [4]$$

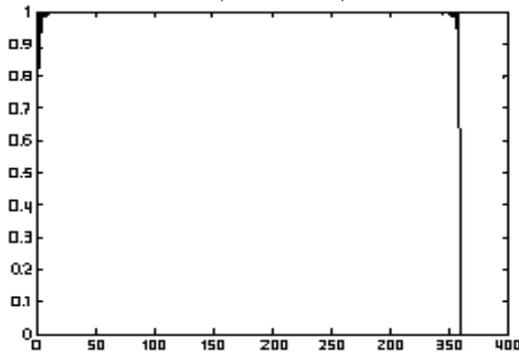


Figure 03 : Graphe du filtre passe haut

.2 Modélisation :

Dans cette étape on va préparer un seul type de vecteur d'entrée pour chaque enregistrement ; les composantes de ce vecteur représentent les entrées de nos classificateurs. Il est composé de :

- ⇒ Cycle cardiaque c'est-à-dire la durée RR.
- ⇒ La moyenne de 10RR.
- ⇒ La moyenne carrée du complexe QRS.
- ⇒ Le complexe QRS : Sachant que la position de l'échantillon du pic R est connu dans le fichier d'annotation de la base de données MIT-BIH, alors nous avons pris 15 échantillons à sa gauche et 14

échantillons à sa droite afin d'obtenir 30 échantillons du complexe QRS ($N = Tf_s$, avec N : Le nombre d'échantillons, T : La durée de QRS et f_s : La fréquence d'échantillonnage). Dans notre cas le complexe QRS est réduit à 2 échantillons, qui sont les plus significatifs obtenus par la compression du complexe QRS par la méthode "linear Predictive Coding" (en abrégé LPC).

L'idée de base derrière cette méthode dans l'analyse du signal ECG est que les données de l'ECG échantillonnées peuvent être approximées comme une combinaison linéaire des échantillons passés de l'ECG. La structure de ce concept est illustrée dans la figure 04.

La séquence $s(i)$ de l'ECG actuel peut être approximé par des séquences $\hat{s}(i)$ qui sont déterminées par un ensemble de coefficients d'un prédicteur et les P échantillons passés de $s(i)$ i.e. :

$$\hat{s}(i) = \sum_{k=1}^p a(k) * s(i - k)$$

Avec $a(k)$ c'est $k^{\text{ème}}$ coefficient de la prédiction linéaire "LPC", ces coefficients sont utilisés comme des facteurs de poids de la combinaison linéaire de la figure 04.

La différence entre la séquence d'ECG actuel et la séquence prédite est généralement nommée erreur résiduelle du signal $e(i)$:

$$e(i) = s(i) - \hat{s}(i)$$

$$e(i) = s(i) - \sum_{k=1}^p a(k) * s(i - k)$$

Dans le langage de la théorie du système linéaire la séquence prédite $\hat{s}(i)$ c'est la sortie d'un filtre à réponse impulsionnelle finie d'ordre P avec une fonction de

transfert :
$$H(z) = \sum_{k=1}^p a(k) z^{-k}$$

On remarque que l'erreur résiduelle est la sortie d'un système qui a la fonction de transfert suivante en utilisant la transformée en z

$$E(z) = s(z) - \sum_{k=1}^p a(k) * z^{-k} * s(z) = \left(1 - \sum_{k=1}^p a(k) * z^{-k} \right) * s(z)$$

Il existe plusieurs méthodes pour la résolution et le calcul des coefficients $a(k)$ de la prédiction linéaire, notons que l'algorithme de DURBIN est une méthode simple pour calculer les coefficients $a(k)$ et l'erreur résiduelle dans l'analyse d'ECG [5].

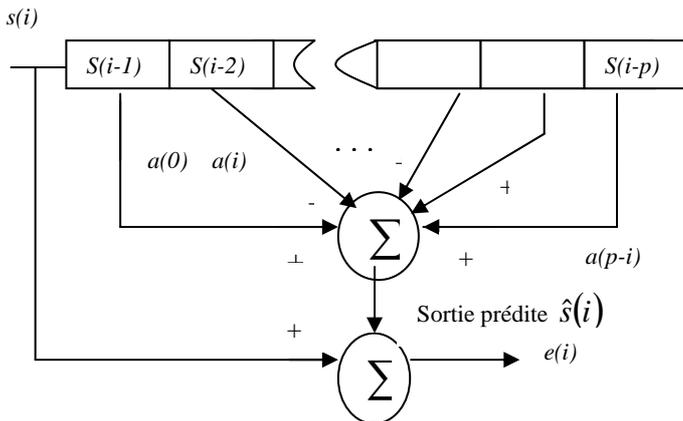


Figure 04: Mécanisme de la prédiction linéaire de p^{ème} ordre

2. Architecture des classificateurs et phase d'apprentissage :

2.1 Classificateur N°1 (Réseau de Kohonen) :

Ce classificateur est constitué :

⇒ D'une couche d'entrée de 5 neurones

⇒ D'une couche de sortie de 30 neurones (ou couche de compétition). Les neurones de cette couche entrent en compétition. Seuls les meilleurs gagnent ("WTA ou Winner takes all")

L'algorithme d'apprentissage est LVQ : [6], [7]

C'est une méthode d'entraînement de couche compétitives d'une manière supervisée. Une couche compétitive apprend automatiquement à classifier les vecteurs d'entrées mais les classes trouvées par la couche compétitive dépend uniquement de la distance entre les vecteurs d'entrées. (C'est la seule méthode qui soit réellement adoptée à la classification de données par " la recherche du plus proche voisin ").

Si deux vecteurs d'entrées sont similaires, la couche compétitive va les mettre probablement dans la même classe. Il n'existe pas un mécanisme dans la conception de la couche compétitive pour dire que deux vecteurs d'entrées sont dans la même classes ou dans des classes différentes. Le réseau LVQ apprend à classifier les vecteurs d'entrées par rapport à une classe cible (désirée) choisie par l'utilisateur.

Il existe plusieurs versions de cet algorithme appelées : LVQ1, LVQ2, LVQ2.2, LVQ3.

Dans notre travail on a utilisé la méthode LVQ1, dont son principe général est le suivant :

⇒ Les poids de chaque neurone de la carte sont initialisés à des valeurs aléatoires.

⇒ Calcul de la distance ("distance euclidienne") entre le vecteur à classer et les poids de chaque neurone de la carte.

La distance euclidienne entre ces deux vecteurs est définie par :

$$D_E(X, W) = \sqrt{\sum_{i=1}^n (x_i - w_i)^2}$$

Avec :

$X(x_1, x_2, x_3, \dots, x_n)$: Vecteur d'entrer.

$W(w_1, w_2, w_3, \dots, w_n)$: Vecteur de poids.

⇒ Le neurone dont le vecteur poids est le plus proche du vecteur d'entrée est sélectionné (neurone vainqueur).seuls les poids de ce neurone sont modifiés par la règle d'apprentissage suivante :

➤ $W_c(t+1) = W_c(t) + \alpha(t)\|x(t) - W_c(t)\|$ Si le neurone sélectionné (c a d le plus proche) représente la bonne classe.

➤ $W_c(t+1) = W_c(t) - \alpha(t)\|x(t) - W_c(t)\|$ Si le neurone sélectionné ne représente pas la bonne classe.

➤ $W_i(t+1) = W_i(t)$ pour les autres neurones avec $0 < \alpha(t) < 1$.

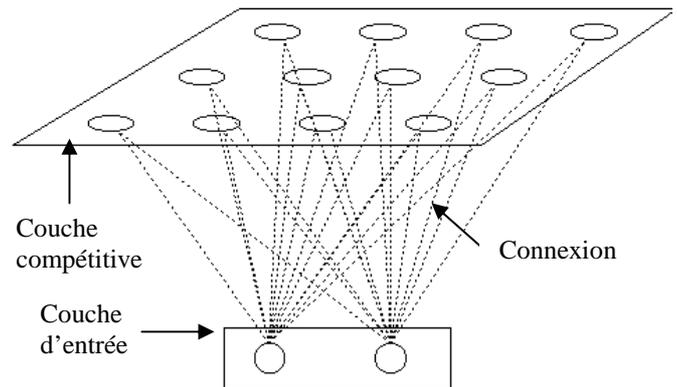


Figure 05 : réseau de Kohonen

2. Classificateur N° (RNM) :

C'est un réseau de neurones multicouches (RNM) constitué :

➤ D'une couche d'entrée de 5 neurones.

➤ D'une couche cachée de 3 neurones

➤ D'une couche de sortie de 2 neurones

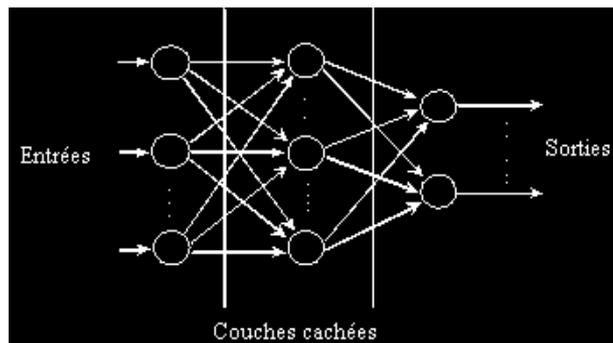


Figure 06 : réseau à couches « classique »

L'algorithme d'apprentissage utilisé c'est l'algorithme de rétropropagation de gradient. [8]

Cet algorithme est utilisé dans les réseaux de type feedforward, ce sont des réseaux de neurones à couches, ayant une couche d'entrée, une couche de sortie, et au moins une couche cachée. Il n'y a pas de récursivité dans les connexions, et pas de connexions entre neurones de la même couche. Le principe de la rétropropagation consiste à présenter au réseau un vecteur d'entrées, de procéder au calcul de la sortie par propagation à travers les couches, de la couche d'entrée vers la couche de sortie en passant par les couches

cachées. Cette sortie obtenue est comparée à la sortie désirée, une erreur est alors obtenue. A partir de cette erreur, est calculé le gradient de l'erreur qui est à son tour propagé de la couche de sortie vers la couche d'entrée, d'où le terme de rétropropagation. Cela permet la modification des poids du réseau et donc l'apprentissage. L'opération est répétée pour chaque vecteur d'entrée et cela jusqu'à ce que le critère d'arrêt soit vérifié [9].

Notons que la phase d'apprentissage va s'arrêter sous l'une de ces conditions :

- L'erreur soit inférieur a 10^{-8} .
- Le nombre d'itérations (epoch) maximum est atteint.

Remarques :

- A cause de l'insuffisance de mémoire (du Micro-ordinateur) on n'a pas respecté la durée 30mn pour chaque enregistrement du classificateur N°1.
- On a effectué l'apprentissage par l'enregistrement "119" pour les deux classificateurs (comprend un nombre suffisant de cas normaux et ESV).
- Pour améliorer les résultats, on a fait une normalisation des données d'entrées.
- Pour la conception des deux classificateurs on utilisée le logiciel matlab 5.3.

3. Résultats expérimentales [10] :

Bien sur après l'entraînement des réseaux, il faut les tester afin de vérifier leurs performances. En effet on va effectuer la phase de validation, on applique trois lois statistiques basées sur la reconnaissance des catégories mutuellement exclusive de TP (true positive), FP (false positive), TN (true negative), FN (false negative).

Ces lois sont :

La sensibilité : $SE = 100 \times TP / (TP + FN)$: c'est la fraction de cas réel "ESV" correctement reconnu sur tous les cas réels ESV.

La spécificité : $SP = 100 \times TN / (TN + FP)$: la fraction de cas réel normal "N" correctement rejeté sur tous les cas réels normal "N".

La classification correcte : $CC = 100 \times (TP + TN) / (TN + TP + FN + FP)$: c'est le taux de classification.

3.1 L'évaluation des classificateurs en visant le cas ESV :

Avant de représenté les résultats obtenue il faut donné quelques définitions :

TP: nombre de battements réellement ESV correctement reconnu.

TN: nombre de battements réellement non ESV correctement reconnu.

FP: nombre de battements réellement non ESV reconnu comme ESV.

FN: nombre de battements réellement ESV reconnu comme non ESV.

Le tableau si dessous montre l'identification des TP, TN, FP et FN :

REEL	ALGORITHME	
	n	v
N	TN	FP
V	FN	TP

Tableau N°02 : définitions des catégories mutuellement exclusive pour la classe "ESV"

ENREGISTREMENT	Classificateur N°1			
	TP	TN	FP	FN
105	35	2503	21	6
106	145	1335	170	375
116	108	534	1766	1
205	5	2562	0	66
215	126	3185	0	38
219	56	405	1675	8
221	12	2029	0	384
228	278	1686	0	84

Tableau N°03 : les catégories mutuellement exclusive du 1^{er} réseau

ENREGISTREMENT	Classificateur N°2			
	TP	TN	FP	FN
105	6	2384	134	35
106	432	1501	1	86
116	108	2283	10	1
205	67	2562	0	4
215	141	2135	1050	23
219	51	2074	1	12
221	381	2023	0	15
228	328	1519	164	32

Tableau N°04 : les catégories mutuellement exclusive du 2^{ème} réseau

ENREGISTREMENT	CLASSIFICATEUR N°1		
	SE	SP	CC
105	85.37	99.17	98.94
106	27.88	88.70	73.08
116	99.10	23.22	26.65
205	07.04	100	97.49
215	76.83	100	98.86
219	87.50	19.47	21.50
221	03.03	100	84.16
228	76.79	100	95.89
La moyenne	57.94	78.81	82.61

Tableau N°05 : les lois statistiques du 1^{er} réseau

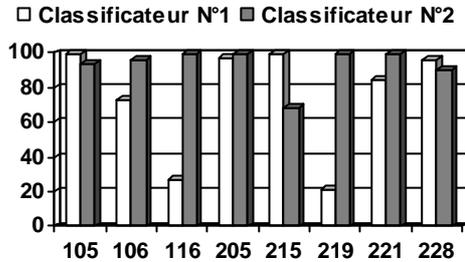
ENREGISTREMENT	CLASSIFICATEUR N°2		
	SE	SP	CC
105	14.63	94.70	93.40
106	83.40	99.93	95.70
116	99.08	99.56	99.54
205	94.36	100	99.85
215	85.98	67.03	67.96
219	80.95	99.95	99.39
221	96.21	100	99.38
228	91.11	90.30	90.41
La moyenne	80.71	93.93	93.20

Tableau N°06 : les lois statistiques du 2^{ème} réseau

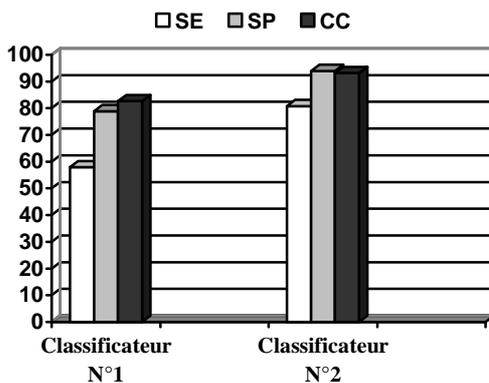
3.2 Interprétation des résultats :

On remarque que le classificateur N°2 qui est composé de 10 neurones a donné des résultats légèrement meilleurs que celles du classificateur N°1 qui est composé de 35 neurones (pour le 1^{er} classificateur : SE=57.94, SP=78.81, CC=82.61; pour le 2^{ème} classificateur : SE=80.71, SP=93.93, CC=93.2).

On peut constater que le réseau multicouche permet de gagner en architecture et en performance par rapport au réseau de Kohonen.



Histogramme N°01: La variation de CC d'un enregistrement à un autre des deux classificateurs



Histogramme N°02: Les lois statistiques des deux classificateurs

III. Conclusion :

D'après les résultats obtenus, nous remarquons que l'apport des réseaux de neurones était de taille sur le plan de précision, de vitesse de calcul et d'architecture ce qui nous encourage dans le futur à penser ? une réalisation Hardware d'un classificateur neuronale des pathologies cardiaques.

Notons finalement, qu'on peut améliorer les performances des classificateurs en tenant compte des points suivants :

⇒ Elargir la base d'apprentissage (On souhaite que dans le futur proche, on peut avoir des enregistrement de l'ECG au niveau du CHU de Tlemcen afin de préparer une base de données propre à notre laboratoire de G.B.M et cela va permettre de développer des classificateurs pour d'autres cas pathologies spécifiques peut être à "la région Tlemcen").

⇒ Exploiter d'autres algorithmes d'apprentissage plus évolués.

⇒ Ajouter d'autres paramètres indicatifs qui peuvent augmenter le taux de reconnaissance des cas

pathologiques du classificateur comme par exemple le calcul précis de la durée du complexe QRS pour chaque cycle.

⇒ Notons que nos classificateurs peuvent être élargis ? d'autres classes :

- La reconnaissance des sous classes d'ESV.
- La reconnaissance d'autres classes ou pathologies cardiaques autre que l'ESV.

Références :

[1]: H.GHOLAM HOSSEINI, H. NAZERAN, "Efficient features for ANN-based ECG classifiers", School of Engineering, The Flinders University of South Australia,1999.

[2]: Dr PHILIPPE MABO," Troubles du rythme-généralités ", Département de cardiologie et maladies vasculaires, CHU de Rennes.

[3]: P.DEGOULET, M.FIESCHI, "Informatique médicale ",3ème édition, Masson, 1998.

[4]:C.P.MAMMEN,B.HASKANRAMARTH, "Classification of cardiac arrhythmias using fuzzy artmap" , IEEE Trans. Biomed. Eng. , vol 43 N04 pp 428.1996.

[5]:KANG.PINGLIN-WALTER, H .CHANG ," QRS Feature Extraction Using Linear prediction ", IEEE Trans .Biomed.eng ;vol.36 N° 10, pp.1050-1055,1989 .

[6]: BENOIT DECOUX, "Reconnaissance de forme - résumé de cours -" ,2000-2001.

[7]: T.KOHNEN," Learning Vector Quantization ", version 3.1.7 avril.1995.

[8]: S.E FAHLMAN ", An empirical study of learning speed in backpropagation networks", Carhenge Mellon University, Computer Science Department, 1988.

[9]: F. BLOYO-M.VERLEYSEN, " Les réseaux de neurones artificiels ", Presse Universitaire De France , 1996 .

[10]: FREDRIC M. HAM - SOOWHAN HAN , " Classification of cardiac arrhythmias using fuzzy ARTMAP", IEEE Transactions Biomedical Engineering ;vol.43,n°4 ,pp. 425-429,1996 .