



REPUBLIQUE ALGERIENNE
DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT
SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE



UNIVERSITE LARBI TEBESSI - TEBESSA
FACULTE DES SCIENCES ET TECHNOLOGIES
DEPARTEMENT DE GENIE ELECTRIQUE

MEMOIRE

DE FIN D'ETUDES POUR L'OBTENTION DU DIPLOME DE MASTER EN

THEME

**Identification Neuronale Des Signaux Dynamiques: Application Sur
L'électrocardiogramme (ECG)**

Présenté par le binôme :

- ZOUANI Oumaima
- RABAH Wafa

Devant le jury :

- | | |
|--------------------|-----------|
| - KHMAISSIA Seddik | Président |
| - AOUCHE Abdelaziz | Encadreur |
| - LEMITA Abdallah | Examineur |



REMERCIEMENTS

Nous remercions ALLAH le tout puissant de nous avoir donné le courage et la volonté de parvenir à la fin de notre parcours universitaire.

Nous tenons à remercier tous ceux qui nous aidé, conseillé et encouragé à fin de réaliser ce modeste travail.

Et n'oublier pas de remercier Dr. Abdelaziz AOUICHE notre encadreur pour tous son soutien et ces conseils qui nous apporté de l'aide dans la réalisation de notre projet.

Nos remerciements vont aussi à tous le corps pédagogique :

Enseignants, administrateurs,

Employés du département de génie électrique ainsi que toutes les personnes de notre faculté.

Dédicaces

Avec un cœur remplie de joies et bonheur je dédie se modeste travail aux personnes les plus chères ou monde :

**A mon cher père 'Mohamed'*

A ce qui Allah distingue avec gloire et révérence, à qui je porte son nom avec fierté, à qui grâce a son souffles je vie et avec sa présence j'attends demain avec optimisme, j'espérais que ALLAH prolongera dans votre vie pour voire les fruits de ce qui a été plantée, , je prie dieu de nous protéger, je vous aime beaucoup.

**A ma chère mère 'Rebah'*

A ma copine, A la source de l'amour, de la compassion et du dévouant. À ceux qui l'appellent le secret de mon succès, à mon fondateur et la source de ma personnalité. Pour le plus cher dans le monde, je prie dieu de nous protéger.

**A mon chère frère 'Achref'.*

A qui je voir la vie par ses yeux, et le bonheur par son sourire, et le joies par son succès.

*الى القلوب المزهرة والنفوس البريئة الى رياحين حياتي و بهجة عمري الى احبابي الصغار الى الفرح الذي يحكيه دعائي
دائما دمتم لي شيئا جميلا لا ينتهي ابدا احبكم (وصال-امنة-اريام) (انس -احمد ياسين)*

**for a friend, a flavor of lover 'NADA'*

Who is not seemed like the other in anything at all, for my miracle and my language of twenty eight letters, for that happiness in the deep of my heart . O ALLAH I loved her in you.

**A mes chères grands parents : (Ahmed, Tounis) ; (Saleh, Aldjeai et Aicha)*

**A mes tantes et mes oncles*

**A ma collègue : Oumaima*

**A ma grande famille*

Dédicaces

Du profond de mon cœur, je dédie ce modeste travail à tous ceux qui me sont chers.

A mon grand-père "ALI" et ma grand-mère "FATMA" :

Je dédie d'abord mon succès à ceux qui ont cessé de les voir et ont continué à parler de leur amour, à ceux qui ont été notre chandelle brillante dans la vie, à ceux qui sont allés avec leur corps et sont restés avec nous avec leurs souvenirs, que Dieu ait pitié (Allah yerhamhoum).

A mon cher père " ABD EL-WAHAB" :

L'épaule solide, l'œil attentif compréhensif et la personne la plus digne de mon estime et de mon respect. Aucune dédicace ne pourrait exprimer mes sentiments, que Dieu te préserve et te procure Santé et longue vie.

A ma très chère aimée mère "ABLA" :

Tu m'a donnée la vie tu es l'exemple de dévouement qui n'a pas cessé de m'encourager et de prier pour moi, Que Dieu, le tout- puissant, te préserve et t'accorde santé, longue vie et bonheur.

J'espère qu'ils trouveront dans ce travail toute ma reconnaissance et tout mon amour.

A mon très chère frère "ABD EL-KADER" :

A la lumière de la vie et le soleil de l'espoir, à celui avec qui j'aime le monde.

Je vous souhaite bonne chance et réussite dans votre vie.

A mon très chère sœur "AMANI" :

A mon bijou brillant et à mon étoile brillante. A mon compagnon de vie. Dieu vous bénisse et vous garde.

A mon petites sœurs "RIHEB" et "CHAIMA" :

Les sourire de vie et la source de bonheur et d'espoir et la source de joie et de plaisir. Bonne chance avec vos vies.

A toute la famille ZOUANI et BELBAKHOUCHE.

A tout ce qui m'ont aidé de près ou de loin pour la réalisation de ce travail.

A Toute la promotion Instrumentation Electronique 2019/ 2020.

*Tous mes ami(e)s.
Tous ceux qui me sont chers.
Tous ceux qui m'aiment.
Tous ceux que j'aime.*

OUMAIMA

Table De Matières

Table de matière

Remerciement	
Dédicace	
Table De Matières	I-V
Introduction générale	01
Chapitre I : Représentation des Signaux Dynamiques Non Linéaires	
I.1 Introduction	03
I.2 Principe de la modélisation mathématique	03
I.3 Structures de modèles non linéaires	06
I.3.1 Modèle de Volterra-Wiener	08
I.4 Modèles dynamiques non linéaires	09
I.4.1 Modèle NFIR	09
I.4.2 Modèle NARX	10
I.4.3 Modèle NOE	11
I.4.4 Modèle NARMAX	12
I.5 Choix des critères d'estimation paramétrique et de sélection de modèle	13
I.5.1 Choix du critère d'estimation paramétrique	14
I.5.2 Choix du critère de sélection de modèle	14
I.6 Estimation des paramètres de modèles	16
I.7. Identification des systèmes	17
I.8. Les structures des identifications	18
I.8.1. Identification parallèle	18

Table de matières

I.8.2. Identification série-parallèle	19
I.9. Modélisation neuronale des systèmes non linéaires	19
I.10. Etude et simulation	20
I.10.1. Cas des systèmes SISO	20
I.10.1.1. Système 1	20
I.10.2. Cas des systèmes MISO	19
I.10.2.1. Système 1	20
I.10.2.2. Système 2	21
I.11. Conclusion	21
Chapitre II : Le signal d'ECG	
II.1. Introduction	22
II.2. Système cardio-vasculaire	22
II.2.1. Cœur humain	23
II.2.2. La circulation sanguine	24
II.2.3. Cycle cardiaque	25
II.2.4. L'activité électrique du cœur	25
II.2.5. Genèse de l'activité électrique cardiaque	26
II.2.5.1. Le potentiel d'action des cellules du myocarde	27
II.2.5.2. Propagation de l'influx électrique	29
II.3. Electrocardiographie	32
II.3.1. Définition	32
II.3.2. Le signal électrocardiogramme (ECG)	32
II.3.2.1. Les ondes du signal ECG	33

Table de matières

II.3.2.2. Les segments et intervalles du signal ECG	35
II.4. A quoi sert l'électrocardiogramme ?	35
II.5. Intérêt de l'électrocardiogramme	36
II.6. SIMULATION MATHEMATIQUE D'UN SIGNAL ECG THEORIQUE	36
II.6.1. Modèle et expression mathématique du motif	36
II.6.2. Valeurs numériques des amplitudes et intervalles	38
II.7. Conclusion	38
 Chapitre III : Les réseaux de neurones 	
III.1. Introduction	39
III.2. Historique	39
III.3. Présentation	40
III.4. Définition	40
III.5. Architecture de réseaux de neurones	42
III.5.1. Réseaux statiques "feed-forward "	42
III.5.1.1. Réseaux multicouches (ou Perceptron Multi Couche PMC)	42
III.5.2. Réseau récurrents "Feed-back"	43
III.6. Quelques types de réseaux de neurones	44
III.6.1. Réseaux à une seule couche (monocouche)	45
III.6.2. Perceptron Multi Couches	45
III.6.3. Réseau à fonction radiale	45
III.7. Avantage des réseaux de neurones	45
III.7.1. Non-linéarité	45
III.8. Neurone formel	45

Table de matières

III.8.1.Représentation mathématique	46
III.8.2. Fonctions d'activation	47
III.8.3.Architecture d'un réseau de neurones artificiel	47
III.8.3.1. Réseaux monocouche	47
III.8.3.2.Réseaux multicouche	47
III.9. Architecture d'un réseau MLP	47
III.10.Processus d'apprentissage dans les réseaux MLP	48
III.10.1.Algorithme d'apprentissage dans un MLP non récurrent	49
III.10.1.1. Evaluation du gradient pour un neurone de sortie	50
III.10.1.2. Evaluation du gradient pour un neurone caché	51
III.10.2. Algorithme d'apprentissage dans un MLP récurrent	52
III.10.2.1. Back propagation Th rough Time (BPTT)	52
III.10.2.2. Real Time Récurrent Learning (RTRL)	52
III.11.Conclusion	53
Chapitre IV : Résultats de Simulation	
IV.1. Introduction	54
IV.2. Présentation des signaux à identifier	54
IV.3. Résultats	55
IV.4. La simulation	57
IV.5.Choix du vecteur d'entrée du notre ECG	60
IV.6.Les équations d'électrocardiogramme (ECG)	62
IV.7.Interprétation des résultats	64
IV.8.Conclusion	65

Table de matières

Conclusion générale	66
Bibliographique	
Résumé	

Introduction générale

Introduction générale

L'organisation mondiale de la santé a reporté que pendant l'année 2030, 23.6 millions de personnes à travers le monde décéderont à cause de maladies cardiovasculaires [1], qui demeurent les premières causes de mortalité du siècle. Suite à ce constat alarmant la détection précoce des dysfonctionnements cardiaques devient une tâche cruciale dans le processus de traitement des pathologies cardiaques.

Depuis son introduction par Einthoven en 1902 l'électrocardiogramme qui représente l'activité électrique du cœur enregistrée à la surface de la peau à des emplacements spécifiques par le biais d'électrodes dites dérivations, demeure un outil de diagnostic efficace des maladies cardiaques. L'ECG fût le sujet de plusieurs recherches pour la détection automatique des arythmies cardiaques [2], aussi il fût utilisé dans beaucoup de travaux relatifs à la biométrie pour l'identification des individus [3]. Cependant son traitement automatique reste toujours une tâche difficile à cause des variations morphologiques de ce signal chez une même personne et chez des personnes différentes.

Ce processus d'automatisation de la détection des anomalies cardiaques se compose de deux étapes essentielles dont la segmentation du signal ECG ; phase qui consiste en l'extraction des caractéristiques de l'ECG, et dont le résultat est la détection des différentes ondes, segments et intervalles constituant les battements cardiaques telles que l'onde P qui reflète l'activité électrique des oreillettes, le complexe QRS qui renseigne sur le fonctionnement des ventricules, l'onde T qui représente leurs repolarisation et les intervalles PR, QT et ST qui informent sur la conduction électrique de divers parties du cœur. A la phase de segmentation succède la détection des anomalies ou des irrégularités du rythme cardiaque dite arythmies qui a reçu un grand intérêt et a fait l'objet de plusieurs investigations, dont entre autre l'utilisation d'algorithmes d'apprentissage tels que les réseaux de neurones, en l'occurrence les perceptrons multicouches. Cette méthode recèle des avantages et des inconvénients, par conséquent l'application de ces algorithmes est tributaire du contexte de leur utilisation. Dans cette étude nous nous focalisons sur l'identification neuronale des signaux dynamiques ainsi une application sur l'Electrocardiogramme (ECG).

Le présent mémoire est reparti en quatre chapitres :

- Le premier chapitre se limite aux signaux dynamiques non linéaires à temps discret de type MISO (multi-entrées, mono-sortie). Pour ces signaux, la sortie est une fonction non linéaire des variables caractéristiques.

- Le deuxième chapitre est dédiée une description générale du système cardio-vasculaire sera faite. Un intérêt particulier sera porté à l'étude du signal électrocardiogramme et sa genèse.

Aussi, la technique d'électrocardiographie. La dernière partie de ce chapitre dispose le modèle mathématique de ce signal fantôme qui permet le calcul théorique des coefficients pour différentes familles de polynômes orthogonaux.

- Le troisième chapitre présente une définition et architecture de réseaux de neurone puis identifiée les types, les avantages et les applications de ce réseau. Outre une représentation du neurone formel. Après cela une brève présentation de l'architecture des réseaux MLP, le processus d'apprentissage des réseaux MLP non récurrents et récurrents est abordé.

- Dans le quatrième chapitre on va appliquer cette technique d'identification sur quatre signaux non linéaires selon leur complexité inclus le signal Electrocardiogramme (ECG), et pour cela on va utiliser l'algorithme du rétro-propagation du gradient qui est un algorithme d'apprentissage supervisé, ainsi que la structure d'identification série-parallèle.

Le mémoire est terminé par une conclusion générale.

Chapitre I

*Représentation des Signaux Dynamiques Non
Linéaires*

I.1 Introduction

La modélisation est une représentation du signal dans le but de satisfaire un besoin préalablement défini. La représentation qu'on va faire du signal, donc le modèle à établir, dépend principalement des objectifs visés. Dans les sciences pour l'ingénieur, on utilise principalement le modèle physique ou le modèle mathématique. Ce chapitre se limite aux signaux dynamiques non linéaires à temps discret de type MISO (multi-entrées, mono-sortie). Pour ces signaux, la sortie est une fonction non linéaire des variables caractéristiques. Après une description du principe de la modélisation mathématique, nous abordons ici différentes structures de modèles de signaux dynamiques non linéaires, les types les plus courants de modèles non linéaires, les critères d'estimation paramétrique et de sélection de modèles ainsi que les méthodes d'estimation paramétrique des modèles non linéaires [4].

Les signaux réels sont difficile à étudier, donc on est amené à les représenter mathématiquement pour pouvoir les commander, Il y a un intérêt considérable pour ces dernières années en explorant l'application des réseaux de neurones artificiels pour l'identification. L'identification des signaux exige la sélection d'une classe de la fonction (ou modèle) pour approximer le comportement entrée-sortie des signaux de la meilleure façon possible. Dans beaucoup de situations, telles que l'identification des signaux dynamiques, le rendement du signal physique à modeler est une fonction des entrées et des sorties antérieures [5].

On va décrire brièvement les différentes méthodes, et les étapes de la conception d'un modèle en utilisant les réseaux de neurones artificiels MLP

I.2 Principe de la modélisation mathématique

La modélisation mathématique est une représentation qui traduit le fonctionnement d'un signal à travers des relations mathématiques liant les différentes variables du signal. Elle peut se faire de deux façons différentes :

➤ **Modélisation théorique** : la représentation du signal est faite à partir des lois (physiques, chimiques, biologiques, etc.) régissant le fonctionnement du signal. Il est donc nécessaire d'avoir une connaissance complète du signal. Cette modélisation peut présenter des difficultés lorsqu'elle est appliquée à des signaux complexes. Les modèles de ce type sont appelés modèles de connaissance ou modèles de type « boîte blanche » [4].

➤ **Modélisation expérimentale** : la représentation est faite sur les bases de données recueillies sur le signal à modéliser. Cette représentation ne requiert aucune connaissance du signal. Les modèles de ce type sont appelés modèles expérimentaux ou de type « boîte noire ». Ils sont représentés en général sous la forme d'une relation de type « entrée-sortie ». Dans certains cas, des connaissances a priori sur le signal permettent de fixer la structure du modèle. La combinaison de ces connaissances a priori et des données expérimentales recueillies permet d'aboutir à une représentation du signal communément appelée modèle de type «boîte grise».

Dans notre travail, nous utilisons la modélisation expérimentale. L'établissement de ce type de modèle est une procédure itérative comportant cinq phases [6] (voir figure I.1) :

- **Extraction de données** : durant cette phase, des mesures sont effectuées sur les variables sensées à caractériser le système. Ces variables peuvent être des variables externes qui agissent sur le signal (entrées de commande ou perturbations mesurables), des variables internes qui traduisent l'état du signal (variables d'état), ou la réponse du signal (variable de sortie). Il existe souvent des perturbations non mesurables qui agissent sur le signal (en entrée ou en sortie) rendant plus difficile sa modélisation [4].
- **Choix de la structure du modèle** : il s'agit de définir d'une façon formelle la relation expliquant le fonctionnement du signal. Cette relation correspond à une famille de fonctions mathématiques dont une seule correspond au modèle recherché [4].
- **Choix du critère d'estimation paramétrique** : c'est le choix de la fonction objectif (fonction coût) dont l'optimisation (minimisation) permet de déterminer la structure du modèle de façon unique. Ce critère est en fonction de l'écart entre la sortie du signal et celle du modèle. Le critère quadratique est généralement choisi [4].
- **Estimation paramétrique** : de la famille de fonctions obtenues du choix de la structure du modèle, il faut en déterminer une qui représente convenablement le signal. Il s'agit alors de trouver la valeur des paramètres permettant la satisfaction d'un critère de performance donné (optimisation de la fonction objectif) [4].
- **Validation du modèle** : c'est une procédure qui permet d'évaluer l'exactitude (ou la fidélité) du modèle. Pendant cette phase, le modèle est testé avec des données non utilisées pendant la phase d'identification [4].

Il existe deux grandes catégories de modèles :

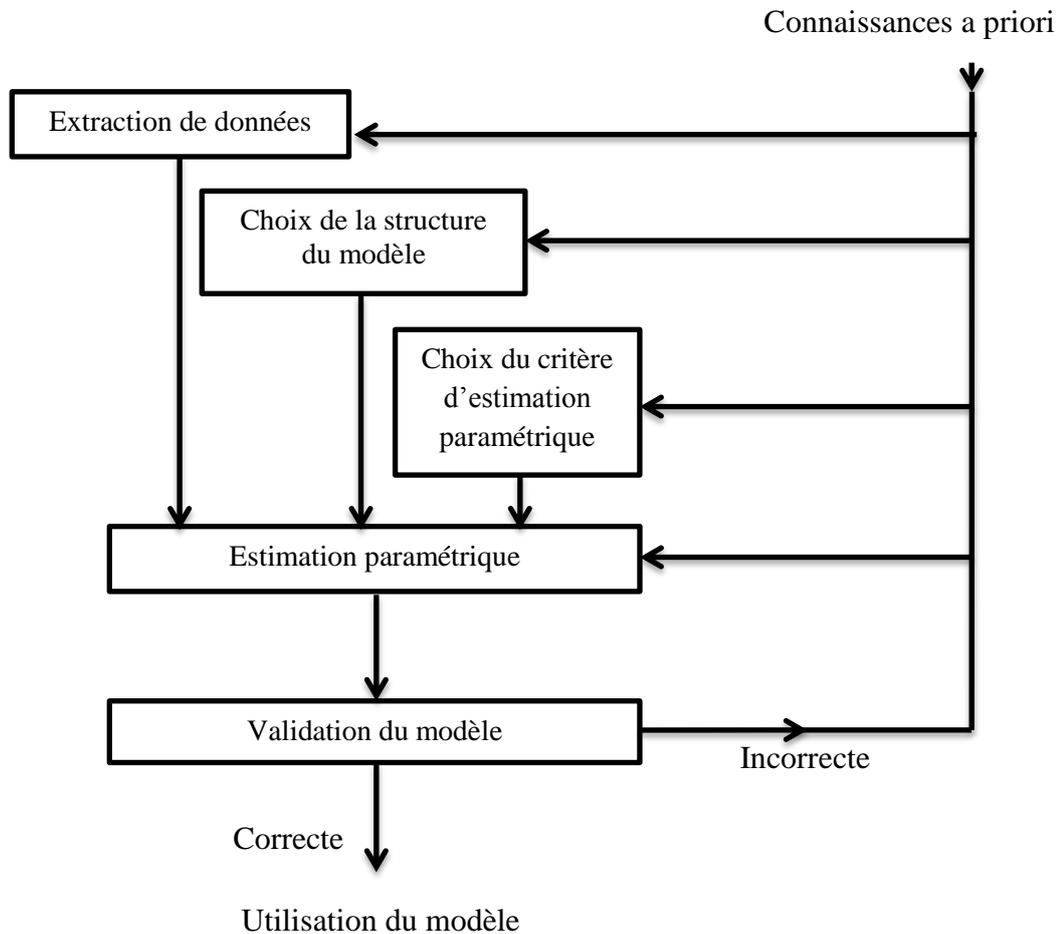


Fig.1.1 – Procédure d'identification d'un système.

1. Les modèles de prédiction qui fonctionnent en parallèle avec le signal et pour lesquels la sortie du signal à l'instant $t + h$ est estimée à partir des entrées et des sorties disponibles jusqu'à l'instant t , h étant le pas de prédiction. Si $h = 1$ le modèle correspond à un prédicteur un pas. Ces modèles sont très utilisés dans l'industrie, la prédiction météorologique, la prédiction du taux de pollution, la prédiction des cours en bourse, etc.
2. Les modèles de simulation qui fonctionnent indépendamment du signal et pour lesquels la sortie inconnue est estimée en se basant sur les entrées externes du signal. Ces modèles permettent entre autre : l'extrapolation du fonctionnement du signal dans des conditions dont la réalisation expérimentale est difficile, dangereuse voire coûteuse, la synthèse de correcteur pour un signal de commande, etc.

Les modèles que nous étudions dans ce travail font partie de l'une ou l'autre de ces deux catégories [4].

I.3 Structures de modèles non linéaires

La construction d'un modèle « boîte noire » d'un signal repose sur l'hypothèse selon laquelle il existe une relation déterministe liant les entrées du signal à sa sortie. D'une manière générale, le modèle *prédictif* de comportement d'un signal dynamique Non linéaire peut s'écrire sous la forme :

$$y_s(t+h) = f_s(\underline{u}(t), \underline{\tilde{y}}_s(t)) + e(t+h) \quad (\text{I.1})$$

Où :

$y_s(t+h)$ est la sortie du signal à l'instant $t+h$, h étant le pas de prédiction ; $f_s(\cdot)$ est une fonction non linéaire déterministe inconnue, appelée prédicteur théorique ; $\underline{u}(t)$ est un vecteur dont les composantes sont des éléments des entrées externes du signal à l'instant courant t et/ou aux instants antérieurs :

$$\begin{aligned} \underline{u}(t) = & [u_1(t), u_1(t-1), \dots, u_1(t-n_{u_1}+1), \dots, \\ & u_k(t), u_k(t-1), \dots, u_k(t-n_{u_k}+1), \dots, \\ & u_{n_i}(t), u_{n_i}(t-1), \dots, u_{n_i}(t-n_{u_{n_i}}+1)]^T \end{aligned}$$

avec n_{u_k} l'ordre de l'entrée u_k , $k = 1, \dots, n_i$; n_i étant le nombre d'entrées ; $\underline{\tilde{y}}_s(t)$ est un vecteur dont les composantes sont liées à l'état du signal à l'instant courant t et/ou aux instants antérieurs ;

On peut avoir par exemple :

$$\underline{\tilde{y}}_s(t) = [y_s(t), y_s(t-1), \dots, y_s(t-n_{y_s}+1)]^T$$

Avec n_{y_s} l'ordre de la sortie y_s ;

$e(t+h)$ est une variable aléatoire de moyenne nulle et de variance σ^2 représentant le bruit. La représentation formelle donnée par la relation (I.1) intègre les connaissances a priori du signal ainsi que des hypothèses concernant son comportement : connaissance des variables descriptives, caractère statique ou dynamique, linéaire ou non linéaire, présence ou absence de perturbations.

Le modèle est statique si la sortie à l'instant t ne dépend que des entrées à l'instant t , il est dynamique si la sortie dépend aussi des entrées et/ou sorties antérieures. Le modèle est linéaire si $y_s(t+h)$ est une combinaison linéaire de $\underline{u}(t)$ et de $\underline{\tilde{y}}_s(t)$. Dans le cas contraire, il est non linéaire. Le modèle est récurrent si $\underline{\tilde{y}}_s(t)$ comporte des variables d'état estimés à l'instant courant t et/ou aux instants antérieurs. A l'inverse, si la sortie du modèle ne dépend que des entrées et/ou des sorties mesurées, le modèle est non récurrent. L'estimation paramétrique des modèles non linéaires récurrents est un problème majeur en identification. L'un des principaux apports de ce travail de thèse est la mise en place d'une méthodologie d'estimation paramétrique de modèles non linéaires récurrents. En considérant la sortie du signal comme une variable aléatoire $y_s(t)$ dont une réalisation est $y_s(t)$, on peut écrire [7] :

$$Y_s(t+h) = E[Y_s(t+h)|t] + e(t+h) \quad (I.2)$$

Où $E[y_s(t+h)|t]$ est l'espérance mathématique conditionnelle de $y_s(t+h)$, lorsqu'on dispose de toutes les informations disponibles jusqu'à l'instant courant t , et $e(t+h)$ correspondent à la partie non prédictible de $y_s(t+h)$ à l'instant t (erreur de modélisation). La sortie y du signal, donnée par le modèle $F_s(\cdot)$, est :

$$y(t+h) = E[Y_s(t+h)|t] = F_s(\underline{u}(t), \underline{\tilde{y}}_s(t)) \quad (I.3)$$

la fonction $F_s(\cdot)$ est approchée par la fonction $F(\cdot)$ de structure connue paramétrée par un vecteur $\underline{\theta}$. La sortie \hat{y} estimée par ce prédicteur réel est :

$$\hat{y}(t+h) = F(\underline{u}(t), \underline{\tilde{y}}_s(t), \underline{\theta}) = F(\underline{\varphi}(t), \underline{\theta}) \quad (I.4)$$

Où $\underline{\varphi}(t) = [\underline{u}(t)^T, \underline{\tilde{y}}_s(t)^T]^T$ est le vecteur de régression ou d'information constitué de l'ensemble des variables explicatives du signal dans la zone de validité du modèle. Il est obtenu par la concaténation des éléments des vecteurs $\underline{u}(t)$ et $\underline{\tilde{y}}_s(t)$. Chaque élément de $\underline{\varphi}(t)$ est appelé régresseur

L'erreur de prédiction du modèle est obtenue par :

$$\varepsilon(t) = y_s(t) - \hat{y}(t) \quad (I.5)$$

La détermination des régresseurs est un problème majeur rencontré en modélisation expérimentale. L'idéal est de ne sélectionner que les variables caractéristiques des non-linéarités du signal. Ces variables étant inconnues, plusieurs démarches sont proposées pour la sélection des entrées [8,9]. L'une d'elle, comme expliquée dans [9], consiste à choisir un ensemble de variables d'entrée le plus grand possible permettant d'obtenir le « modèle complet ». Les performances de ce modèle sont comparées à celles des modèles dont les variables d'entrée constituent des sous-ensembles des variables du « modèle complet ». Le modèle qui présente les meilleures performances est choisi. Avec cette démarche le nombre de modèle croît de façon exponentielle avec le nombre de variables, ce qui complique la mise en œuvre. Des stratégies sous-optimales (décrites dans [9]) mais plus simples à mettre en œuvre sont souvent utilisées en pratique. Il s'agit de la stratégie d'élimination (« stepwise backward regression ») et de la stratégie de construction (« stepwise forward regression »). Dans ce travail, nous ne traitons pas le problème de la sélection des entrées et considérons que les variables permettant de décrire les signaux à étudier sont connues. La description du signal donnée par l'équation (I.4) conduit à deux questions fondamentales: l'identification structurelle de la fonction $F(\cdot)$ et l'estimation paramétrique.

L'identification structurelle consiste à choisir une structure de $F(\cdot)$ adéquate pour la description du système. L'estimation paramétrique de $F(\cdot)$ consiste à estimer la valeur $\hat{\underline{\theta}}$ de $\underline{\theta}$ qui minimise une norme de l'écart entre la sortie réelle du signal y_s et celle du modèle \hat{y} pour l'ensemble des observations :

$$\hat{\underline{\theta}} = \underset{\underline{\theta}}{\operatorname{arg\,min}} \left(\left\| y_s(t+h) - F(\varphi(t), \underline{\theta}) \right\| \right) \quad (\text{I.6})$$

La valeur $\hat{\underline{\theta}}$ détermine la structure choisie pour $F(\cdot)$ de façon unique. La variété des modèles de représentation des signaux dynamiques non linéaires repose sur le choix de la structure de la fonction $F(\cdot)$.

I.3.1 Modèle de Volterra-Wiener

Le modèle de Volterra-Wiener [10], l'un des plus anciens, est basé sur une décomposition en série, soit pour un signal mono-entrée :

$$y(t) = \sum_{i=1}^{\infty} y_i(t) \quad (\text{I.7})$$

$$y_i(t) = \sum_{T_1=1}^{t-1} \dots \sum_{T_i=1}^{t-1} h_i(T_1, \dots, T_i) u(t-T_1) u(t-T_i) \quad (\text{I.8})$$

Où $h_i(T_1, \dots, T_i)$ est la réponse impulsionnelle d'ordre i du signal. Cette représentation n'a pas connu beaucoup de succès en identification, vu le nombre très élevé de paramètres qu'elle engendre.

I.4 Modèles dynamiques non linéaires

Les connaissances a priori du signal à modéliser, prises en compte dans la représentation (1.4), intègrent le choix des variables explicatives et la manière dont le bruit agit sur le signal. Le bruit peut agir sur la sortie, sur l'état ou sur la sortie et l'état à la fois. Ces informations sont spécifiées lors de la constitution du vecteur de régression qui permet ainsi de déterminer la classe du modèle non linéaire. On distingue différentes classes de modèles non linéaires. Le choix d'un de ces modèles est indépendant du choix de la structure de la fonction $F(\cdot)$. Ainsi, un même modèle non linéaire peut par exemple être représenté avec une structure neuronale ou multi modèle. Le choix de la structure doit permettre d'obtenir un modèle parcimonieux (faible erreur avec un minimum de paramètres). Tout au long de ce travail, les performances des structures MLP et multi modèles sont étudiées à travers l'implantation de quelques modèles non linéaires qui seront présentés ici.

I.4.1 Modèle NFIR

Le modèle NFIR (Non linear Finite Impulse Response) permet de représenter des signaux non linéaires dont la sortie ne dépend que des entrées à l'instant courant et/ou aux instants antérieurs.

$$\begin{aligned}
 y_s(t+1) = & F_s(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\
 & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\
 & u_{n_1}(t-d_{u_{n_1}}+1), u_{n_1}(t-d_{u_{n_1}}), \dots, u_{n_1}(t-d_{u_{n_1}}-n_{u_{n_1}}+2)), \\
 & +e(t+1)
 \end{aligned} \tag{I.9}$$

Où :

$d_{u_k} \geq 1$ est le retard correspondant à l'entrée u_k ; $n_{u_k} \geq 1$ est la mémoire sur l'entrée u_k , avec $k = 1, \dots, n_i$, n_i nombre d'entrées.

Le pas de prédiction h défini dans (I.1) peut être déterminé par :

$$h = \min(d_{u_k}), \quad k = 1, \dots, n_i$$

Le prédicteur réel du modèle NFIR est la fonction non linéaire $F(\cdot)$ de structure Connue, paramétrée par un vecteur $\underline{\theta}$ qui, convenablement choisi, permettrait d'obtenir une erreur de prédiction ayant les mêmes caractéristiques statistiques que le bruit:

$$\begin{aligned} \hat{y}(t+1) = & F(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\ & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\ & u_{n_i}(t-d_{u_{n_i}}+1), u_{n_i}(t-d_{u_{n_i}}), \dots, u_{n_i}(t-d_{u_{n_i}}-n_{u_{n_i}}+2), \underline{\theta} \end{aligned} \quad (I.10)$$

Puisque le vecteur de régression du modèle NFIR ne dépend que des entrées externes, le modèle est non récurrent [11, 12, 13, 14].

I.4.2 Modèle NARX

Le modèle NARX (Nonlinear AutoRegressive with eXogenous input) permet de représenter des signaux dynamiques non linéaires dont la sortie dépend des entrées passées et des sorties mesurées passées. Il permet également la représentation de signaux dynamiques non linéaires avec « bruit d'état » :

$$\begin{aligned} x(t+1) = & F_s(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\ & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\ & u_{n_i}(t-d_{u_{n_i}}+1), u_{n_i}(t-d_{u_{n_i}}), \dots, u_{n_i}(t-d_{u_{n_i}}-n_{u_{n_i}}+2), \\ & x(t-d_x+1), x(t-d_x), \dots, x(t-d_x-n_x+2)) + e(t+1) \\ & y_s(t) = x(t) \end{aligned} \quad (I.11)$$

Où :

x désigne l'état du signal et y_s sa sortie ;

$d_x \geq 1$ et $n_x \geq 1$ représentent le retard et l'ordre de la variable x respectivement.

Le prédicteur réel $F(\cdot)$ du model NARX est :

$$\begin{aligned}
 \hat{y}(t+1) = & F(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\
 & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\
 & u_{n_i}(t-d_{u_{n_i}}+1), u_{n_i}(t-d_{u_{n_i}}), \dots, u_{n_i}(t-d_{u_{n_i}}-n_{u_{n_i}}+2), \dots, \quad (I.12) \\
 & y_s(t-d_{y_s}+1), y_s(t-d_{y_s}), \dots, y_s(t-d_{y_s}-n_{y_s}+2), \underline{\theta})
 \end{aligned}$$

Où :

$d_{y_s} > 1$ est le retard correspondant à la sortie mesurée y_s ; $+n_{y_s} \geq 1$ est l'ordre de la partie autorégressive de y_s .

Le pas de prédiction h défini dans (I.1) peut être déterminé par :

$$h = \min(d_{u_k}, d_{y_s})$$

Le modèle NARX (appelé aussi modèle à Erreur d'Equation ou « Equation Error » en anglais) est un modèle non récurrent, tous les régresseurs étant des mesures faites sur le signal (le vecteur de régression est constitué des entrées passées u_k et des sorties mesurées passées de y_s) [11, 12, 13, 14].

I.4.3 Modèle NOE

Le modèle NOE (Nonlinear Output Error) permet de représenter des signaux dynamiques non linéaires par estimation de la sortie à un instant t à partir des entrées antérieures et des sorties antérieures estimées. Il permet également la représentation de signaux dynamiques non linéaires avec « bruit de sortie » :

$$\begin{aligned}
 x(t+1) = & F_s(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\
 & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\
 & u_{n_i}(t-d_{u_{n_i}}+1), u_{n_i}(t-d_{u_{n_i}}), \dots, u_{n_i}(t-d_{u_{n_i}}-n_{u_{n_i}}+2), \dots, \quad (I.13) \\
 & x(t-d_x+1), x(t-d_x), \dots, x(t-d_x-n_x+2)) \\
 y_s(t) = & x(t) + e(t)
 \end{aligned}$$

Le prédicteur réel $F(\cdot)$ du model NOE est :

$$\begin{aligned}
 \hat{y}(t+1) = & F(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\
 & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\
 & u_{n_i}(t-d_{u_{n_i}}+1), u_{n_i}(t-d_{u_{n_i}}), \dots, u_{n_i}(t-d_{u_{n_i}}-n_{u_{n_i}}+2), \\
 & \hat{y}(t-d_{\hat{y}}+1), \hat{y}(t-d_{\hat{y}}), \dots, \hat{y}(t-d_{\hat{y}}-n_{\hat{y}}+2), \underline{\theta})
 \end{aligned} \tag{I.14}$$

Où $d_{\hat{y}}$ et $n_{\hat{y}}$ sont le retard et l'ordre associé à \hat{y} . Le pas de prédiction est :

$$h = \min(d_{u_k}, d_{\hat{y}})$$

Le vecteur de régression est constitué des entrées passées u_k et des sorties passées estimées \hat{y} , ce qui fait du modèle NOE un modèle récurrent. C'est un modèle qui convient bien à la simulation puisqu'il n'utilise pas les sorties réelles du signal [11, 12, 13, 14].

I.4.4 Modèle NARMAX

NARMAX désigne Nonlinear AutoRegressive Moving Average with eXogenous input. Ce modèle permet de représenter un signal dynamique non linéaire par estimation de la sortie à un instant t à partir des entrées passées, des sorties mesurées passées et des erreurs de prédiction passées. Le modèle NARMAX est aussi utilisé pour représenter un signal dynamique non linéaire en présence de « bruit d'état et bruit de sortie » :

$$\begin{aligned}
 y_s(t+1) = & F_s(u_1(t-d_{u_1}+1), u_1(t-d_{u_1}), \dots, u_1(t-d_{u_1}-n_{u_1}+2), \dots, \\
 & u_k(t-d_{u_k}+1), u_k(t-d_{u_k}), \dots, u_k(t-d_{u_k}-n_{u_k}+2), \dots, \\
 & u_{n_i}(t-d_{u_{n_i}}+1), u_{n_i}(t-d_{u_{n_i}}), \dots, u_{n_i}(t-d_{u_{n_i}}-n_{u_{n_i}}+2), \\
 & y_s(t-d_{y_s}+1), y_s(t-d_{y_s}), \dots, y_s(t-d_{y_s}-n_{y_s}+2), \\
 & e(t-d_e+1), e(t-d_e), \dots, e(t-d_e-n_e+2)) \\
 & +e(t+1)
 \end{aligned} \tag{I.15}$$

Où $d_e \geq 1$ et $n_e \geq 1$ sont le retard et la mémoire correspondant à la variable aléatoire. Les valeurs $e(t - d_e + 1), e(t - d_e), \dots, e(t - d_e - n_e + 2)$ n'étant pas mesurables, ce prédicteur est irréalisable. Cependant en supposant que ces valeurs peuvent être estimées par celles de l'erreur de prédiction $(t) = y_s(t) - \hat{y}(t)$, on peut obtenir le prédicteur réel du modèle NARMAX :

$$\begin{aligned}
 \hat{y}(t + 1) = & F(u_1(t - d_{u_1} + 1), u_1(t - d_{u_1}), \dots, u_1(t - d_{u_1} - n_{u_1} + 2), \dots, \\
 & u_k(t - d_{u_k} + 1), u_k(t - d_{u_k}), \dots, u_k(t - d_{u_k} - n_{u_k} + 2), \dots, \\
 & u_{n_k}(t - d_{u_{n_k}} + 1), u_{n_k}(t - d_{u_{n_k}}), \dots, u_{n_k}(t - d_{u_{n_k}} - n_{u_{n_k}} + 2, \\
 & y_s(t - d_{y_s} + 1), y_s(t - d_{y_s}), \dots, y_s(t - d_{y_s} - n_{y_s} + 2), \quad (I.16) \\
 & \varepsilon(t - d_\varepsilon + 1), \varepsilon(t - d_\varepsilon), \dots, \varepsilon(t - d_\varepsilon - n_\varepsilon + 2), \underline{\theta})
 \end{aligned}$$

Où $d_\varepsilon \geq 1$ et $n_\varepsilon \geq 1$ représentent le retard et la mémoire correspondant à l'erreur de prédiction ε .

Le pas de prédiction est :

$$h = \min(d_{u_k}, d_{y_s}, d_\varepsilon)$$

Le vecteur de régression du modèle NARMAX est constitué des entrées passées u_k , des sorties mesurées passées de y_s et des erreurs de prédiction ε . C'est donc un modèle récurrent. Le modèle NARMAX est un excellent outil pour l'analyse, la modélisation et la prédiction de séries temporelles [11, 12, 13, 14].

I.5 Choix des critères d'estimation paramétrique et de sélection de modèle

La fonction non linéaire $F(\cdot)$ définie par l'équation (I.4) peut être choisie parmi les structures présentées au paragraphe §1.3 : $F(\cdot)$ peut être un modèle flou, un modèle neuronal, un multi modèle, etc. Quelle que soit la structure adoptée pour la fonction $F(\cdot)$, on aboutit toujours à une famille de fonctions paramétrées par $\underline{\theta}$. Une procédure d'identification paramétrique doit permettre d'estimer $\underline{\theta}$ de façon à ce qu'un critère de performance J (ou fonction de coût) du modèle soit optimal. Cependant, dans la mesure où plusieurs possibilités existent pour représenter un seul et même signal, il est nécessaire de disposer d'un outil de comparaison,

C'est-à-dire, d'un critère de sélection de modèles. Cet outil, basé sur des critères de performances à atteindre, permet de sélectionner le meilleur modèle. Par ailleurs, le choix de la structure de modèle s'accompagne de la détermination de sa topologie interne (par exemple, nombre de règles pour un modèle flou, nombre de neurones cachés pour un neuronal ou nombre de modèles locaux pour un multi modèle). L'utilisation d'un critère de sélection de modèles permet aussi de déterminer la meilleure topologie pour une structure de modèle donnée ([15, 16, 17]).

I.5.1 Choix du critère d'estimation paramétrique

L'estimation des paramètres d'un modèle se fait en optimisant un critère de performance dans le but d'approcher la sortie du signal par celle du modèle. Ce critère de performance est une fonction de l'écart (ou résidu) ε entre la sortie réelle du signal et celle du modèle :

$$\varepsilon(t) = y_s(t) - \hat{y}(t) \quad (\text{I.17})$$

Le critère quadratique est le plus utilisé. Il s'exprime par :

$$J = \frac{1}{2} \sum_{t=1}^k \varepsilon(t)^2 \quad (\text{I.18})$$

Où k désigne le nombre d'observations considérées.

Dans certains cas, si la variance du bruit varie fortement pour certaines observations,

Il est nécessaire d'utiliser le critère quadratique pondéré défini par :

$$J = \frac{1}{2} \sum_{k=1}^k \omega(t) \varepsilon(t)^2 \quad (\text{I.19})$$

Où $\omega(t)$ est la fonction de pondération affectée au résidu $\varepsilon(t)$, de façon à réduire l'influence des points situés dans les zones de forte variance ([15, 16, 17]).

I.5.2 Choix du critère de sélection de modèle

La structure du modèle détermine sa complexité en termes de nombre de paramètres nécessaires pour décrire le signal et de procédure d'estimation de ces paramètres. L'objectif est d'obtenir un modèle qui soit, d'une part, aussi simple que possible comportant un minimum de paramètres, et d'autre part, aussi précis que possible en disposant d'une bonne capacité de généralisation.

L'estimation de la capacité de généralisation d'un modèle nécessite la disposition d'une base de données de test n'ayant pas été utilisée dans la phase d'apprentissage. Cela réduit la base d'apprentissage et peut donc conduire à des pertes d'informations. Des méthodes de sélection de modèles basées sur la parcimonie (moins de paramètres et plus de précision) ont été élaborées ([15, 16, 17]).

La méthode de validation croisée consiste à diviser la base d'apprentissage en k sous-ensembles de tailles identiques et à procéder à k étapes d'identification-validation.

A chaque étape, $k - 1$ sous-ensembles sont utilisés pour l'identification et le dernier sous ensemble pour la validation. L'erreur quadratique moyenne de généralisation (Mean Squared Generalization Error - MSGE) est ensuite évaluée par :

$$MSGE = \frac{1}{k} \sum_{j=1}^k \sum_{t=1}^{N_j} (y_s(t) - y_j(t))^2 \quad (I.20)$$

Où $y_j(\cdot)$ est le modèle identifié à l'itération j et N_j la taille du sous-ensemble de validation à l'itération j .

La structure de modèle permettant d'avoir la plus petite MSGE est sélectionnée. Parmi les différents modèles de cette structure, le modèle $y_j(\cdot)$ ayant la plus petite erreur sur les données de test est choisi.

D'autres critères de sélection de modèles ayant la particularité de ne pas réduire la base d'apprentissage ont été élaborés [18, 19, 20]. Ces critères font intervenir deux termes dont l'un permet de mesurer la qualité de l'estimation paramétrique (valeur du critère d'estimation) et l'autre de pénaliser la complexité du modèle estimé (nombre de paramètres utilisés). En effet si le modèle comporte trop de paramètres (sur-ajustement), il aura tendance à modéliser le bruit. Si par contre le modèle comporte peu de paramètres (sous-ajustement), il ne sera pas à mesure d'expliquer le signal. Parmi ces critères de sélection, on peut noter :

Critère d'information d'Akaike (Akaike Information Criterion - AIC) : Ce critère détermine la complexité du modèle en minimisant la fonction d'information théorique définie par :

$$AIC = N \ln J + 2n_\theta \quad (I.21)$$

Où N est le nombre de données d'observation sur le signal et n_θ est le nombre de paramètres dans le modèle. Le terme $2n_\theta$ permet d'introduire une pénalité sur le nombre de paramètres pour les modèles complexes. Le modèle retenu est celui qui minimise le critère AIC (plus de précision avec moins de paramètres).

Critère de l'erreur de prédiction finale d'Akaike : (Akaike's Final Prediction Error Criterion - FPE) : ce critère est défini par :

$$FPE = \frac{1}{2} \frac{N+n_\theta}{N-n_\theta} J \quad (I.22)$$

Le terme $(N + n_\theta)/(N - n_\theta)$ décroît avec n_θ . Il représente une pénalité pour la surparamétrisation. Critère de la longueur de description minimum de Rissanen : (*Rissanen's Minimum Description Length0 Criterion - MDL*) : l'idée est de trouver « la plus simple description possible » des données. Le critère est défini par :

$$MDL = \ln J + \frac{n_\theta}{N} \ln N \quad (I.23)$$

La « plus simple description » correspond au minimum du critère MDL.

Ces critères de sélection sont basés sur des considérations statistiques avec les hypothèses suivantes [21, 22] :

- ✓ le vrai modèle du signal est correctement spécifié ou sur-paramétré par les modèles candidats;
–les paramètres du modèle sont identifiables ;
- ✓ les données de validation possèdent les mêmes propriétés statistiques du deuxième ordre que les données d'estimation.

Le critère MDL est surtout utilisé si peu de données sont disponibles. L'expression (I.22) du critère FPE montre que le terme de pénalité n'est pas très significatif si le nombre de paramètres n_θ est très petit devant le nombre d'observations N . Pour ces raisons, le critère de sélection AIC est utilisé tout au long de cette mémoire. Mais dans le cadre de la toolbox développée, l'utilisateur a le choix entre plusieurs critères de sélection de modèles.

I.6 Estimation des paramètres de modèles

L'identification paramétrique résulte de la minimisation du critère J défini par la relation (I.18). Cependant deux cas sont à considérer :

- Premier cas : l'ensemble des données (base d'apprentissage DN constituée de N données d'observation sur le signal) nécessaires à l'identification est disponible et l'estimation est faite sur cet ensemble simultanément : on parle alors de méthodes globales de minimisation. L'évaluation du critère J se fait sur toute la base d'apprentissage D_N . Le problème d'optimisation décrit par l'équation (I.6) peut se mettre sous la forme suivante :

$$\underline{\hat{\theta}} = \arg \min_{\underline{\theta}} (J(\underline{\theta}, D_N)) \quad (\text{I.24})$$

$$J(\underline{\theta}, D_N) = \frac{1}{2} \sum_{t=1}^N \varepsilon(t, \underline{\theta})^2 \quad (\text{I.25})$$

$$\varepsilon(t, \underline{\theta}) = y_s(t) - \hat{y}(t, \underline{\theta}) \quad (\text{I.26})$$

L'inconvénient de cette approche est la nécessité de disposer de l'ensemble des éléments du vecteur de régression $\varphi(t)$ (voir relation (I.4)) avant de pouvoir identifier le modèle. Cette démarche ne s'applique pas aux modèles récurrents qui, en dehors des données issues des mesures, font intervenir des données issues du modèle en cours d'identification. L'approche ne convient pas non plus à l'identification en temps réel de signaux pour lesquels les données

***Remarque :** En général, lorsque les unités de mesure diffèrent d'une variable à l'autre, il est recommandé de normaliser les variables afin d'atténuer l'effet d'échelle et obtenir des paramètres de même ordre de grandeur nécessaires ne sont pas entièrement disponibles.*

- Deuxième cas : certaines données nécessaires à l'identification des modèles récurrents ne sont pas entièrement disponibles (par exemple sorties estimés ou erreurs de prédiction). Il convient alors de faire une estimation récursive qui permet une estimation des paramètres au fur et à mesure que les données sont disponibles.

La minimisation du critère J se fait de proche en proche sur des sous-ensembles réduits de DN où toutes les données nécessaires sont disponibles. Cette approche est aussi adaptée à l'identification en temps réel de signaux. [23, 24].

Les paragraphes suivants décrivent différentes méthodes d'estimation paramétrique des modèles non linéaires.

I.7. Identification des signaux

L'identification est la détermination, sur la base de la connaissance d'un nombre fini d'entrées-sorties du signal, d'un modèle appelé modèle d'identification, l'identification consiste

à déterminer un ensemble d'équations –un modèle- décrivant le mieux possible le procédé. Il y a deux étapes dans le travail la première consiste à fixer la forme des équations, c'est l'étape qualitative, ou caractérisation, la seconde consiste à trouver les valeurs numériques des coefficients qui interviennent dans ces équations, c'est l'étape quantitative, ou estimation des paramètres. Ces valeurs numériques sont déterminées pour que le comportement de modèle soit le plus proche de celui du signal [25].

I.8. Les structures d'identification

La sortie d'un signal dynamique dépend de son entrée et de son état ultérieur, c'est pour cela qu'il existe deux classes de modèle d'identification [26].

I.8.1. Identification parallèle

Dans le cas d'un signal dynamique à temps discret, la sortie du modèle est calculée à partir de ses entrées et sorties passées

$$\hat{y}(k + 1) = NN[\hat{y}(k), \hat{y}(k - 1), \dots, \hat{y}(k - n + 1); u(k), u(k - 1), \dots, u(k - m + 1)] \quad (I.27)$$

Certaines précautions doivent être prises lors de l'identification, la principale étant d'utiliser des entrées bornées et sorties bornées, le signal reste stable, il est dit BIBO (Bunded Input Bonded Output).L'inconvénient de l'identification parallèle est que même avec un signal, rien ne garantit que les paramètres vont converger et que $e_i \rightarrow 0$ [26].

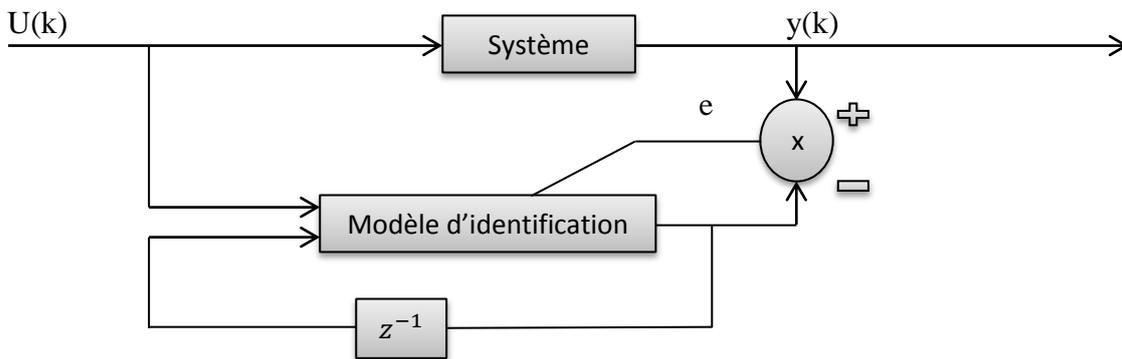


Fig. I.2 - Structure d'identification parallèle

I.8.2. Identification série-parallèle

La sortie du modèle est calculée à partir de ses entrées et la sortie du signal à identifier

$$\hat{y}(k + 1) = f[y(k), y(k - 1), \dots, y(k - n + 1); u(k), u(k - 1), \dots, u(k - m + 1)] \quad (I.28)$$

Ce modèle a plus de chances de converger, car tous les signaux utilisés lors de l'identification sont bornés [26].

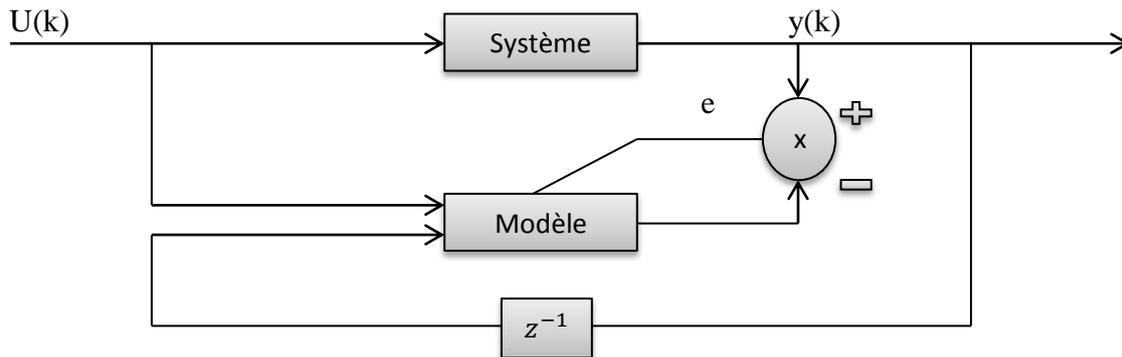


Fig. I.3 - Structure d'identification série-parallèle

I.9. Modélisation neuronale des signaux non linéaires

- Acquisition des données d'apprentissage et de test,
- Choix de la structure du modèle,
- Estimation des paramètres du modèle,
- Validation du modèle identifié.

La première étape fournit les données entrées/sorties susceptibles de permettre l'extraction d'un modèle de procédé significatif, la deuxième étape consiste à choisir la structure du modèle susceptible de représenter la dynamique du signal, l'architecture du réseau de neurones et ses entrées. Les réseaux multicouches statiques sont les plus utilisés à cause de la simplicité de leurs algorithmes d'apprentissage et leurs aptitudes à l'approximation et à la généralisation. Il n'existe pas de méthodes générales pour le choix du nombre de neurones sur chaque couche cachée ainsi que le nombre de ces dernières. Cependant, un réseau à une seule couche cachée est dans la majorité des cas suffisant [27].

I.10. Étude et simulation

I.10.1. Cas des signaux SISO

I.10.1.1. Signal 1

On a un système d'ordre 2 représenté par l'équation aux différences suivantes :

$$y(k + 1) = f[y(k)] + u(k) \quad (\text{I.29})$$

Où la fonction inconnue f est donnée par :

$$f[y(k)] = \frac{y(k)}{1+y^2(k)} \quad (\text{I.30})$$

Le modèle d'identification est décrit par :

$$\hat{y}(k + 1) = \hat{f}[y(k)] + u(k) \quad (\text{I.31})$$

Où l'entrée du système et du modèle est donnée par :

$$u(k) = \sin\left(\frac{2\pi k}{25}\right) + \sin\left(\frac{2\pi k}{50}\right) \quad (\text{I.32})$$

I.10.2. Cas des signaux MISO

I.10.2.1. Signal 1

Soit un système d'ordre 2 décrit par l'équation aux différences suivante :

$$y(k + 1) = f[y(k), y(k - 1)] + u(k) \quad (\text{I.33})$$

Où f est donnée par :

$$f[y(k), y(k - 1)] = \frac{y(k)y(k-1)[y(k)+2.5]}{1+y^2(k)+y^2(k-1)} \quad (\text{I.34})$$

Le modèle d'identification est décrit par :

$$\hat{y}(k + 1) = \hat{f}[y(k), y(k - 1)] + u(k) \quad (\text{I.35})$$

L'entrée du système et du modèle est donnée par

$$u(k) = \sin\left(\frac{2\pi k}{25}\right) \quad (\text{I.36})$$

I.10.2.2. Signal 2

Soit un système d'ordre 2 décrit par l'équation aux différences suivante :

$$y(k + 1) = f[y(k), y(k - 1), y(k + 2), u(k), u(k - 1)] \quad (I.37)$$

Où f est donnée par :

$$f[y(k), y(k - 1)] = \frac{y(k)*y(k-1)*y(k-2)*u(k-1)*(y(k-2)-1)+u(k)}{1+y(k-2)*y(k-2)+y(k-1)*y(k-1)} \quad (I.38)$$

Le modèle d'identification est décrit par :

$$\hat{y}(k + 1) = \hat{f}[y(k), y(k - 1), y(k + 2), u(k), u(k - 1)] \quad (I.39)$$

L'entrée du système et du modèle est donnée par

$$u(k) = 0.8 * \sin\left(\frac{2\pi k}{250}\right) + 0.2 * \sin\left(\frac{2\pi k}{25}\right) \quad (I.40)$$

I.11 Conclusion

Dans ce chapitre, nous avons présenté les différents aspects liés à la représentation des signaux dynamiques non linéaires. Différents modèles non linéaires ainsi que différentes structures de représentations permettant leur implantation ont également été présentés. Les méthodes d'estimation paramétrique les plus fréquemment utilisées ont aussi été présentées. Ces méthodes sont utilisées dans les chapitres suivants. Le principe de la sélection des modèles, basée sur des critères de performances mesurant la parcimonie ou la capacité de généralisation, a également été abordé. Aussi, nous avons étudié dans ce chapitre le problème de l'identification des systèmes non linéaires, nous avons vu qu'il existe plusieurs modèles d'identification pouvant être utilisés pour l'identification de ce type de systèmes. Dans les chapitres suivants, des méthodologies améliorant l'identification des systèmes dynamiques non linéaires seront mises en œuvre ainsi que les méthodes à base des réseaux de neurone artificiels.

Chapitre II

Le signal d'ECG

II.1. INTRODUCTION

Le cœur est l'organe central du système cardiovasculaire, il peut être affecté par de nombreuses pathologies qui peuvent soit être bénignes, comme certaines tachycardies par exemple, soit s'avérer très sérieuses, comme l'infarctus du myocarde. Avec l'évolution des techniques, les médecins disposent aujourd'hui d'outils performants pour observer le fonctionnement du muscle cardiaque et dresser ainsi leur diagnostic. Parmi les examens cardiologiques possibles, l'électrocardiogramme (ECG) est l'examen le plus couramment effectué [28].

L'ECG est l'abréviation d'Electrocardiogramme, il représente l'activité électrique du cœur. L'analyse de ce signal électrique a été et continue d'être une voie obligée pour la compréhension de l'électrophysiologie cardiaque ainsi que l'aide au diagnostic. C'est un complément nécessaire à l'imagerie médicale qui permet une bonne résolution spatiale mais souvent à un prix plus cher. Au contraire, l'enregistrement de l'activité électrique donne accès à une haute résolution temporelle (couramment en ms). Cet enregistrement peut se faire soit par voie externe, à l'aide d'électrodes posées à la surface du corps, soit par voie interne en introduisant une sonde en do cavitaire, soit encore en enregistrant l'activité électrique à la surface du cœur [29]

Au niveau de ce chapitre, une description générale du système cardio-vasculaire sera faite. Un intérêt particulier sera porté à l'étude du signal électrocardiogramme et sa genèse. Aussi, la technique d'électrocardiographie. La dernière partie de ce chapitre dispose le modèle mathématique de ce signal fantôme qui permet le calcul théorique des coefficients pour différentes familles de polynômes orthogonaux.

II.2. Système cardio-vasculaire

Le système cardio-vasculaire appelé aussi système circulatoire assure la circulation du sang d'une manière continue dans l'organisme. Il permet ainsi d'alimenter les tissus cellulaires en oxygène et en nutriments et d'évacuer les déchets vers les reins et le dioxyde de carbone vers les poumons. Ce système est composé d'un organe pompe, le cœur, et d'un réseau continu et fermé de conduits qui permettent le transport du sang, le système vasculaire (les veines et les artères) [30].

II.2.1. Cœur humain

Le cœur est un muscle creux (poids 270g chez l'adulte), à contraction rythmique dont la fonction est d'assurer la progression du sang à l'intérieur des vaisseaux. Le cœur est situé dans le thorax entre les deux poumons, il repose sur le diaphragme dans le médiastin antérieur, derrière le sternum et en avant de la colonne vertébrale. Le cœur est de forme pyramidale triangulaire [31].

Le cœur se compose de deux ventricules et de deux oreillettes (figure II.1). Chaque oreillette droite et gauche communique avec le ventricule correspondant. Dans l'oreillette droite (OD) arrivent les deux veines caves, la veine cave supérieure (VCS) et les veine caves inférieure (VSI) et dans l'oreillette gauche (OG), les quatre veines pulmonaires gauche (VPG) et les veines pulmonaires droite (VPD) qui amènent le sang au cœur, le sang est expulsé du ventricule gauche (VG) par l'aorte (Ao), et du ventricule droite (VD) par l'artère pulmonaire (AP). Les artères les veines et les capillaires forment les tubes conducteurs ou vaisseaux [32]- [33]; chaque oreillette droite et gauche communique avec le ventricule correspondant par des orifices auriculo ventriculaires munis d'un système valvulaire. Celui-ci est composé de deux valves, à gauche la valve mitral (VM) et à droite la valve tricuspide (VT) ; l'artère pulmonaire est pourvue d'un système anti-reflux : les trois valvules sigmoïdes pulmonaires (VSP). L'artère est, elle aussi, pourvue d'un système valvulaire sigmoïde : les valvules sigmoïdes aortiques (VSAo). Ces appareils valvulaires n'autorisent le passage de sang que des oreillettes aux ventricules.

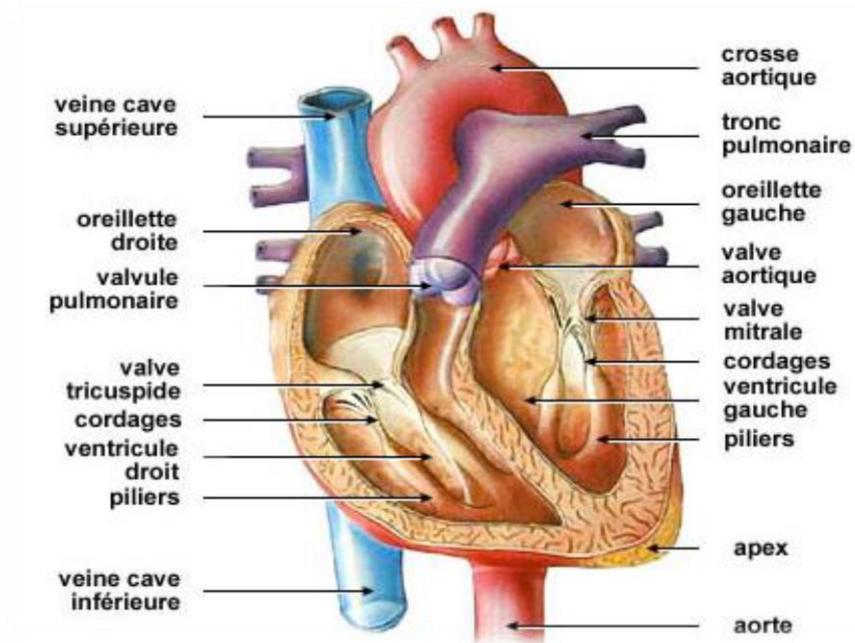


Fig.II.1: Structure interne du cœur.

II.2.2. La circulation sanguine :

La circulation sanguine débute quand le cœur se détend entre deux battements [34] : le sang s'écoule des deux oreillettes dans les ventricules, qui se dilatent ensuite. La période suivante est la période d'éjection, c'est-à-dire lorsque les deux ventricules pompent le sang dans les grandes artères.

Dans la circulation systémique, le ventricule gauche pompe du sang riche en oxygène dans l'artère principale (aorte). Le sang circule de l'artère principale vers les artères plus grandes et plus petites et dans le réseau capillaire. Là, le sang tombe de l'oxygène, des nutriments et d'autres substances importantes et ramasse le dioxyde de carbone et les déchets. Le sang, qui contient peu d'oxygène, est recueilli dans les veines et se dirige vers l'oreillette droite et dans le ventricule droit.

C'est ici que commence la circulation pulmonaire : le ventricule droit pompe le sang à faible teneur en oxygène dans l'artère pulmonaire, qui se ramifie en artères et capillaires de plus en plus petites. Les capillaires forment un fin réseau autour des vésicules pulmonaires (sacs aériens ressemblant à du raisin à la fin des voies respiratoires). C'est à cet endroit que le sang libère du dioxyde de carbone dans l'air à l'intérieur des vésicules pulmonaires et que de l'oxygène frais pénètre dans le sang. Lorsque nous expirons, le dioxyde de carbone quitte notre corps. Le sang riche en oxygène circule dans les veines pulmonaires et l'oreillette gauche dans le ventricule gauche. Le battement de cœur suivant commence un nouveau cycle de circulation systémique. L'ensemble de ces étapes forme la circulation sanguine illustrée sur la figure II.2. [35]

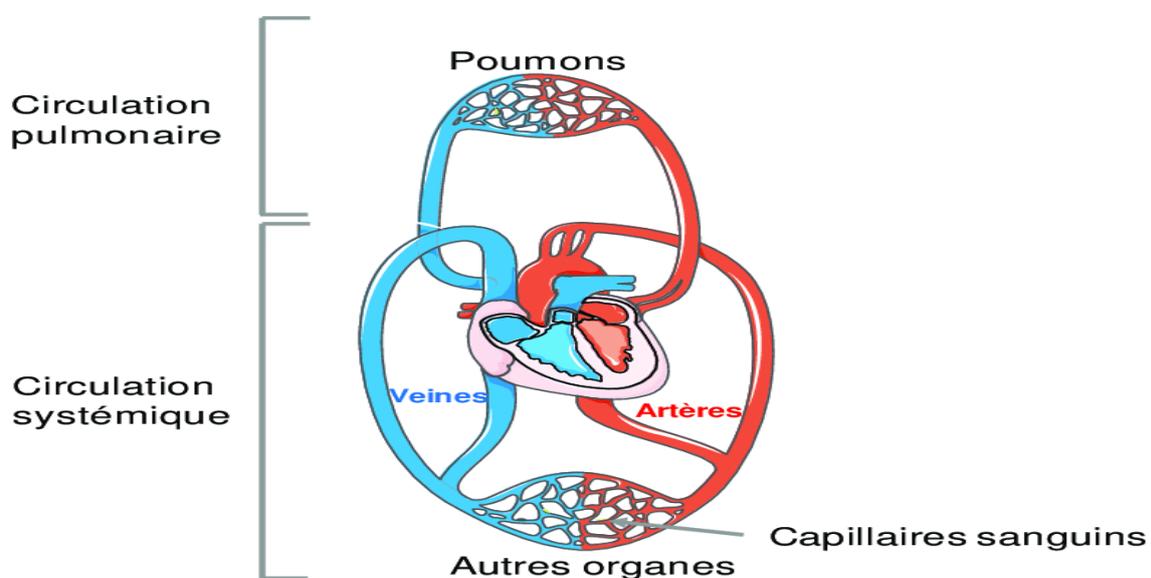


Fig.II.2:La circulation sanguine

II.2.3. Cycle cardiaque

Chaque battement du cœur entraîne une séquence d'événements mécaniques et électriques collectivement appelés cycle cardiaque. Celui-ci consiste en trois étapes majeures : la systole auriculaire, la systole ventriculaire et la diastole.

Dans la systole auriculaire, les oreillettes se contractent et projettent le sang vers les ventricules. Une fois le sang expulsé des oreillettes, les valvules auriculo-ventriculaires entre les oreillettes et les ventricules se ferment. Ceci évite un reflux du sang vers les oreillettes. La systole ventriculaire implique la contraction des ventricules expulsant le sang vers le système circulatoire. Une fois le sang expulsé, les deux valvules, pulmonaires à droite et aortique à gauche se ferment. Enfin, la diastole est la relaxation de toutes les parties du cœur, permettant le remplissage passif des ventricules et l'arrivée de nouveau sang. Les phases de contraction harmonieuses des oreillettes et des ventricules sont commandées par la propagation d'une impulsion électrique. Lorsque la fréquence cardiaque change, la diastole est raccourcie ou rallongée tandis que la durée de la systole reste relativement stable [36].

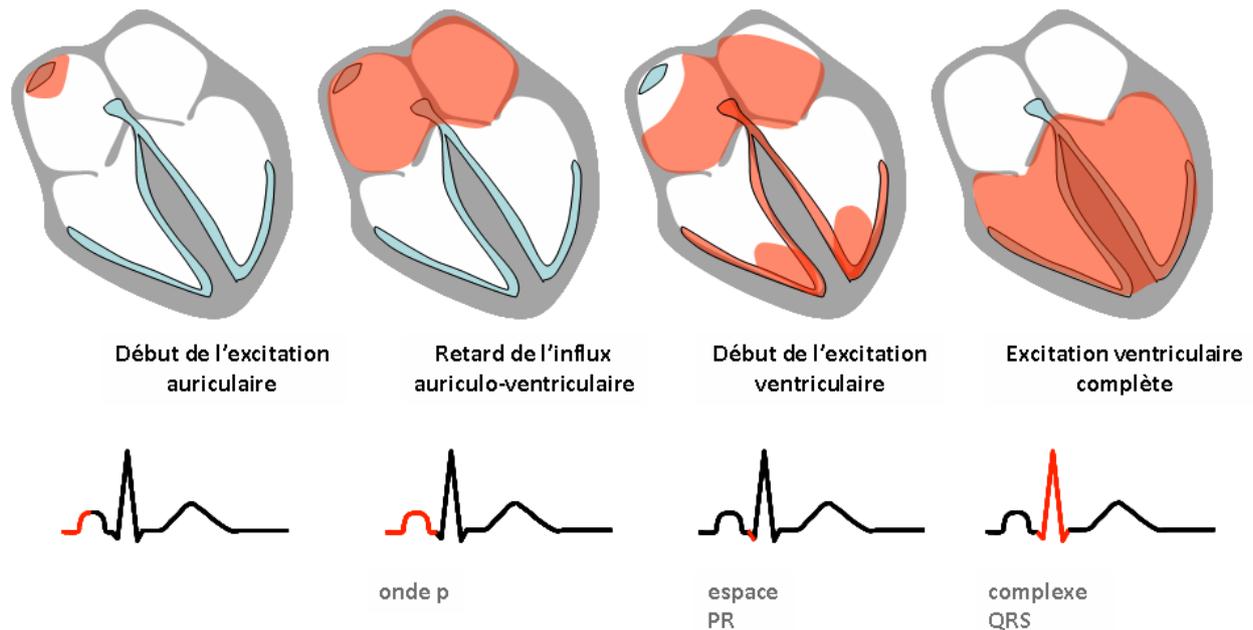
II.2.4. L'activité électrique du cœur

Le cycle cardiaque est formé par deux phases, la première est l'activité de contraction ou la systole, et la deuxième c'est la diastole. Toutes les cellules myocardiques du cœur au repos sont polarisées, et leurs mises en activité se traduisent par la suppression de la polarisation (la dépolarisation). L'ensemble de polarisation/dépolarisation constitue le cycle cardiaque. L'activité électrique sur la figure (II.3) décrit la genèse d'un cycle cardiaque, l'onde de dépolarisation se propage à travers un système de conduction qui est composé d'un tissu musculaire spécialisé qui génère et distribue les influx électriques stimulant la contraction des fibres musculaires cardiaques, L'activité électrique peut être décrite par les étapes suivantes [37]:

1. Formation de l'impulsion de stimulation dans le nœud sino-auriculaire(SA).
2. Activation des oreillettes: l'électrocardiogramme enregistre une petite onde dite l'onde P.
3. Activation du nœud auriculo-ventriculaire et du faisceau de His : l'électrocardiogramme revient à la ligne isoélectrique.
4. Activation des ventricules (activation des branches suivie de celle des parois internes) l'électrocardiogramme enregistre plusieurs déflexions formant le complexe QRS.
5. lorsque toutes les parties du myocarde sont activées, l'électrocardiogramme enregistre de nouveau une ligne isoélectrique: le segment ST.

6. Lors de la ré-polarisation ventriculaire l'électrocardiogramme enregistre une onde T.
7. Pendant la ré-polarisation tardive de quelques régions de myocarde, l'électrocardiogramme pourrait enregistrer une onde U.

L'ECG normale est donc caractérisé par trois ondes principales: P, QRS et T, l'onde P représente la dépolarisation auriculaire, le complexe QRS caractérise la dépolarisation des ventricules. L'onde T traduit la ré-polarisation ventriculaire.



Activité électrique intrinsèque et analyse ECG

Fig.II.3:L'activité électrique du cœur.

II.2.5. Genèse de l'activité électrique cardiaque

Comme pour tous muscles, la contraction du myocarde est due à la propagation d'une impulsion électrique le long des fibres musculaires cardiaques induite par la dépolarisation des cellules musculaires. Le cœur est doté d'un réseau intrinsèque de cellules conductrices qui produisent et propagent des impulsions électriques, ainsi que des cellules qui répondent à ces impulsions par une contraction. L'influx électrique du myocarde naît du nœud sinusal (ou nœud de Keith & Flack), pacemaker naturel du cœur, puis après avoir traversé l'oreillette, cette stimulation électrique passe par le nœud auriculo-ventriculaire (ou nœud d'Aschoff- Tawara) puis rejoint les ventricules via le réseau de distribution nodal c'est à dire, le faisceau de His, les branches de Tawara et le réseau terminal de Purkinje. Durant tout le battement cardiaque (systole et diastole), les myocytes sont le siège de phénomènes complexes électriques membranaires et intracellulaires, responsable de la contraction. Chaque myocyte est le siège d'échanges

membranaires dans lesquels sont impliqués différents ions : le sodium Na^+ , le potassium K^+ , le calcium Ca^{2+} et le chlorure Cl^- .

Les variations de potentiels électriques observées au cours d'un cycle cardiaque correspondent à des modifications de la perméabilité membranaire entraînant des échanges ioniques. Au repos, l'intérieur de la membrane cellulaire est chargé négativement par rapport à l'extérieur. Cette différence de potentiel (potentiel de repos cellulaire) dépend des concentrations ioniques dans les milieux intra- et extracellulaire ; pour les cellules ventriculaires, sa valeur est voisine de -90 mV. Quand une impulsion électrique d'amplitude suffisante agit sur une cellule excitable, l'intérieur de la cellule devient rapidement positif par rapport à l'extérieur à cause des échanges ioniques décrits par la suite. Ce processus correspond à la dépolarisation cellulaire et il se poursuit par le processus de repolarisation cellulaire, c'est à dire lorsque la cellule revient à son état de repos [38, 39,40].

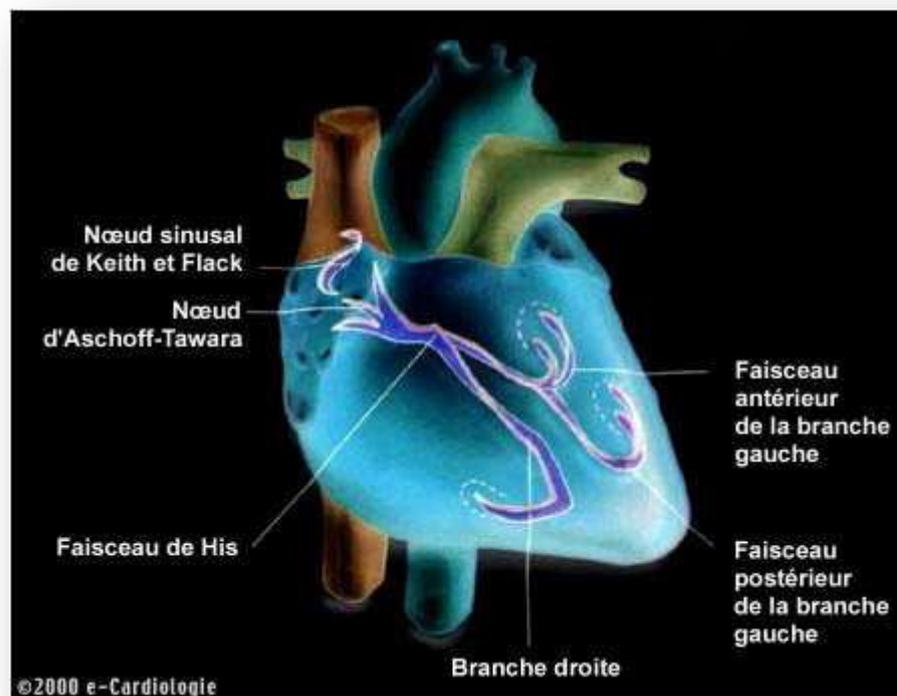


Fig.II.4. : Schéma du réseau de conduction électrique du cœur

II.2.5.1. Le potentiel d'action des cellules du myocarde

Les myocytes ont une différence de potentiel (DP) électrique de part et d'autre de leurs membranes due aux différences de concentrations en ions sodium Na^+ , potassium K^+ , calcium Ca^{2+} et chlorure Cl^- .

Au repos, il existe une différence de concentrations entre le potentiel intracellulaire qui est négatif et le potentiel extracellulaire qui est positif, cette différence étant de l'ordre de -90 mV. La contraction du myocyte est due d'une inversion de cette différence de potentiel : ce phénomène constitue un potentiel d'action (PA). Ces phénomènes électriques s'accompagnent d'une inexcitabilité électrique durant la période réfractaire tout d'abord totale, puis relative du myocarde.

Les échanges ioniques transmembranaires qui se déroulent durant la contraction du myocyte définissent le potentiel d'action, qui se décline en cinq phases successives :

- La phase 0 ou dépolarisation rapide : après une excitation électrique au-dessus du seuil d'activation de la cellule, un afflux rapide d'ions Na^+ rentre dans la cellule et inverse rapidement la polarité de la cellule.
- La phase 1 ou début de repolarisation : elle est caractérisée par une repolarisation rapide et de courte durée, due à l'inactivation des canaux Na^+ et au flux sortant d'ions de potassium K^+ .
- La phase 2 ou plateau : elle correspond à la phase de repolarisation lente. Elle est due à l'entrée lente des ions Ca^{2+} dans la cellule qui atténue l'influence des canaux K^+ continuant à sortir, ralentissant ainsi la phase de repolarisation.
- La phase 3 ou repolarisation : elle correspond à la phase de repolarisation finale, et se caractérise par la fermeture de canaux ioniques spécifiques qui ramène la cellule au potentiel de repos originel. Durant cette phase, les ions K^+ sont toujours sortants tandis que le potentiel de la cellule tend vers son seuil de repos.
- La phase 4 : elle correspond au potentiel de repos, où la cellule est plus facilement excitable.

Il existe une période durant laquelle toute nouvelle excitation est incapable de produire un nouveau potentiel d'action : c'est la période réfractaire absolue. Cette période commence dès la phase zéro du potentiel d'action et se termine à la moitié de la phase trois environ (aux alentours de -50 mV), le myocyte est durant cet instant inexcitable. A cette phase succède une période réfractaire relative durant laquelle il n'y a normalement pas réponse du myocyte sauf pour un stimulus de forte intensité. Ces périodes réfractaires sont dues aux états d'inactivation par lesquels passent les canaux sodiques et calciques avant de retrouver leur état de disponibilité initial [14].

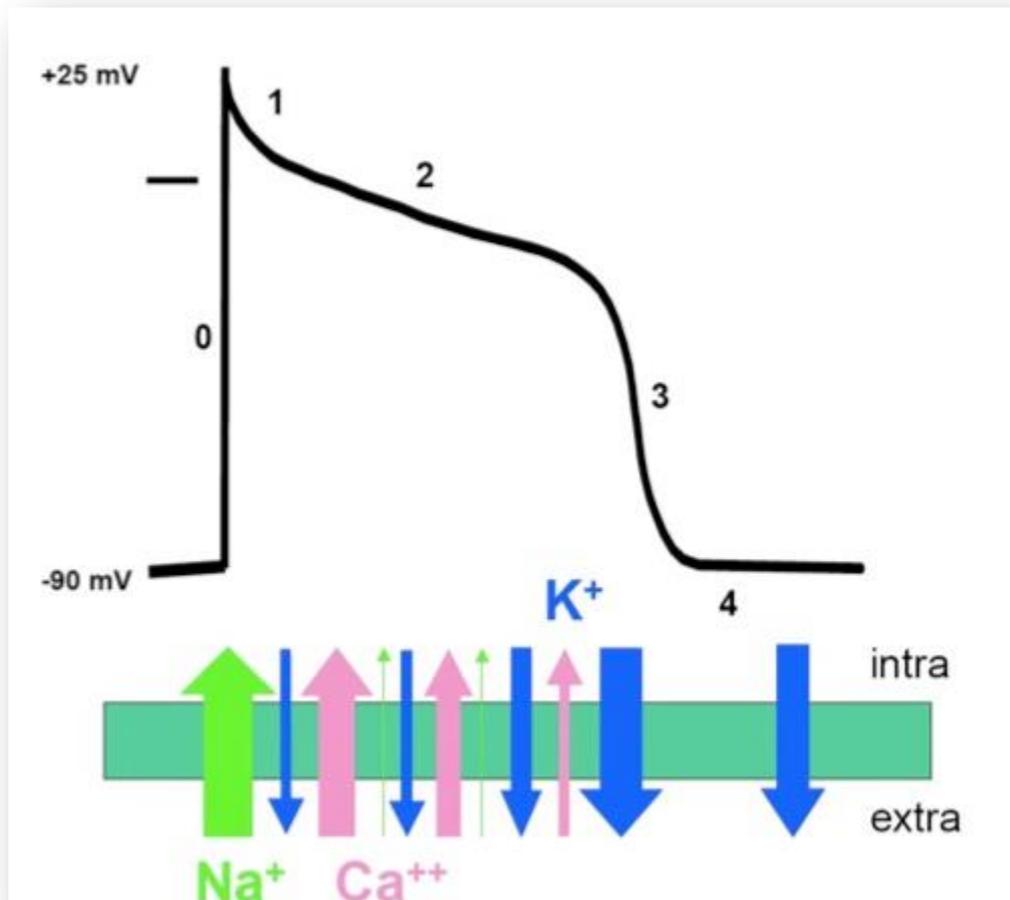


Fig.II.5. : Les cinq phases du potentiel d'action du myocyte et échanges ioniques au niveau cellulaire correspondants : respectivement, la phase 0 correspond à la dépolarisation de la cellule, la phase 1 au début de la repolarisation, la phase 2 à la repolarisation lente, la phase 3 à la repolarisation rapide, et la phase 4 au repos.

II.2.5.2. Propagation de l'influx électrique

C'est la propagation de l'influx électrique qui entraîne l'apparition d'une activité électrique et mécanique au sein de chaque myocyte. Sous l'effet de cet influx, la surface cellulaire se dépolarise rapidement, donnant naissance à un courant électrique, qui entraîne la contraction, puis c'est le temps de repolarisation, plus lente, qui ramène le myocyte dans son état électrique initial.

L'influx électrique voyage au sein du cœur dans un réseau de conduction électrique présenté schématiquement sur les figures II. 4 et II. 6. Il prend naissance dans le nœud sinusal, situé dans la partie haute de la paroi intérieure de l'oreillette droite. Il s'agit d'un petit ensemble de cellules d'environ un centimètre de diamètre situé à la jonction de la veine cave supérieure et de l'oreillette droite. Ce nœud sinusal est le stimulateur cardiaque, le "pacemaker" physiologique.

Il émet 60 à 100 stimuli par minute en fonctionnement normal, et il est influencé par les systèmes nerveux sympathique et parasympathique, définis par la suite.

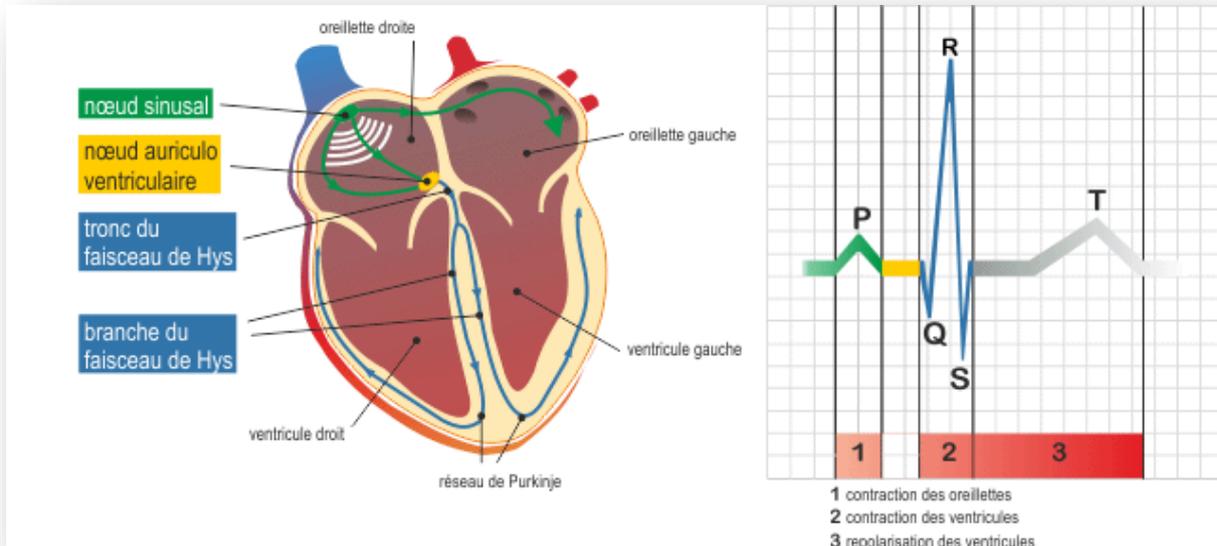


Fig.II.6. : Propagation de l'influx électrique

L'influx électrique diffuse à partir de ce point aux deux oreillettes et au nœud auriculo-ventriculaire (AV) qui se trouve en bas de l'oreillette droite. Ce nœud auriculo-ventriculaire a une forme de petit nodule de cinq millimètres de diamètre et joue un double rôle. Il agit comme un ralentisseur au niveau passage AV de l'onde de dépolarisation, grâce aux fibres alpha à conduction lente. Il permet également la transmission de l'onde de dépolarisation vers les ventricules via le réseau de His-Purkinje. Le nœud auriculo-ventriculaire peut également être influencé par les systèmes sympathique et parasympathique.

Ensuite, l'influx électrique poursuit son chemin au travers du tronc du faisceau de His puis de ses deux branches droite et gauche (branches de Tawara). Ce faisceau, localisé dans la partie haute du septum inter-ventriculaire, passe au travers d'un tissu connectif, mais non excitable, qui permet de séparer électriquement les oreillettes des ventricules. Enfin, l'influx électrique termine son trajet au sein du réseau de Purkinje qui le diffuse dans les parois des ventricules. Ce réseau électrique est sous l'influence du seul système sympathique et permet la régularité du rythme cardiaque et assure un synchronisme entre les contractions des oreillettes puis celles des ventricules [38,41].

Sur un cœur normal, la seule voie de propagation entre les oreillettes et les ventricules est l'axe compris entre le nœud AV et le faisceau de His. Notons également que la forme du potentiel d'action est fonction du tissu qu'il traverse, comme nous pouvons le voir sur le figure II.7.

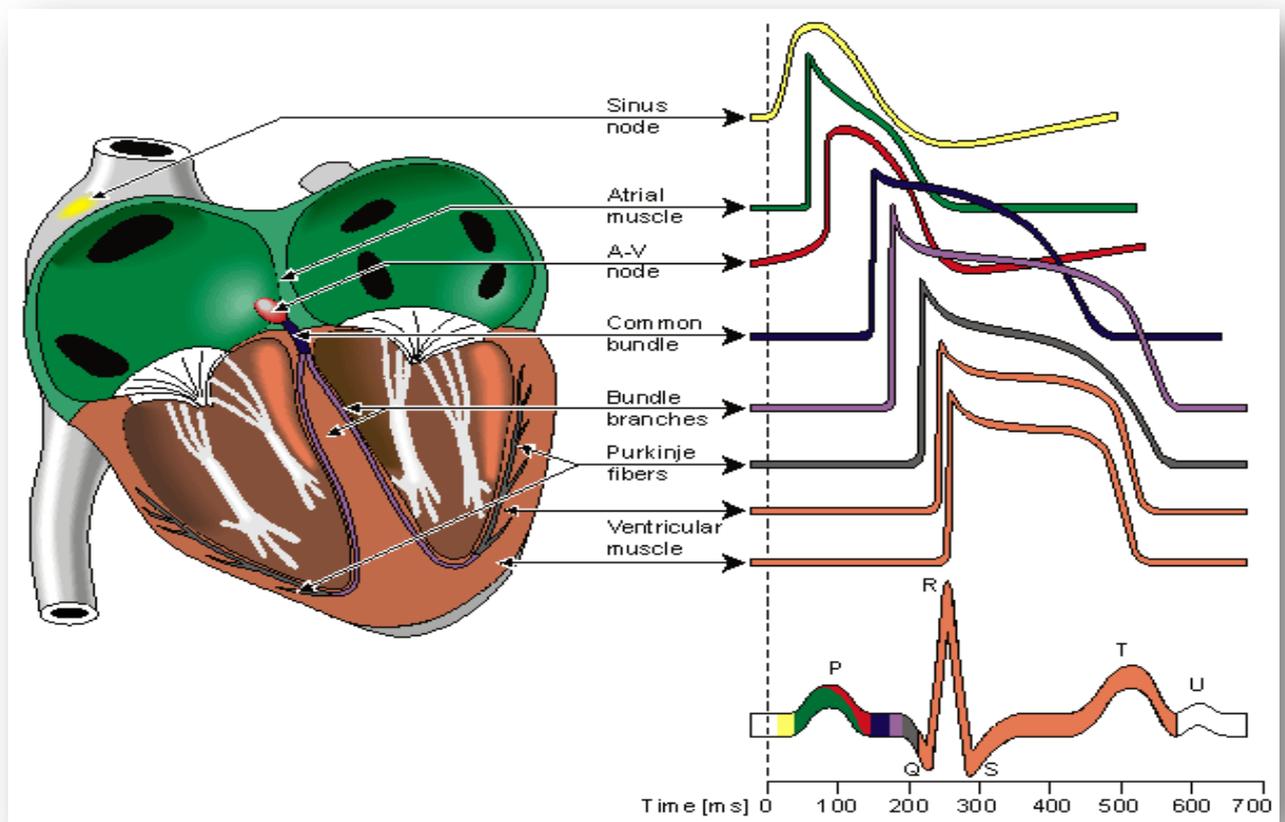


Fig.II.7 : Genèse du cycle cardiaque

Les caractéristiques durée/ amplitude du cycle cardiaque [42]-[43] sont données dans le tableau II.1 et le graphe correspondant par la figure II.5:

Durées et amplitudes des différentes ondes :

Onde ou Intervalle	Onde P	Intervalle PQ	Complexe QRS	Intervalle ST	Intervalle QT	Onde T
Durée (s)	(P_d) 0.08-0.1	(PQ_d) 0.12-0.2	0.08	(ST_d) 0.20	(QT_d) 0.36	0.2
Amplitude (mv)	(P_a) 0.25	Isoélectrique	$Q_a < 0,$ $R_a > 0,$ $S_a < 0$	Isoélectrique	-	$T_a > 0$

Tableau.II.1 : Caractéristique du cycle cardiaque [42]-[43]

II.3. Electrocardiographie

II.3.1. Définition

L'électrocardiographie (ECG) est la représentation graphique du potentiel électrique qui commande l'activité musculaire du cœur. Ce potentiel est recueilli par des électrodes mises à la surface de la peau.

L'électrocardiographie est constitué en général de :

- Un ensemble d'électrodes destinées à être appliquées en contact direct du patient.
- Un système d'amplification des signaux issus des électrodes.
- Un appareil enregistreur.
- Un système d'enregistrement graphique.

L'ECG est née en 1887 avec les travaux de Waller [44], révélée à la communauté médicale par l'invention en 1901 du galvanomètre à cordes, qui valut à son auteur, le Dr. Wilhem Einthoven, le prix Nobel de Médecine en 1924, l'électrocardiographie est devenue une technique incontournable en pratique cardiologique [45].

Les dérivations précordiales sont utilisées pour le diagnostic médical à partir de 1932 et les dérivations frontales unipolaires à partir de 1942, ce qui permet à Emanuel Goldberger de réaliser le premier tracé sur 12 voies.

Aujourd'hui l'électrocardiographie est une technique relativement peu coûteuse, permettant à l'aide d'un examen indolore et sans danger, de surveiller l'appareil cardio-circulatoire, notamment pour la détection des troubles du rythme et la prévention de l'infarctus du myocarde [46]-[47].

II.3.2. Le signal électrocardiogramme (ECG)

Le signal électrocardiogramme ECG est l'enregistrement de l'activité électrique du cœur. Ce signal électro physiologique est sous forme d'une série d'ondes électriques, aux formes et durées particulières, qui se répètent à chaque cycle cardiaque. En réalité, ces ondes traduisent les différents phénomènes mécaniques et électriques relatifs au parcours du potentiel d'action et dont les étapes sont successives comme illustré dans la figure II.8 [48].

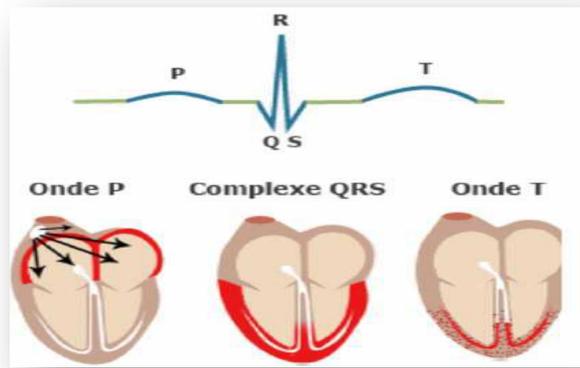


Fig.II.8 : ondes du signal ECG

II.3.2.1. Les ondes du signal ECG

La figure .9 présente la morphologie du signal ECG normal sur un cycle cardiaque.

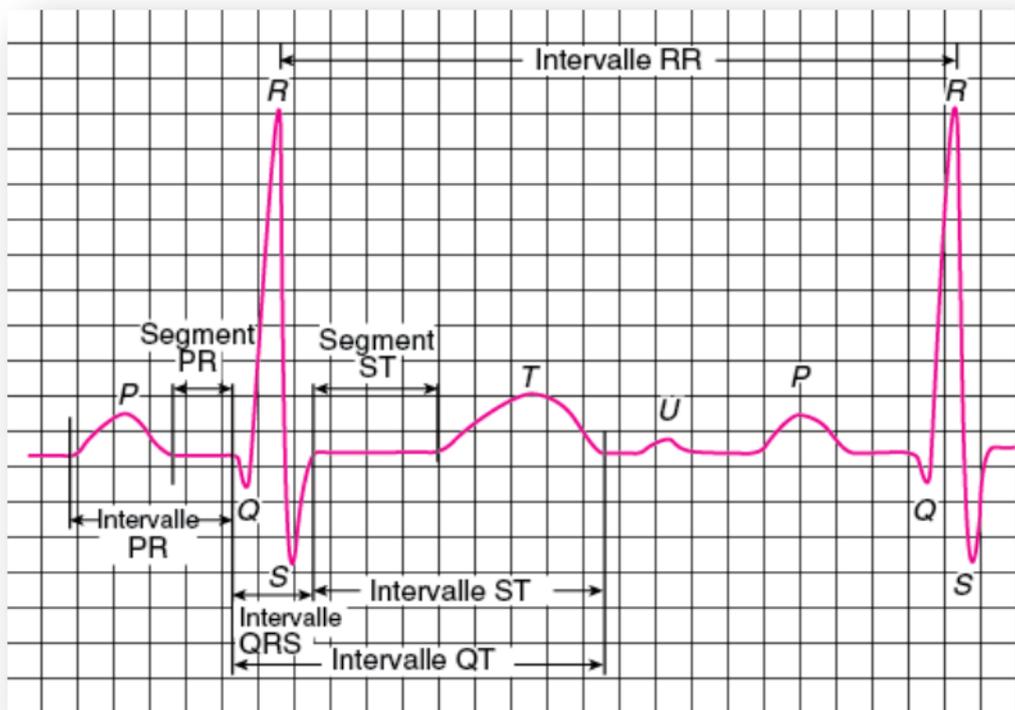


Fig.2.9 : ECG normal

" P = onde auriculaire, PR = temps de conduction auriculo-ventriculaire, QRS = onde ventriculaire rapide ou de dépolarisation, Q = première onde négative, R première onde positive, S = première onde négative suivant une onde positive, ST-T = onde ventriculaire lente ou de repolarisation"

On enregistre, au moyen d'électrodes cutanées, l'évolution temporelle du vecteur champ électrique. Dans l'ECG normal, le rythme est d'origine sinusale fait d'une succession régulière de séquences P-QRS-T-U [49].

Pour chaque battement cardiaque, l'électrocardiogramme enregistre quatre ondes successives Figure II.9 [49] :

Le processus de dépolarisation et de repolarisation des structures myocardiques se présente dans l'ECG comme une séquence de déflexions ou ondes superposées à une ligne de potentiel zéro, appelée ligne isoélectrique ou ligne de base. Ces déflexions sont dites positives si elles sont situées au-dessus de la ligne isoélectrique sinon elles sont dites négatives.

L'onde P : C'est la première onde détectable. Elle apparaît quand l'impulsion électrique se propage à partir du nœud sinusal pour dépolariser les oreillettes (voir Figure II.8). Sa masse musculaire relativement faible entraîne une variation de potentiel faible (moins de 0.25 mv).

La progression de l'onde de dépolarisation dans les oreillettes est beaucoup plus lente que dans les ventricules. Par conséquent, la région des oreillettes autour du nœud sinusal est dépolarisée très en avance par rapport aux régions plus éloignées.

Puis, l'onde de ré-polarisation est produite à l'inverse de l'onde de dépolarisation P. Normalement, l'onde de ré-polarisation des oreillettes apparaît au moment où le complexe QRS est produit.

Comme ce complexe est beaucoup plus intense que le premier, l'onde de ré-polarisation est cachée. [48]

Le complexe QRS : C'est un ensemble de déflexions positives et négatives qui caractérise la dépolarisation des ventricules précédant l'effet mécanique de contraction. Sa forme est variable selon les dérivations utilisées. Ce complexe est constitué par trois ondes principales, la première onde négative initiale est appelée onde Q, avec une durée inférieure à 0,04 et une amplitude dépasse rarement 0,2 mv, une onde positive R qui possède la plus grande amplitude de l'ECG et qui suit par une petite onde négative S [38,50].

L'onde T : Elle correspond à la repolarisation ventriculaire. Cette onde se caractérise par une amplitude moins faible que celle du complexe QRS et une durée plus longue [51].

Dans certains cas, une autre onde positive, appelée l'onde U de très basse amplitude peut être suivie l'onde T, mais elle n'est pas prise en charge dans le diagnostic. Elle est fréquemment observée chez les athlètes et elle est souvent bien visible en V3 et V4 [52, 53].

En général, un tracé d'un électrocardiogramme normal se présente comme illustré dans la figure.II.8. La caractérisation d'un ECG concerne les durées, les amplitudes et la morphologie

des ondes P, QRS et T, ainsi que d'autres paramètres temporels qui sont les segments PR et ST, et les intervalles PR, QT et ST [48].

II.3.2.2. Les segments et intervalles du signal ECG

En plus des différentes ondes qui sont les paramètres de base pour une bonne caractérisation d'un signal ECG, il existe un certain nombre d'intervalles et de segments qui portent des informations très utiles sur la vitesse de conduction de l'impulsion électrique dans les différentes parties du cœur. Les intervalles et les segments les plus importants sont: **Intervalle RR** : L'intervalle RR correspond au délai entre deux dépolarisations des ventricules [48].

C'est cet intervalle qui permet de calculer la fréquence cardiaque [51].

Segment PR : (pause du nœud AV) Le segment PR correspond au délai entre la fin de la dépolarisation des oreillettes et le début de celle des ventricules [48]. C'est le temps pendant lequel l'onde de dépolarisation est bloquée au niveau du nœud AV [54].

Intervalle PR : (durée de conduction auriculo-ventriculaire) L'intervalle PR correspond à la durée de propagation de l'onde de dépolarisation du nœud sinusal jusqu'aux cellules myocardiques ventriculaires.

Intervalle QT : (durée de systole ventriculaire) Cet intervalle correspond au temps de systole ventriculaire, qui va du début de l'excitation des ventricules jusqu'à la fin de leur relaxation.

Segment ST : (durée de stimulation complète des ventricules) Le segment ST correspond à la phase pendant laquelle les cellules ventriculaires sont toutes dépolarisées [48], le segment est alors isoélectrique [53].

II.4. A quoi sert l'électrocardiogramme ?

L'ECG peut constituer un marqueur indépendant d'affection myocardique; il peut refléter des atteintes anatomiques, électro- physiologiques, métaboliques et hémodynamiques; il procure une information qui souvent s'avère essentielle pour le diagnostic et le traitement de diverses anomalies cardiaques; et il est sans égal pour le diagnostic des arythmies.

L'électrocardiographie est une procédure de premier choix chez des patients se plaignant de précordialgies, lipothymies ou syncopes, symptômes qui peuvent être annonciateurs d'infarctus myocardique ou de mort subite. Des anomalies électriques peuvent être les premiers signes indiquant l'existence d'effets secondaires potentiellement désastreux de certains médicaments, ou de sévères déséquilibres métaboliques ou électrolytiques, et par fois le seul signe d'atteinte

myocardique, telle que l'infarctus "silencieux" chez le sujet âgé. L'échocardiographie et la résonance magnétique nucléaire, par exemple, montrent directement la morphologie et la dynamique des structures anatomiques, domaines où l'électrocardiogramme est moins performant. Par contre, l'électrocardiogramme est le premier et parfois le seul témoin de modifications se produisant à l'étage moléculaire et cellulaire. Il peut de la sorte constituer un outil diagnostique essentiel, par exemple pour la détection de l'ischémie myocardique (pathologie fréquente), pour la reconnaissance des atteintes myocardiques précoces comme dans certaines myocardiopathies et certaines dystrophies musculaires (pathologies rares) où les tracés électrocardiographiques peuvent être perturbés avant que n'apparaissent les anomalies échocardiographiques. Enfin l'électrocardiogramme est le seul examen couramment utilisé dans l'étude des troubles de conduction et des troubles du rythme, c'est un formidable outil de diagnostic [50].

II.5. Intérêt de l'électrocardiogramme

L'électrocardiogramme est un procédé biomédical qui facilite le diagnostic et présente une aide pour le personnel médical. Explicitement, il a plusieurs avantages comme :

- Vérifier l'origine d'une douleur.
- Evaluer son niveau de propagation et son ampleur au niveau zonal.
- Préciser avec exactitude son emplacement.
- Prévoir les complications liées à ce genre de dysfonctionnement.
- Détection d'une possible augmentation volumique, qui cible la plupart du temps le ventricule gauche, cette détection est un outil de prévoyance concernant l'apparition de troubles artériels.

En outre, le fluide qui pénètre (le sang) est un liquide transporteur de nutriments et autres agents qui favorisent le bon fonctionnement de l'organisme, ceci implique que le cœur joue un rôle prépondérant dans toute une chaîne et fait de l'échocardiographie un test qui permet le dépistage de plusieurs anomalies [55].

II.6. L'étude Théorique D'un Signal ECG

II.6.1. Modèle et expression mathématique du motif

Nous avons construit un signal fantôme, à l'image du signal ECG. Ce signal fantôme est constitué uniquement de segments de droite. On peut déterminer son expression mathématique, il sera donc utilisé pour prévoir théoriquement les performances des différents algorithmes [56]

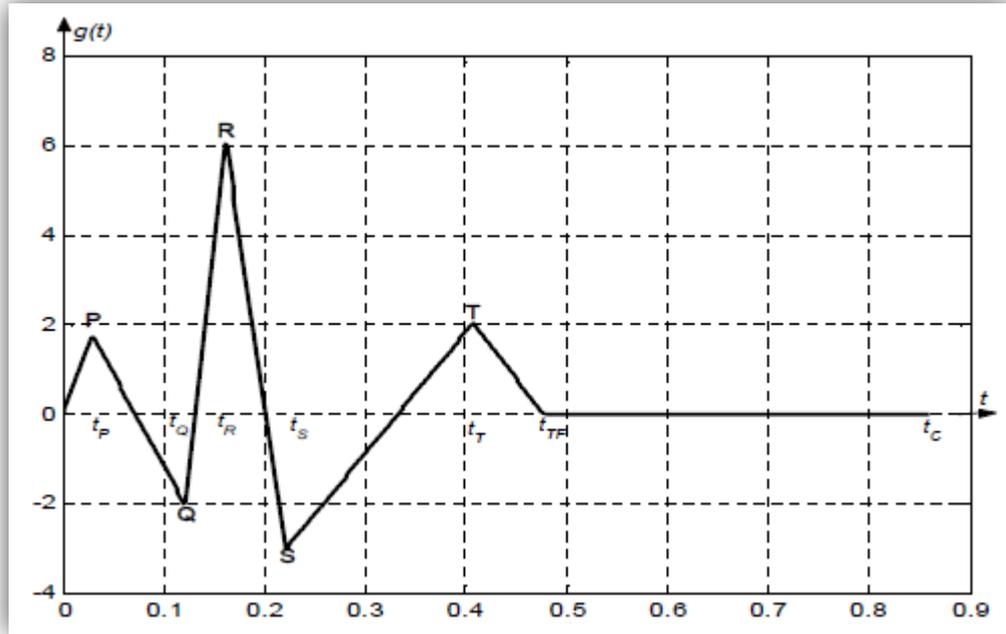


Fig.II.10. : Motif principal du signal ECG simulé

Nous représentons sur la figure 2.10 le motif principal $g(t)$ de ce signal test. $g(t)$ coïncide avec un cycle cardiaque et peut être exprimé par :

$$g(t) = \begin{cases} \lambda_P t + \gamma_P & \text{si } 0 \leq t \leq t_P \\ \lambda_{PQ} t + \gamma_{PQ} & \text{si } t_P < t \leq t_Q \\ \lambda_{QR} t + \gamma_{QR} & \text{si } t_Q < t \leq t_R \\ \lambda_{RS} t + \gamma_{RS} & \text{si } t_R < t \leq t_S \\ \lambda_{ST} t + \gamma_{ST} & \text{si } t_S < t \leq t_T \\ \lambda_{TF} t + \gamma_{TF} & \text{si } t_T < t \leq t_F \\ a & \text{si } t_F < t \leq t_C \end{cases} \quad (\text{II.1})$$

λ_x sont les pentes des segments, γ_x et a sont des constantes réelles ;

$X \in \{P, PQ, QR, RS, ST, TF\}$. Lorsqu'on considère $u(t)$ qui est la fonction échelon unitaire, on peut réécrire $g(t)$ sous la forme de l'équation (II.2) ci-après

$$g(t) = (\lambda_P t + \gamma_P)u(t) - (\lambda_P t + \gamma_P)u(t - t_P) + (\lambda_{PQ} t + \gamma_{PQ})u(t - t_P) - (\lambda_{PQ} t + \gamma_{PQ})u(t - t_Q) + (\lambda_{QR} t + \gamma_{QR})u(t - t_Q) - (\lambda_{QR} t + \gamma_{QR})u(t - t_R) + (\lambda_{RS} t + \gamma_{RS})u(t - t_R) - (\lambda_{RS} t + \gamma_{RS})u(t - t_S) + (\lambda_{ST} t + \gamma_{ST})u(t - t_S) - (\lambda_{ST} t + \gamma_{ST})u(t - t_T) + (\lambda_{TF} t + \gamma_{TF})u(t - t_T) - (\lambda_{TF} t + \gamma_{TF})u(t - t_F) + a(u(t - t_F) - u(t - t_C)) \quad (\text{II.2})$$

Ou encore :

$$\begin{aligned}
 g(t) = & (\lambda_P t + \gamma_P)u(t) + [(\lambda_{PQ} - \lambda_P)t + (\gamma_{PQ} - \gamma_P)]u(t - t_P) + [(\lambda_{QR} - \lambda_{PQ})t + \\
 & + (\gamma_{QR} - \gamma_{PQ})]u(t - t_Q) + [(\lambda_{RS} - \lambda_{QR})t + (\gamma_{RS} - \gamma_{QR})]u(t - t_R) + [(\lambda_{ST} - \lambda_{RS})t + \\
 & + (\gamma_{ST} - \gamma_{RS})]u(t - t_S) + [(\lambda_{TF} - \lambda_{ST})t - (\gamma_{TF} - \gamma_{ST})]u(t - t_T) + [-\lambda_{TF}t + (a - \\
 & \gamma_{TF})]u(t - t_F) - a(u(t - t_C)) \tag{II.3}
 \end{aligned}$$

Le signal fantôme ECG $s(t)$ est une répétition périodique des translations de $g(t)$. On peut donc dans le cas de N répétitions de $g(t)$, soit $N + 1$ cycles cardiaques, poser :

$$s(t) = \sum_{k=0}^N g(t - kt_C) \tag{II.4}$$

II.6.2. Valeurs numériques des amplitudes et intervalles

Pour ce qui est de la réalisation numérique des $s(t)$, nous avons considéré un rythme cardiaque de l'ordre de 70 battements par minute, ce qui conduit à $t_C = 0.860$ s. La fréquence d'échantillonnage est de 500 Hz, 2 échantillons consécutifs sont donc distants de 0.002 seconde [56]. Les critères de normalité du sont utilisés pour dimensionner les intervalles et les ondes de la manière suivante :

$$\begin{cases} t_P = 0.028 \text{ s} \\ g(t_P) = 1.7 \text{ mv} \end{cases} \quad \begin{cases} t_Q = 0.120 \text{ s} \\ g(t_Q) = -2 \text{ mv} \end{cases} \quad \begin{cases} t_R = 0.160 \text{ s} \\ g(t_R) = 6 \text{ mv} \end{cases} \quad \begin{cases} t_S = 0.220 \text{ s} \\ g(t_S) = -3 \text{ mv} \end{cases} \\
 \begin{cases} t_T = 0.406 \text{ s} \\ g(t_T) = 2 \text{ mv} \end{cases} \quad \begin{cases} t_{TF} = 0.476 \text{ s} \\ g(t_{TF}) = a = 0 \end{cases} \quad \begin{cases} t_C = 0.860 \text{ s} \\ g(t_C) = a = 0 \end{cases} \tag{II.5}
 \end{cases}$$

Avec ces valeurs, le calcul des paramètres λ et γ revient à résoudre un ensemble de systèmes de 2 équations à 2 inconnues. On obtient

$$\begin{cases} \lambda_P = 60.7143 \\ \gamma_P = 0 \end{cases} \quad \begin{cases} \lambda_{PQ} = -41.1111 \\ \gamma_{PQ} = 2.9333 \end{cases} \quad \begin{cases} \lambda_{QR} = 210.5263 \\ \gamma_{QR} = -27.6842 \end{cases} \\
 \begin{cases} \lambda_{RS} = -155.1724 \\ \gamma_{RS} = 31.1379 \end{cases} \quad \begin{cases} \lambda_{ST} = 27.1739 \\ \gamma_{ST} = -9.0326 \end{cases} \quad \begin{cases} \lambda_{TF} = -29.4117 \\ \gamma_{TF} = 14.0000 \end{cases} \tag{II.6}
 \end{cases}$$

III.7. Conclusion

L'électrocardiographie est une technique largement utilisée, elle remplit bien sa fonction et fourni de façon fiable un signal auquel nous pouvons appliquer des méthodes appropriées du traitement de signal. Ce chapitre a donné au lecteur les informations de base pour comprendre la génération du signal cardiaque ainsi que les méthodes de sa détection

Chapitre III

Les réseaux de neurones

III.1. Introduction

Inspirés du fonctionnement du cerveau humain, les Réseaux de Neurones Artificiels (RNA) occupent aujourd'hui une place prépondérante dans plusieurs domaines des Sciences pour l'Ingénieur. Les progrès accomplis dans la compréhension du fonctionnement du cerveau humain ont contribué dans une large mesure au développement des RNA.

Cependant les scientifiques sont toujours impressionnés par l'architecture du système neuronal humain, sa complexité, son efficacité et sa rapidité dans le traitement de certains problèmes complexes (par exemple ceux liés à la perception) que le plus puissant des ordinateurs actuels ne peut résoudre avec la même efficacité.

Les domaines d'application des RNA sont très nombreux : contrôle et commande de processus [57-58], identification [59-60-61], classification [62], prédiction [63-64-65], diagnostic [66-67], reconnaissance de forme [68], etc. Il existe plusieurs types de RNA. Les RNA de type Perceptrons Multicouches (Multi Layer Perceptron - MLP) sont les plus utilisés, notamment dans les problèmes de régression non linéaire qui sont à la base de ce travail. Ils font donc l'objet d'une présentation dans ce chapitre dans le but d'une part, une définition et architecture de réseaux de neurone puis identifiée les types, les avantages et les applications de ce réseau. Outre une représentation du neurone formel. Après cela une brève présentation de l'architecture des réseaux MLP, le processus d'apprentissage des réseaux MLP non récurrents et récurrents est abordé.

III.2. Historique

L'histoire des réseaux de neurones artificiels revient en 1943, où Mc Culloch et Pitts ont proposé des neurones formels mimant les neurones biologiques et capables de mémoriser des fonctions booléennes simples [69]. En 1949, Hebb a mis en évidence l'importance du couplage synaptique dans l'apprentissage par renforcement ou dégénérescence des liaisons inter-neuronales lors de l'interaction du cerveau avec le milieu extérieur. Le premier modèle opérationnel est le perceptron simple inspiré du modèle visuel et capable d'apprentissage. Il a été proposé en 1958 par Rosenblatt. Les limites du Perceptron monocouche du point de vue performance ont été montrées en 1969 par les mathématiciens Minsky et Papert.

Les travaux de Hopfield en 1982 ont montrés que des réseaux de neurones artificiels étaient capables de résoudre des problèmes d'optimisation et ceux de Kohonen (1982) ont montré qu'ils étaient capables des résoudre des tâches de classification et de reconnaissance [69].

En 1988, Broomhead et Lowe s'inspirant des fonctions radiales, développèrent les réseaux RBF (Radial Basis Function). Ils ouvrirent la voie à Chen et Billings (1992) et leurs Functional Link Network (FLN) ou une transformation non linéaire des entrées permet une réduction de la puissance de calcul ainsi qu'une convergence plus rapide.

En 2013, Les réseaux de neurones profonds sont similaires aux réseaux PMC mais avec plus de couches cachées. Plus le nombre de neurones est élevé, plus le réseau est « profond ». Les réseaux profonds obtiennent d'excellentes performances pour la classification d'images et de sons.

En 2015, les géants du logiciel (Google, Facebook, IBM, etc.) ont recruté pratiquement tous les experts (universitaires) en réseaux de neurones profonds pour développer de nouvelles applications.

Nous pouvons donc estimer que les RNA ont répondu à nos attentes et sont en passe de résoudre certains des challenges de l'IA [70].

III.3.Présentation

Les recherches sur les Réseaux de Neurones artificiels ont débutées dans la fin des années 50 pour permettront l'étude de modèles théoriques proposés tels que les ordinateurs. L'avenue de ceux-ci étant héritiers de la révolution scientifique à cette époque, ces modèles d'études consistaient en la transposition de la pensée humaine sous forme machine. Ces recherches sur le lien entre l'esprit humain, son cerveau et la machine à la fin des années 50 qui étaient conduites par une variété de chercheurs tels que Newman, Turing, Church, Newel et Simon allaient d'ailleurs produire les fondations de ce que l'on appelle aujourd'hui l'intelligence artificielle. Ces chercheurs allaient aboutir sur un modèle mimétique au cerveau humain, le réseau de neurones, reproduisant de manière exhaustivement simpliste un modèle neuronal tel que connu à cette époque.

Les Réseaux de Neurones artificiels ont des propriétés remarquables : capacité d'adaptation, apprentissage à partir d'exemple et généralisation, robustesse face au bruit, ils sont intégrables dans des processus temps réel et ils sont efficaces pour l'extraction des règles à partir d'exemple pour des problèmes difficilement modélisables [71].

III.4.Définition

Un réseau de neurones artificiels, est un ensemble d'algorithmes dont la conception est à l'origine très schématiquement inspirée du fonctionnement des neurones biologiques, et qui par

la suite s'est rapproché des méthodes statistiques. Un réseau de neurones est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Chaque couche (i) est composée de N_i neurones, prenant leurs entrées sur les N_{i-1} neurones de la couche précédente. À chaque synapse est associé un poids synaptique, de sorte que les N_{i-1} sont multipliés par ce poids, puis additionnés par les neurones de niveau i, ce qui est équivalent à multiplier le vecteur d'entrée par une matrice de transformation. Mettre l'une derrière l'autre les différentes couches d'un réseau de neurones reviendrait à mettre en cascade plusieurs matrices de transformation et pourrait se ramener à une seule matrice, produit des autres, s'il n'y avait à chaque couche, la fonction de sortie qui introduit une non linéarité à chaque étape. Ceci montre l'importance du choix judicieux d'une bonne fonction de sortie : un réseau de neurones dont les sorties seraient linéaires n'aurait aucun intérêt. [72].

L'architecture d'un réseau de neurones artificiel est définie par la structure de ses neurones et leur connectivité. Elle est spécifiée par le nombre d'entrées, de sorties, de nœuds et la façon selon laquelle sont interconnectés et organisés les nœuds. Une fameuse architecture des réseaux de neurones est celle basée sur des couches ou les nœuds de chaque couche n'ont aucune connexion entre eux. Cette architecture est utilisée dans presque 90 % des applications commerciales et industrielles [73].

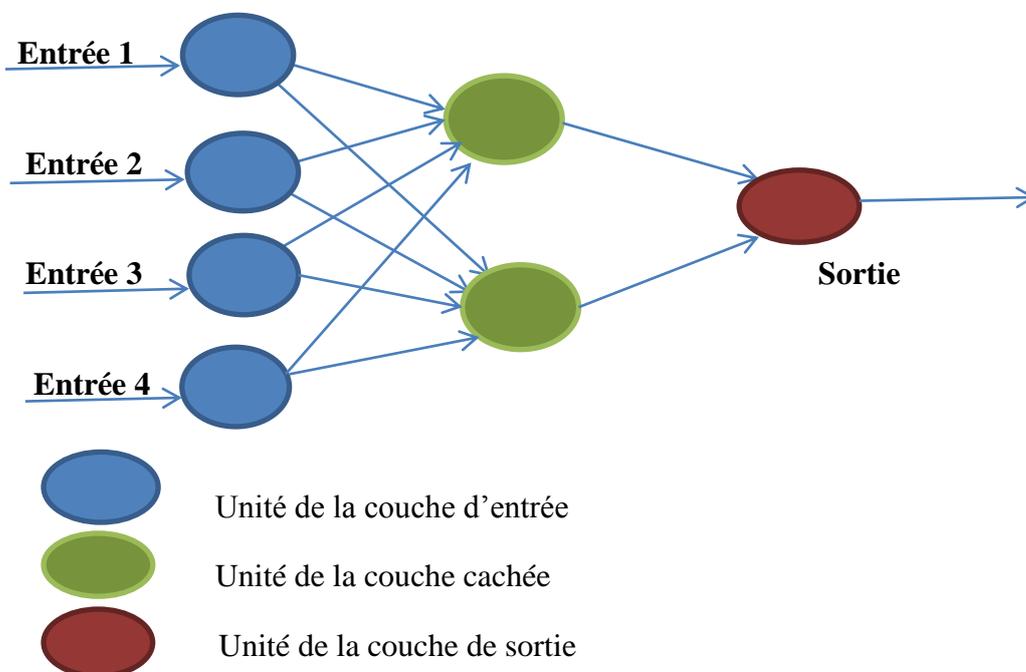


Fig.III.1: Schéma général d'un réseau de neurones. [73]

- Les nœuds d'entrées
- Les nœuds cachés
- Les nœuds de sortie

III.5. Architecture de réseaux de neurones

Selon la topologie de connexion des neurones, on peut les classer en deux grandes catégories: réseaux non bouclés (statique ou feed forward) et réseaux bouclés (dynamique, feed back ou récurrent).

III.5.1. Réseaux statiques "feed-forward "

Un réseau de neurones non bouclé (appelé aussi statique) est représenté comme un graphe dont les nœuds sont les neurones. L'information circule des entrées vers les sorties sans retour en arrière (Figure III.2). Ce type de réseaux est utilisé pour effectuer des tâches d'approximation de fonction non linéaire, de la classification ou de la modélisation de processus statiques non linéaires [74]

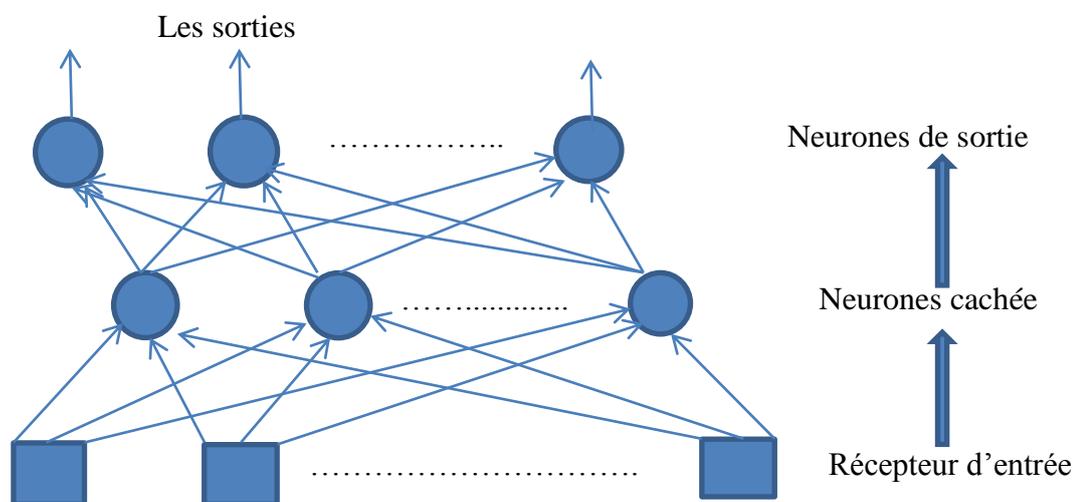


Fig.III.2 : Exemple d'un réseau de neurones non bouclé.

III.5.1.1. Réseaux multicouches (ou Perceptron Multi Couche PMC)

C'est le réseau de neurones statique le plus utilisé. Les neurones sont arrangés par couche. Les neurones de la première couche reçoivent le vecteur d'entrée, ils calculent leurs sorties qui sont transmises aux neurones de la seconde couche qui calculent eux même leurs sorties et ainsi de suite de couche en couche jusqu'à celle de sortie. Chaque neurone dans la couche cachée est

connecté à tous les neurones de la couche précédente et de la couche suivante, et il n'y a pas de connexions entre les cellules d'une même couche.

Il peut résoudre des problèmes non linéairement séparables et il suit un apprentissage supervisé avec la règle de correction de l'erreur [75].

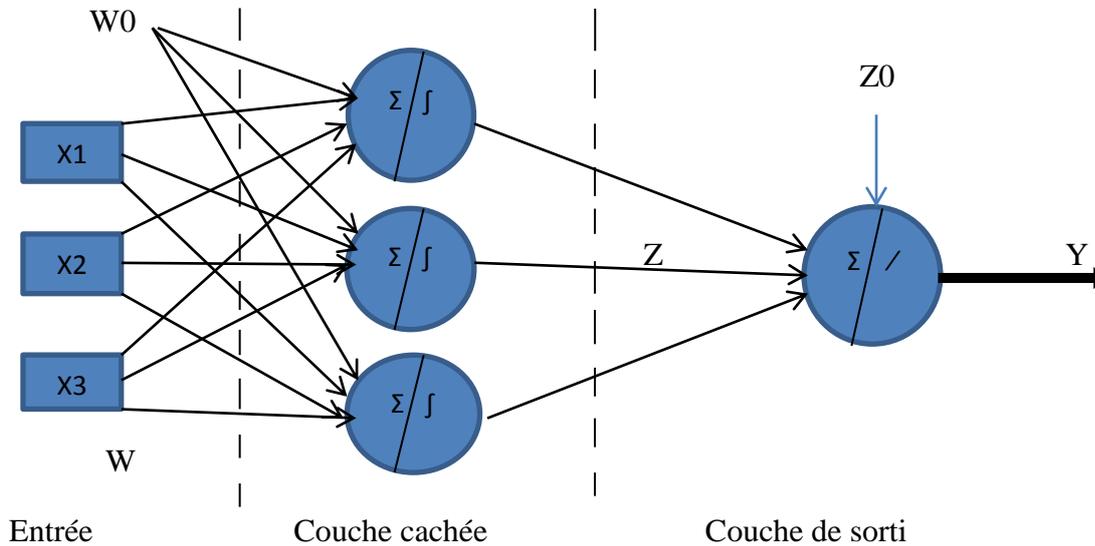


Fig.III.3 : Perceptron Multi Couche PMC.

La sortie du réseau a pour expression :

$$Y = g[Z + [f(WX + W_0)] + Z_0] \quad \text{III.1}$$

Avec :

f et g les fonctions de transfert, des couches cachées et de sorties respectivement, Y sortie du réseau, X vecteur des entrées. W : Matrice des poids de connexions liant la couche d'entrée à la couche cachée. W_0 : Vecteur des biais des cellules de la couche cachée. Z : Matrice des poids des connexions liant la couche cachée à la couche de sortie.

Z_0 : Vecteur des biais des cellules de la couche de sortie.

III.5.2. Réseau récurrents "Feed-back"

Un réseau bouclé (récurrent), régi par une ou plusieurs équations différentielles, résulte de la composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions. Ces réseaux sont utilisés pour effectuer des tâches de modélisation des systèmes dynamiques, de commande de processus ou de filtrage [74-76].

Le comportement dynamique d'un réseau de neurones bouclé peut être décrit par une représentation d'état paramétrée par les coefficients C , représentée sur la figure III.4.

$$\begin{cases} S(K + 1) = \psi(S(k), I(k); C) \\ Y(K) = \xi(S(k), I(k); C) \end{cases} \quad \text{III. 2}$$

Où $I(k)$ est le vecteur des entrées externes, $S(k)$ le vecteur des variables d'état, $Y(k)$ le vecteur des sorties, $\psi(\dots; C)$ et $\xi(\dots; C)$ représentent les fonctions réalisées par le réseau de neurones statiques de la forme canonique interconnectés avec les coefficients C [77].

Nerand a démontré dans ses articles [74]-[78] que : tout réseau de neurones bouclé aussi complexe soit-il peut être mis sous une forme canonique comportant un réseau de neurones non bouclé dont certaines sorties (les variables d'état) sont ramenées aux entrées par des bouclages de retard unité.

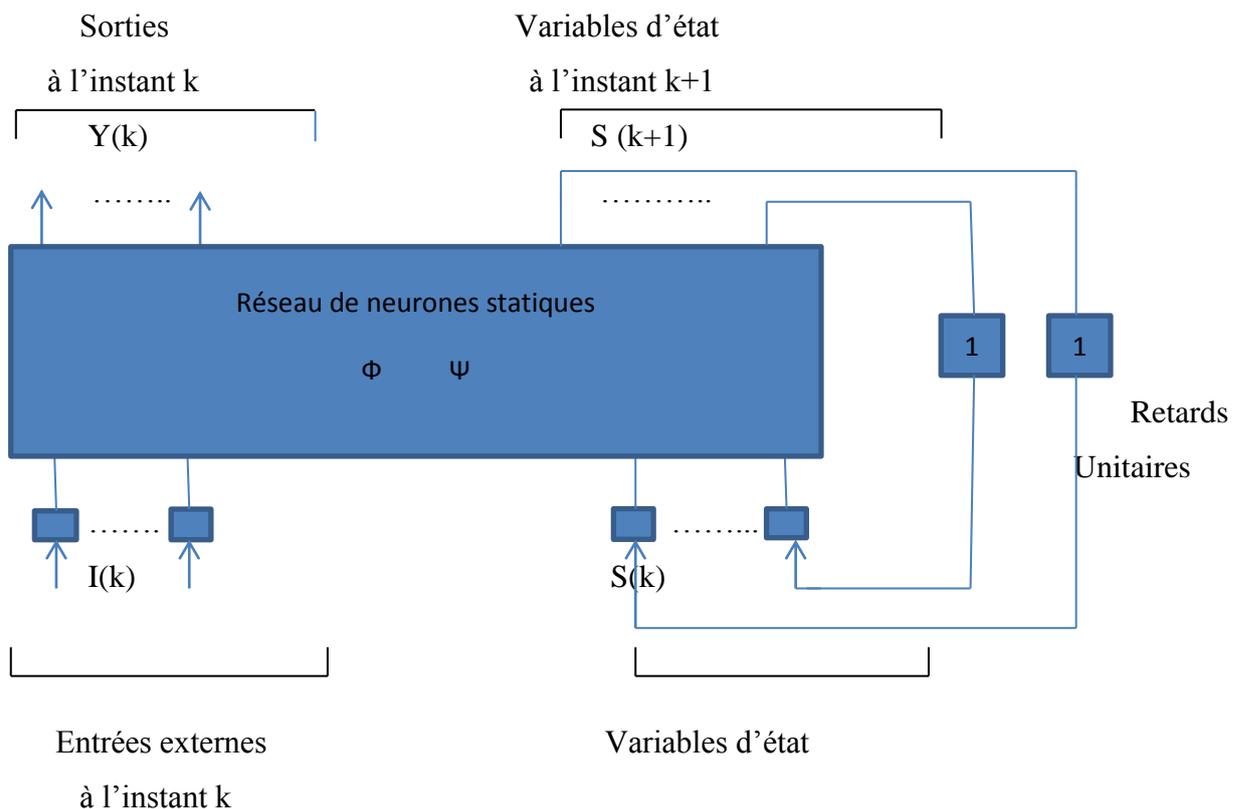


Fig.III.4 : Forme canonique d'un réseau de neurones bouclé.

III.6. Quelques types de réseaux de neurones

Il existe plusieurs types de réseaux de neurones, nous citons principalement :

III.6.1. Réseaux à une seule couche (monocouche)

III.6.2. Perceptron Multi Couches

III.6.3. Réseau à fonction radiale

III.7. Avantage des réseaux de neurones

Il est évident qu'un réseau de neurones tire sa puissance de calcul grâce, premièrement, à sa structure distribuée extrêmement parallèle et, deuxièmement, à son aptitude à apprendre et donc à généraliser. La généralisation fait référence à la production par le réseau de neurones de sorties raisonnables pour les entrées non rencontrées pendant l'apprentissage.

Ces deux capacités de traitement de l'information permettent aux réseaux de neurones de trouver de bonnes solutions approximatives à des problèmes complexes (à grande échelle) difficiles à résoudre.

Les réseaux de neurones offrent les propriétés et capacités utiles suivantes [79] :

III.7.1. Non-linéarité

Un neurone artificiel peut être linéaire ou non linéaire. Un réseau de neurones, constitué d'une interconnexion de neurones non linéaires, est lui-même non linéaire. De plus, la non-linéarité est d'un type particulier en ce sens qu'elle est distribuée dans tout le réseau.

III.8. Neurone formel

Le neurone artificiel (ou cellule) est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones appartenant à un niveau situé en amont (on parlera de neurones amont). À chacune des entrées est associé un poids w représentatif de la force de la connexion.

Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones appartenant à un niveau situé en aval (on parlera de neurones "avals"). À chaque connexion est associé un poids. [80]

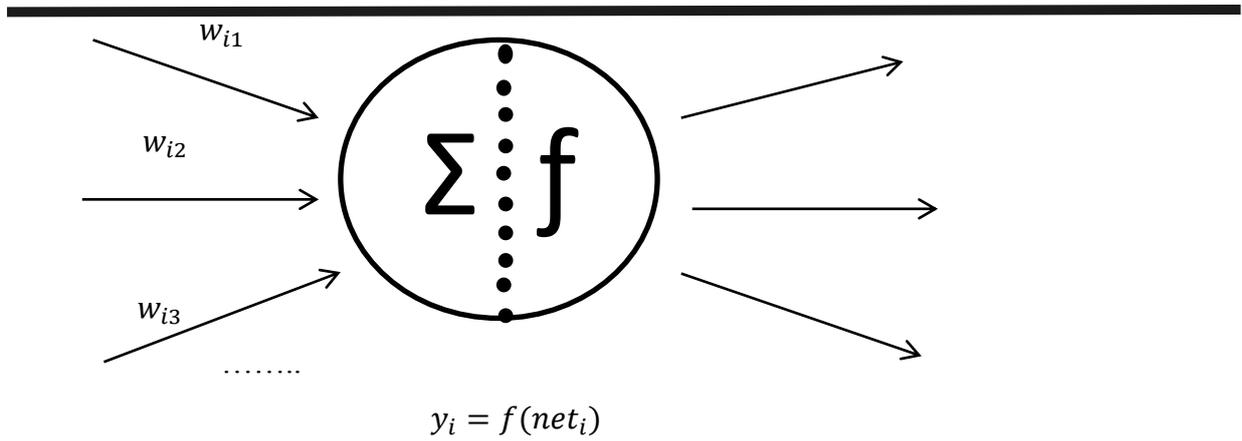


Fig.III.8: Neurone formel. [80]

III.8.1.Représentation mathématique

Les réseaux de neurones formels sont à l'origine d'une tentative de modélisation mathématique du cerveau humain. Les premiers travaux datent de 1943 et sont l'œuvre de MM. Mac Culloch et Pitts. Ils présentent un modèle assez simple pour les neurones et explorent les possibilités de ce modèle. La modélisation consiste à mettre en œuvre un système de réseau neuronal sous un aspect non pas biologique mais artificiel. Un neurone est donc avant tout un opérateur mathématique, dont on peut calculer la valeur numérique par quelques lignes de

logiciel. D'un point de vue mathématique, un neurone formel réalise donc une fonction linéaire. [81]

$$y = f(x_1, x_2, \dots, x_p ; w_1, w_2, \dots, w_p) \tag{III. 3}$$

Les $\{x_i\}$ sont les variables (ou entrées), les $\{w_j\}$ sont des paramètres (ou poids). Les entrées peuvent être booléennes, binaires (0,1), bipolaire (-1,1) ou réels. En règle générale, le calcul de la valeur de cette fonction peut se décomposer en deux étapes :

-Une combinaison linéaire des entrées

$$U = \sum_{i=1}^n w_i x_i - \theta \tag{III. 4}$$

- La sortie du neurone est :

$$Y = f(U) = f(\sum_{i=1}^n w_i x_i - \theta) \tag{III. 5}$$

(θ) est appelé biais, il peut être considéré comme la pondération de l'entrée 0 fixée à 1
 (U) est appelé potentiel du neurone.

La fonction (f) permet de définir l'état interne du neurone en fonction de son entrée totale.
 Citons à titre d'exemple quelques fonctions d'activation ou de transfert souvent utilisées.

III.8.2. Fonctions d'activation

Dans sa première version, le neurone formel était donc implémenté avec une fonction à seuil, mais de nombreuses versions existent. Ainsi le neurone de McCulloch et Pitts a été généralisé de différentes manières, en choisissant d'autres fonctions d'activations. La sortie du neurone dépend d'une fonction de transfert, dont les principales sont :

- **fonction binaire à seuil**
- **Fonction linéaire à seuil ou multi seuil**
- **La fonction sigmoïde**

III.8.3. Architecture d'un réseau de neurones artificiel

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certaine régularité (réseau à connexion complète) [81].

III.8.3.1. Réseaux monocouche

III.8.3.2. Réseaux multicouche

III.9. Architecture d'un réseau MLP

Un réseau MLP comporte une ou plusieurs couches cachées à fonction d'activation de type sigmoïde ainsi qu'une couche de sortie. Les neurones de la couche cachée c reçoivent des informations des neurones (ou unités) de la couche $c - 1$ et sont connectés aux neurones de la couche $c + 1$. Il n'existe pas de connexions entre les neurones d'une même couche.

Chaque neurone de la couche de sortie réalise une fonction non linéaire des entrées du réseau. Le potentiel v_i d'un neurone i et son activation O_i à un instant t sont donnés par :

$$v_i(t) = \sum_{j=1}^p \omega_{ij} x_j(t) - b_i \quad \text{III. 6}$$

$$O_i(t) = f_i(v_i(t)) \quad \text{III. 7}$$

Où :

x_j représente l'entrée j du réseau si le neurone i appartient à la première couche cachée, ou dans le cas contraire, la sortie O_j du neurone j de la couche cachée précédant celle du neurone i ; b_i est une constante scalaire appelée biais ; $f_i(\cdot)$ est la fonction d'activation du neurone i . Elle peut être différente selon que le neurone soit un neurone caché ou un neurone de sortie. En général, tous les neurones cachés ont la même fonction d'activation qui est souvent une fonction sigmoïde (par exemple $f(v) = 1/(1 + e^{-v})$). Les neurones de sortie ont également la même fonction d'activation, en général linéaire (par exemple $f(v) = v$).

Les MLP sont utilisés dans plusieurs types d'applications telles que : classification (y compris pour des classes non linéairement séparables), approximation de fonctions, identification, etc. C'est ce type de réseau que nous utilisons dans ce travail pour l'identification des systèmes dynamiques non linéaires. La figure III.14 représente un schéma simplifié d'un réseau MLP à deux entrées, comportant une couche cachée à trois neurones et une couche de sortie à deux neurones. Le MLP à une couche cachée avec des fonctions d'activation sigmoïde et une couche de sortie constituée d'un neurone linéaire possède la propriété d'approximateur universel parcimonieux [82-83-84-85].

III.10. Processus d'apprentissage dans les réseaux MLP

Les réseaux MLP utilisent un mode d'apprentissage supervisé. Dans ce mode d'apprentissage, un ensemble de données constitué des entrées du système à modéliser et des sorties correspondantes est présenté au réseau qui doit adapter ses paramètres suivant un algorithme d'apprentissage de façon à ce que la différence entre la sortie du système et celle du modèle soit suffisamment faible.

Les techniques d'apprentissage les plus utilisées dans les réseaux MLP sont l'algorithme de rétro-propagation du gradient (Back Propagation - BP, [86]) pour les MLP non récurrents et l'algorithme de rétro-propagation à travers le temps (Back Propagation Through Time - BPTT, [85]) pour les MLP récurrents. Nous présentons ici ces deux techniques d'apprentissage.

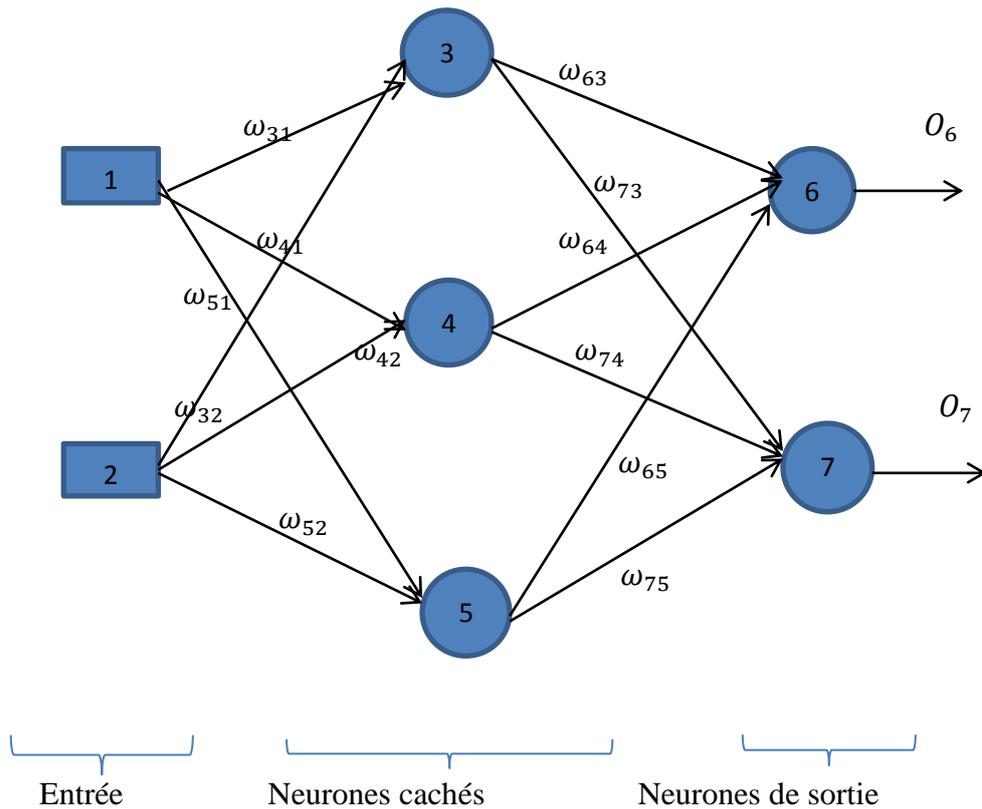


Fig.III.14: Schéma simplifié d'un perceptron multicouche à deux entrées, une couche cachée et une couche de sortie.

III.10.1. Algorithme d'apprentissage dans un MLP non récurrent

Considérons un réseau MLP comportant plusieurs couches cachées et une couche de sortie à plusieurs neurones. A un instant t donné, l'erreur entre la sortie désirée $d_i(t)$ et la sortie $O_i(t)$ produite par le neurone de sortie d'indice i s'exprime par :

$$e_i(t) = d_i(t) - O_i(t) \quad \text{III. 8}$$

L'erreur quadratique moyenne du réseau est :

$$\varepsilon(t) = \frac{1}{2} \sum_{i \in S} [e_i(t)]^2 \quad \text{III. 9}$$

Où S est l'ensemble des indices des neurones de sortie.

L'objectif de l'apprentissage est de minimiser le critère J dans laquelle θ représente le vecteur des poids du réseau d'éléments ω_{ij} . L'algorithme de rétro propagation du gradient est un algorithme itératif permettant de modifier les paramètres, afin de minimiser l'erreur quadratique moyenne du réseau sur l'ensemble des données d'apprentissage, suivant une technique de descente du gradient :

$$\omega_{ij}(t + 1) = \omega_{ij}(t) - \mu \frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)} \quad \text{III. 10}$$

Le gradient de l'erreur $\frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)}$ peut être calculé de deux façons différentes suivant que le neurone i soit un neurone de sortie ou un neurone caché.

III.10.1.1. Evaluation du gradient pour un neurone de sortie

Pour un neurone de sortie, l'erreur $e_i(t)$ peut être évaluée par l'expression (III.8) qui conduit à :

$$\frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)} = \frac{\partial \varepsilon(t)}{\partial e_i(t)} \frac{\partial e_i(t)}{\partial O_i(t)} \frac{\partial O_i(t)}{\partial v_i(t)} \frac{\partial v_i(t)}{\partial \omega_{ij}(t)} \quad \text{III. 11}$$

A partir des équations (III.9), (III.8), (III.7) et (III.6) il vient respectivement :

$$\frac{\partial \varepsilon(t)}{\partial e_i(t)} = e_i(t) \quad \text{III. 12}$$

$$\frac{\partial e_i(t)}{\partial O_i(t)} = -1 \quad \text{III. 13}$$

$$\frac{\partial O_i(t)}{\partial v_i(t)} = f'_i(v_i(t)) \quad \text{III. 14}$$

$$\frac{\partial v_i(t)}{\partial \omega_{ij}(t)} = O_j(t) \quad \text{III. 15}$$

L'évaluation du gradient de l'erreur donne alors :

$$\frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)} = -e_i(t) f'_i(v_i(t)) O_j(t) \quad \text{III. 16}$$

Soit :

$$\frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)} = \delta_i(t) O_j(t) \quad \text{III. 17}$$

Où $\delta_i(t)$ est le gradient local défini par :

$$\delta_i(t) = e_i(t) f'_i(v_i(t)) \quad \text{III. 18}$$

III.10.1.2. Evaluation du gradient pour un neurone caché

Pour un neurone caché, il n'est pas possible d'évaluer l'erreur $e_i(t)$. Pour un neurone i de la dernière couche cachée, le gradient de l'erreur peut être déterminé par :

$$\frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)} = \frac{\partial \varepsilon(t)}{\partial O_i(t)} \frac{\partial O_i(t)}{\partial v_i(t)} \frac{\partial v_i(t)}{\partial w_{ij}(t)} \quad \text{III. 19}$$

$$\frac{\partial \varepsilon(t)}{\partial O_i(t)} = \frac{\partial}{\partial O_i(t)} [\sum_{k \in S} [e_k(t)]^2]$$

$$= \sum_{k \in S} e_k(t) \frac{\partial e_k(t)}{\partial O_i(t)}$$

$$= \sum_{k \in S} e_k(t) \frac{\partial e_k(t)}{\partial v_k(t)} \frac{\partial v_k(t)}{\partial O_i(t)}$$

$$\sum_{k \in S} e_k(t) \left(-f'_k(v_k(t)) \right) \omega_{ki}(t) \quad \text{III. 20}$$

D'où finalement :

$$\frac{\partial \varepsilon(t)}{\partial \omega_{ij}(t)} = -f'_i(v_i(t)) O_j(t) \sum_{k \in S} e_k(t) \left(f'_k(v_k(t)) \right) \omega_{ki}(t) \quad \text{III. 21}$$

Par conséquent, le gradient local d'un neurone caché d'indice i s'exprime par :

$$\delta_i(t) = f'_i(v_i(t)) \sum_{k \in S} e_k(t) \left(f'_k(v_k(t)) \right) \omega_{ki}(t) \quad \text{III. 22}$$

Où :

$$\delta_i(t) = f'_i(v_i(t)) \sum_{k \in S} \delta_k(t) \omega_{ki}(t) \quad \text{III. 23}$$

Connaissant les gradients locaux des neurones de la dernière couche cachée, on peut calculer pas à pas les gradients locaux des neurones des couches cachées précédentes en utilisant de façon récursive la relation (III.23).

L'algorithme de rétro propagation du gradient peut ainsi se résumer en deux étapes :

– Pendant la première étape, l'information (les entrées) transite de l'entrée du réseau vers sa sortie, les poids des connexions étant maintenus fixes. On calcule alors les erreurs à la sortie du réseau.

– Pendant la deuxième étape, l'information (les erreurs à la sortie du réseau) transite de la sortie vers l'entrée et permet la modification des poids par la relation :

$$\omega_{ij}(t + 1) = \omega_{ij}(t) + \mu\delta_i(t)O_j(t) \quad \text{III. 24}$$

où les gradients locaux $\delta_i(t)$ sont calculés par les relations (III.18) pour les neurones de sortie et (III.23) pour les neurones cachés.

Le principal inconvénient de l'algorithme de rétro propagation est qu'il n'y a pas de garantie de convergence vers le minimum global. De plus, le choix du pas de recherche μ constitue une tâche difficile. Pour accélérer la vitesse de convergence de l'algorithme, il est proposé dans [86] de modifier (III.24) en y ajoutant un terme d'inertie (momentum) qui est d'autant plus grand que la différence entre deux valeurs successives de ω_{ij} est importante :

$$\omega_{ij}(t + 1) = \omega_{ij}(t) + \alpha\Delta\omega_{ij}(t - 1) + \mu\delta_i(t)O_j(t) \quad \text{III. 25}$$

Où
$$\Delta\omega_{ij}(t - 1) = \omega_{ij}(t) - \omega_{ij}(t - 1)$$

α une constante positive de valeur faible ($0 \leq \alpha < 1$).

III.10.2. Algorithme d'apprentissage dans un MLP récurrent

Deux algorithmes sont souvent utilisés pour l'apprentissage des réseaux de neurones récurrents [87] :

III.10.2.1. Back propagation Through Time (BPTT)

III.10.2.2. Real Time Récurrent Learning (RTRL)

III.11. Conclusion

Dans ce chapitre on a défini les réseaux de neurones qui est un ensemble d'algorithmes composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente.

Dans notre travail on a utilisé le MLP (le perceptron multicouche) qui est un classifieur linéaire de type réseau neuronal formel organisé en plusieurs couches au sein des quelles une information circule de la couche d'entrée vers la couche de sortie uniquement.

Chapitre IV

Résultats de Simulation

IV.1. Introduction

Plusieurs méthodes d'identification ont été établies pour les signaux non linéaires. L'avènement de la méthode des réseaux de neurones (MNN), présente une approche d'identification très efficace au non linéarité des systèmes.

Dans ce chapitre on va appliquer cette technique d'identification sur quatre signaux non linéaires selon leur complexité inclus le signal Electrocardiogramme (ECG), et pour cela on va utiliser l'algorithme du rétro-propagation du gradient qui est un algorithme d'apprentissage supervisé, ainsi que la structure d'identification série-parallèle.

IV.2. Présentation des signaux à identifier

➤ *Signal 1*

Le système 1 à identifier sera donné par l'équation récurrente suivante :

$$y(k+1) = F[y(k)] + u(k)^3 \quad (\text{IV-1})$$

Où la fonction inconnue F est définie (pour la simulation) par :

$$F[y(k)] = y(k)/1 + y^2(k)$$

Le modèle d'identification est décrit par l'équation suivante :

$$\hat{y}(k+1) = \hat{F}[y(k)] + u(k)^3$$

➤ *Signal 2*

Le système 2 à identifier sera donné par l'équation récurrente suivante :

$$y(k+1) = f[y(k), y(k-1)] + u(k) \quad (\text{IV-2})$$

Où la fonction inconnue f a la forme :

$$f[y(k), y(k-1)] = y(k)y(k-1)(y(k) + 2.5)/1 + y^2(k) + y^2(k-1)$$

Le modèle d'identification sera décrit par l'équation suivante :

$$\hat{y}(k+1) = \hat{f}[y(k), y(k-1)] + u(k)$$

➤ **Signal 3**

Le système 3 à identifier sera donné par l'équation récurrente suivante :

$$y(k+1) = f[y(k), y(k-1), y(k-2), u(k), u(k-1)] \quad (IV-3)$$

Où la fonction inconnue f a la forme :

$$f[y(k), y(k-1), y(k+2), u(k), u(k-1)] = \frac{y(k)*y(k-1)*y(k-2)*u(k-1)*(y(k-2)-1)+u(k)}{1+y(k-2)*y(k-2)+y(k-1)*y(k-1)}$$

Le modèle d'identification sera décrit par l'équation suivante :

$$\hat{y}(k+1) = \hat{f}[y(k), y(k-1), y(k+2), u(k), u(k-1)]$$

IV.3. Résultats

➤ **Signal 1**

Pour le modèle neuronal, l'identification de F on a choisit les paramètres suivants :

- L'entrée du système et du modèle doit être $u(k) = \sin(2\pi k / 25) + \sin(2\pi k / 10)$
- Pour l'identification nous avons trouvé 2000 itérations pour minimiser l'erreur avec une entrée aléatoire entre $[-2, 2]$.
- 02 couches cachées.
- 20 neurones dans la première couche cachée.
- 10 neurones dans la deuxième couche cachée.
- Un seul neurone dans la couche de la sortie.
- La fonction d'activation utilisée dans les deux couches cachées est la fonction sigmoïde.
- Gain d'ajustement 0.1.

➤ *Signal 2*

Pour le modèle neuronal nous avons choisis les paramètres suivants :

- L'entrée du système et du modèle doit être $u(k) = \sin(2\pi k / 25)$
- Pour l'identification nous avons trouvé 10000 itérations pour minimiser l'erreur avec une entrée aléatoire entre [-2,2].
- 02 couches cachées.
- 20 neurones dans la première couche cachée.
- 10 neurones dans la deuxième couche cachée.
- Un seul neurone dans la couche de la sortie.
- La fonction d'activation utilisée dans les deux couches cachées est la fonction sigmoïde.
- Gain d'ajustement 0.1.

➤ *Signal 3*

Pour le modèle neuronal nous avons choisis les paramètres suivants :

- L'entrée du système et du modèle doit être $u(k) = \sin(2\pi k / 250) + \sin(2\pi k / 25)$
- Pour l'identification nous avons trouvé 10000 itérations pour minimiser l'erreur avec une entrée aléatoire entre [-2,2].
- 02 couches cachées.
- 20 neurones dans la première couche cachée.
- 10 neurones dans la deuxième couche cachée.
- Un seul neurone dans la couche de la sortie.
- La fonction d'activation utilisée dans les deux couches cachées est la fonction sigmoïde.
- Gain d'ajustement 0.1.

IV.4. La simulation

- *Signal 1*

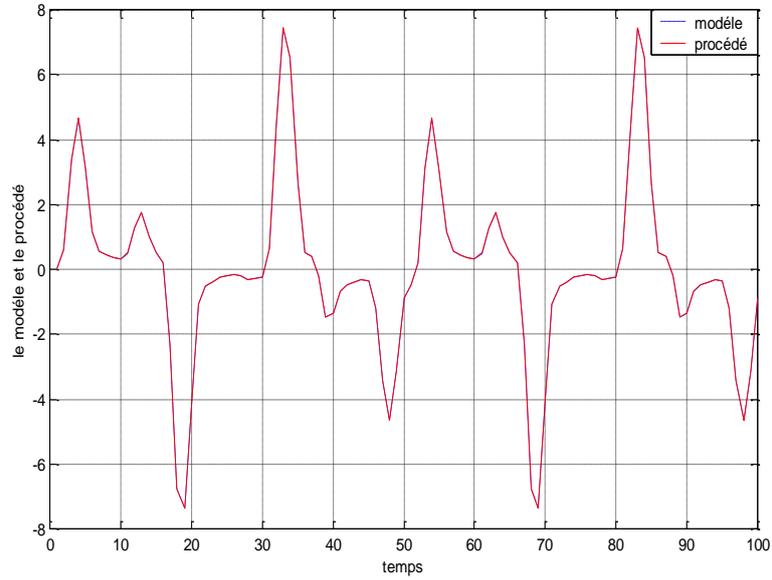


Figure.IV-1 : le modèle et le procédé

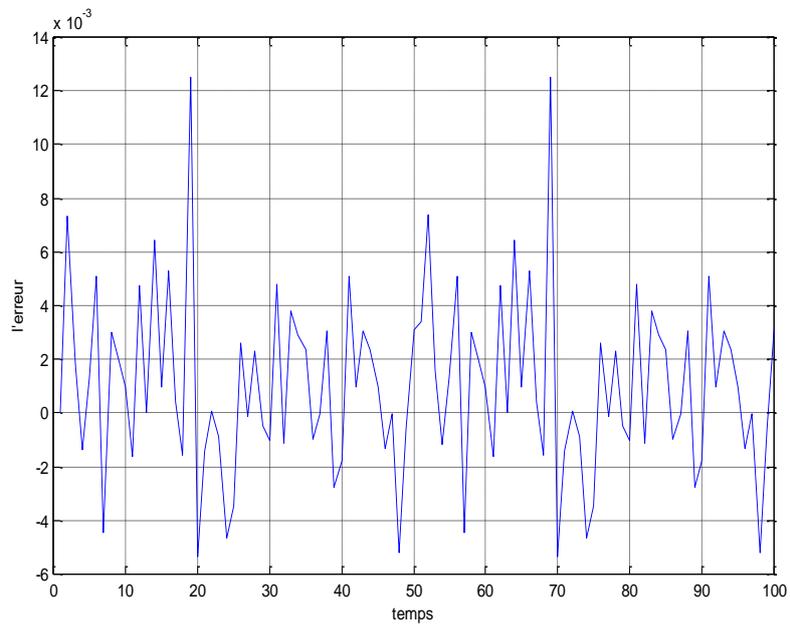


Figure.IV-2 : MSE entre le modèle et le procédé

- *Signal 2*

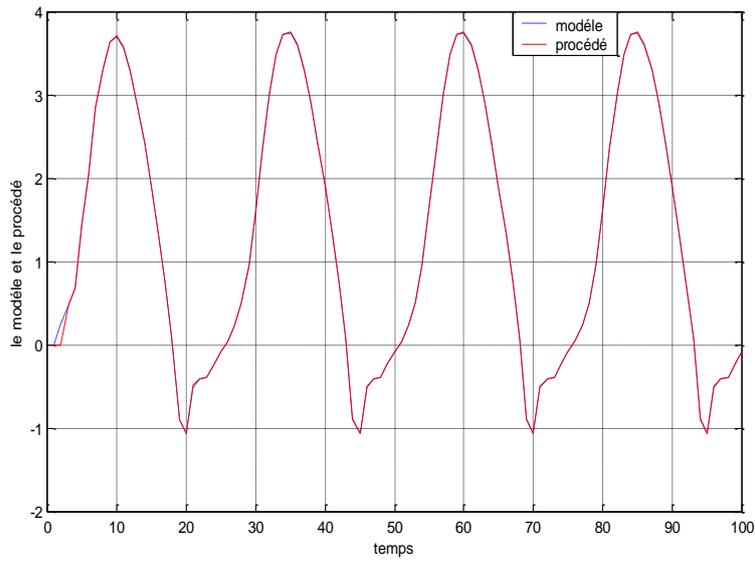


Figure.IV-3 : le modèle et le procédé

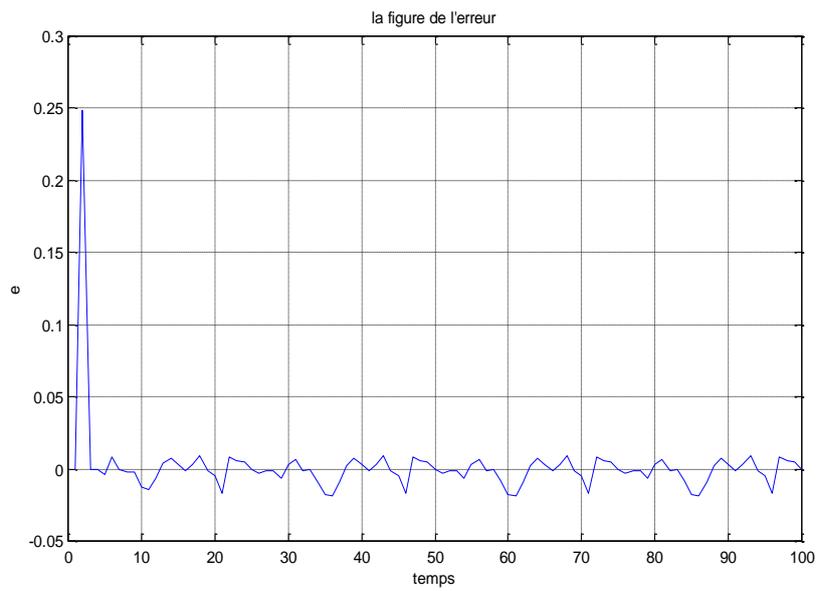


Figure.IV-4 : MSE entre le modèle et le procédé

- *Signal 3*

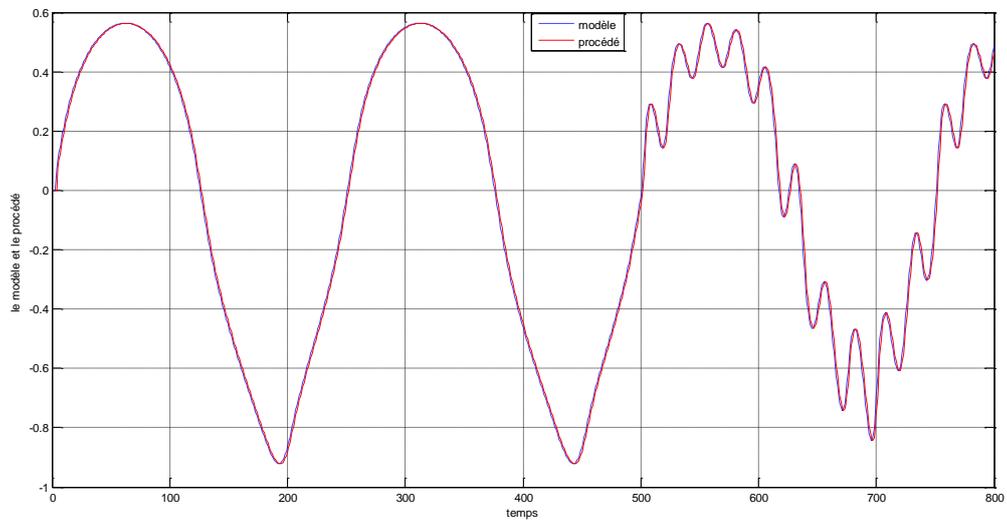


Figure.IV-5 : le modèle et le procédé

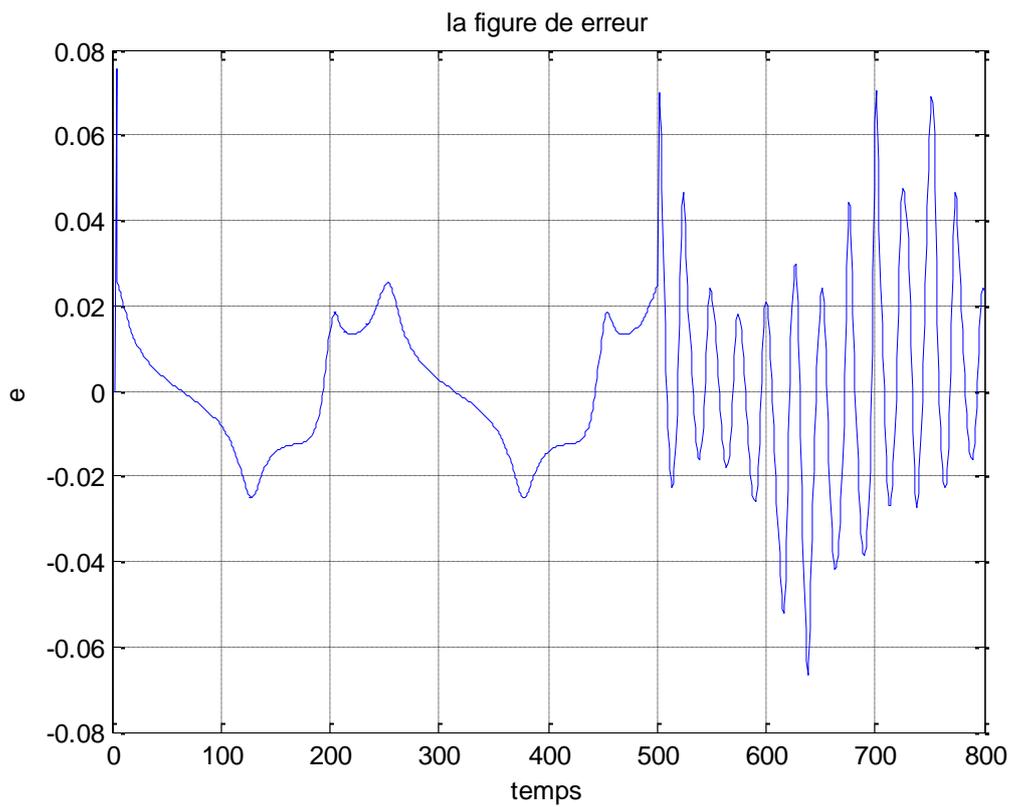


Figure.IV-6 : MSE entre le modèle et le procédé

IV.5.Choix du vecteur d’entrée du notre ECG

Le choix du vecteur d’entrée de notre réseau est très important pour la bonne reconnaissance des pathologies cardiaques. En effet, la qualité de la classification dépend énormément de la pertinence des paramètres du vecteur d’entrée.

Notre choix de caractérisation des différents battements cardiaques est établi en fonction des pathologies ciblées. Les paramètres de caractérisation choisis sont les mêmes paramètres sur lesquels le cardiologue se base pour établir son diagnostic [93].

Nous avons déterminé de chaque signal les amplitudes des ondes (P, Q, R, S, T) et les intervalles (P, QRS, T) comme des caractéristiques. Ces valeurs ont été prises en utilisant le **MATLAB** en tant qu’entrées de notre réseau MLP.

Dans ce qui suit un tableau résume les valeurs normales des différentes caractéristiques. Le signal ECG est normal si la valeur de ces caractéristiques située dans les intervalles citées dans le tableau ci-après, si leurs valeur est hors de ces intervalles donc le signal est anormal [94].

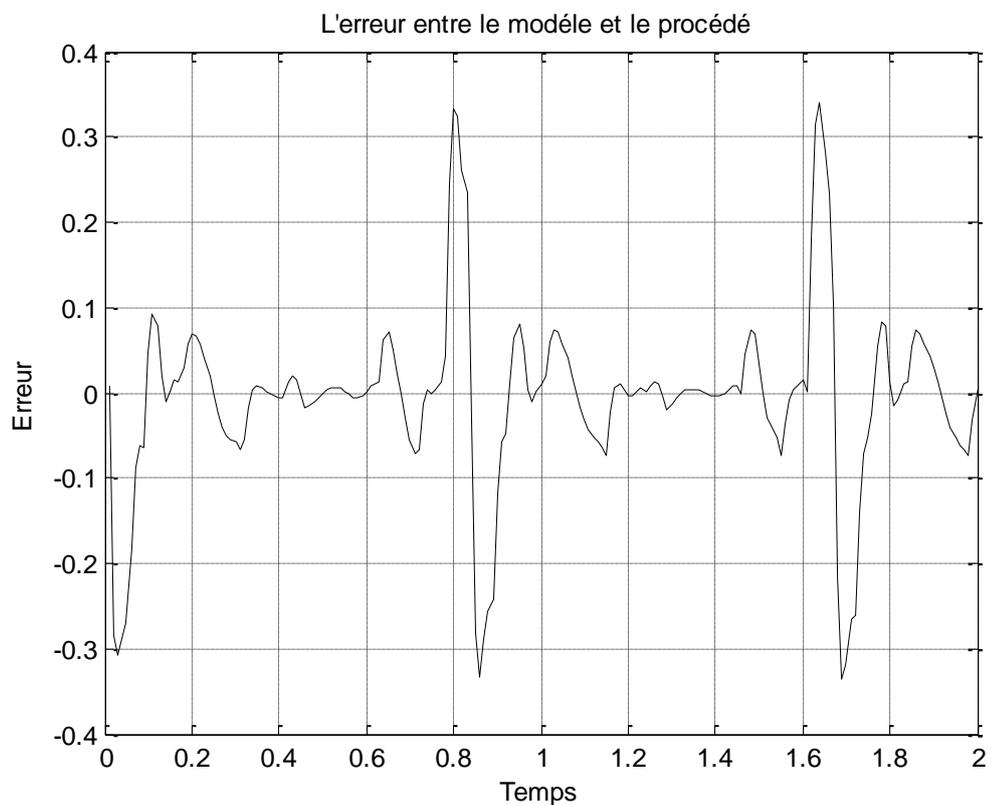
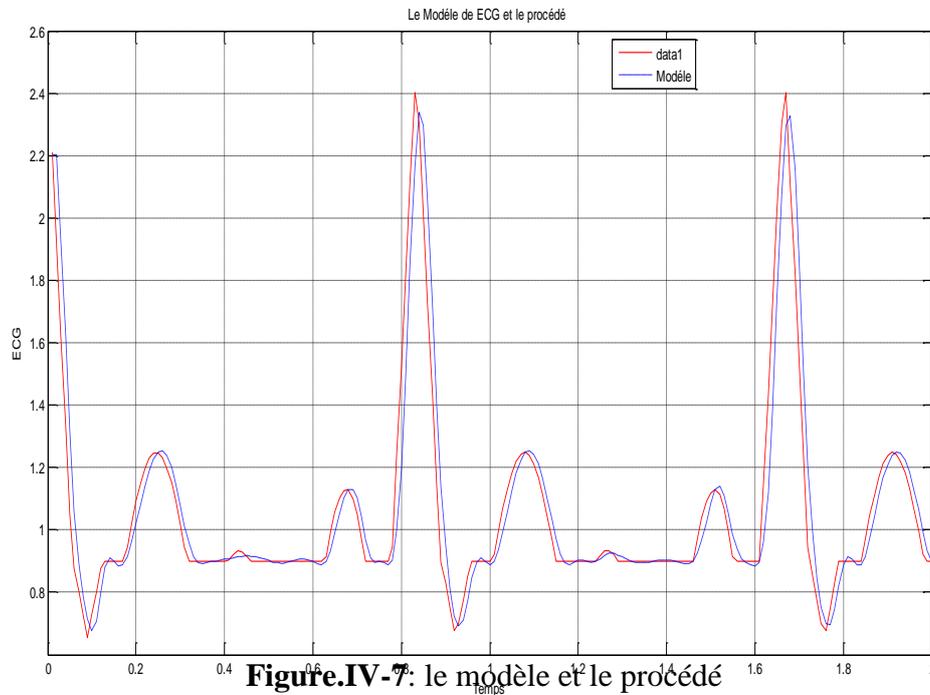
Les caractéristiques		Les valeurs	
Onde P	Durée (s)	0.06-0.11	
	Amplitude (mm)	<2	
Complexe QRS	Durée(s)	0.05 - 0.10	
	Amplitude	Q	<25% de R
		R	<5
S	<20		
Onde T	Durée (s)	0.20-0.25	
	Amplitude (mm)	>-3 et <4	

Tableau.IV-1 : Les différentes caractéristiques d’un ECG normal

Pour le modèle neuronal nous avons choisis les paramètres suivants :

- Pour l’identification nous avons trouvé 3000 itérations pour minimiser l’erreur avec 7 entrées aléatoire comme illustré dans le tableau précédent.
- 02 couches cachées.
- 40 neurones dans la première couche cachée.
- 40 neurones dans la deuxième couche cachée.

- Un seul neurone dans la couche de la sortie.
- La fonction d'activation utilisée dans les deux couches cachées est la fonction sigmoïde.
- Gain d'ajustement 0.01.



IV.6. Les équations d'électrocardiogramme (ECG)

R : le taux de battement de cœur (fréquence cardiaque = de (72-90)) pour un cœur normal

$$l = 30/R$$

a : amplitude

d : durée

t : intervalle

$$a_p = 0.25, d_p = 0.09, t_p = 0.16$$

$$a_q = 0.025, d_q = 0.066, t_q = 0.166$$

$$a_{qrs} = 1.6, d_{qrs} = 0.11$$

$$a_s = 0.25, d_s = 0.066, t_s = 0.09$$

$$a_t = 0.35, d_t = 0.142, t_t = 0.2$$

$$a_u = 0.035, d_u = 0.0476, t_u = 0.433$$

- **Le signal P**

$$x = t_p + x$$

$$b = 2l/d_p$$

$$p_1 = 1/l$$

$$p_s = \sum_{n=1}^N \left(p_1 + \frac{\sin\left(\frac{\pi}{2b}(b-2n)\right)}{(b-2n)} + \frac{\sin\left(\frac{\pi}{2b}(b+2n)\right)}{(b+2n)} \right) \left(\frac{2}{\pi}\right) \cos(n \times \pi \times x/l)$$

$$p_F = a_p p_s$$

- **Le signal Q**

$$x = t_q + x$$

$$b = 2l/d_q$$

$$q_1 = \left(\frac{a}{2b}\right)(2-b)$$

$$q_s = - \sum_{n=1}^N (q_1 + \frac{2 \times b \times a}{(n^2 \times \pi^2)} (1 - \frac{\cos(n \times \pi)}{b}) \cos(n \times \pi \times x)/l)$$

- **Le complexe QRS**

$$b = 2l/d_{qrs}$$

$$q_{rs1} = (\frac{a}{2b})(2 - b)$$

$$q_{rs_s} = \sum_{n=1}^N (q_{rs1} + \frac{2 \times b \times a}{(n^2 \times \pi^2)} (1 - \frac{\cos(n \times \pi)}{b}) \cos(n \times \pi \times x)/l)$$

- **Le signal S**

$$x = x - t_s$$

$$b = 2l/d_s$$

$$s_1 = (\frac{a}{2b})(2 - b)$$

$$s_s = - \sum_{n=1}^N (s_1 + \frac{2 \times b \times a}{(n^2 \times \pi^2)} (1 - \frac{\cos(n \times \pi)}{b}) \cos(n \times \pi \times x)/l)$$

- **Le signal t**

$$x = x - t_t - 0.045$$

$$b = 2l/d_t$$

$$t_1 = (\frac{1}{l})$$

$$t_s = \sum_{n=1}^N (t_1 + \frac{\sin((\frac{\pi}{2b})(b - 2n))}{(b - 2n)} + \frac{\sin((\frac{\pi}{2b})(b + 2n))}{(b + 2n)} (\frac{2}{\pi}) \cos(n \times \pi \times x)/l)$$

$$t_F = a_t \times t_s$$

- **Le signal u**

$$x = x - t_u$$

$$b = 2l/d_u$$

$$u_1 = 1/l$$

$$u_s = \sum_{n=1}^N \left(u_1 + \frac{\sin\left(\left(\frac{\pi}{2b}\right)(b-2n)\right)}{(b-2n)} + \frac{\sin\left(\left(\frac{\pi}{2b}\right)(b+2n)\right)}{(b+2n)} \right) \left(\frac{2}{\pi}\right) \cos(n \times \pi \times x/l)$$

$$u_F = a_u \times u_s$$

Le signal ECG

$$ECG = p_F + q_{rs_s} + t_F + q_s + u_F$$

IV.7. Interprétation des résultats

Nous avons étudié l'identification des signaux non linéaires selon leur complexité. Le signal 1 qui est le plus simple est un signal SISO d'entrée $u(k)$ et de sortie \hat{f} . Le signal 2 est un signal MISO d'entrée $[y(k), y(k-1)]$ et de sortie \hat{f} . Le dernier signal est le plus complexe, car la partie non linéaire à identifier est un signal MISO d'entrées $[y(k), y(k-1), y(k-2), u(k), u(k-1)]$ et de sortie $y(k+1)$. Le dernier signal est le sujet de notre mémoire c'est le signal ECG, la partie non linéaire à identifier est un signal MISO d'entrées $[li=30/72, a_p=0.25, d_p=0.09, t_p=0.16, a_q=0.025, d_q=0.066, t_q=0.166, a_qrs=1.6, d_qrs=0.11]$

La Figure.IV-1 montre les résultats de la simulation du signal 1 par les réseaux de neurone, dans la phase d'apprentissage, nous remarquons que le modèle converge vers la sortie du signal 1. Comme excitation nous avons pris une entrée aléatoire. Nous avons opté comme critère la moyenne de la somme des erreurs au carré MSE (Mean Square Error). Pour l'identification neuronale le MSE égal à $2.3727e-004$, ce qui est un avantage.

La Figure IV.3 montre les résultats de la simulation du signal 2 par les réseaux de neurone, dans la phase d'apprentissage, nous remarquons que le modèle converge vers la sortie du signal 2. Comme excitation nous avons pris une entrée aléatoire. Nous avons opté comme critère la moyenne de la somme des erreurs au carré MSE (Mean Square Error). Pour l'identification neuronale le MSE égal à $6.7267e-004$, ce qui est un avantage pour l'identification neuronale.

La Figure IV.5 montre les résultats d'identification du signal 3. La convergence des modèles vers le signal est toujours assurée. Comme excitation nous avons pris pour les deux cas la même entrée aléatoire toujours. Pour l'identification neuronale nous avons obtenu MSE égal à $4.2842e-004$. Ici sans discussion l'identification très mieux.

La Figure IV.7 montre les résultats de la simulation du signal 4 par les réseaux de neurone, c'est le signal ECG dans la phase d'apprentissage, nous remarquons que le modèle converge un peu vers la sortie du signal. Comme excitation nous avons pris 7 entrées aléatoires. Nous avons opté comme critère la moyenne de la somme des erreurs au carré MSE (Mean Square Error). Pour l'identification neuronale le MSE égal à 0.01

IV.8.Conclusion

Dans ce chapitre nous avons illustré l'identification par les réseaux de neurone utilisant la simulation, nous avons pris quelques signaux particulier de niveaux de complexité différent inclus le signal ECG, ainsi dans ce chapitre nous avons discuté les résultats obtenus par la méthode étudié.

Conclusion générale

Conclusion générale

Dans notre travail mené tout au long de ce mémoire, nous avons abordé le problème d'identification neuronale des signaux dynamique (application sur l'électrocardiogramme "ECG").

Le premier chapitre de ce mémoire a été dédié complètement à l'introduction et les différents aspects liés à la représentation des signaux dynamiques non linéaires. Différents modèles non linéaires ainsi que différentes structures de représentations permettant leur implantation ont également été présentés. Les méthodes d'estimation paramétrique les plus fréquemment utilisées ont aussi été présentées. Aussi, nous avons étudié dans ce chapitre le problème de l'identification des signaux non linéaires, nous avons vu qu'il existe plusieurs modèles d'identification pouvant être utilisés pour l'identification de ce type de signaux.

Dans le deuxième chapitre nous avons étudié une technique largement utilisée c'est l'électrocardiographie, elle remplit bien sa fonction et fourni de façon fiable un signal auquel nous pouvons appliquer des méthodes appropriées du traitement de signal. Ce chapitre a donné au lecteur les informations de base pour comprendre la génération du signal cardiaque ainsi que les méthodes de sa détection.

Nous avons consacré le troisième chapitre pour définir les réseaux de neurones qui est un ensemble d'algorithmes composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente.

Dans notre travail on a utilisé le MLP (le perceptron multicouche) qui est un classifieur linéaire de type réseau neuronal formel organisé en plusieurs couches au sein des quelles une information circule de la couche d'entrée vers la couche de sortie uniquement.

Et le dernier chapitre nous avons illustré l'identification par les réseaux de neurone utilisant la simulation, nous avons pris quelques signaux particulier de niveaux de complexité différent inclus le signal ECG, ainsi dans ce chapitre nous avons discuté les résultats obtenus par la méthode étudié.

Ce travail a montré que les réseaux de neurone est très efficaces pour l'identification des signaux non-linéaires, nous avons concentré sur les valeurs de MSE comme un indice de comparaison entre le modèle et le procédé.

Les perspectives de ce travail sont nombreuses :

- ✓ Sur l'aspect de l'identification on peut appliquer plusieurs méthodes récentes comme la logique floue type 2 et la méthode d'optimisation des particules (PSO) basé sur la technique (SWARM).
- ✓ Sur l'aspect physique on peut étudier le signal ECG avec perturbations et concevoir une technique pour filtrer les distorsions spécialement celles de l'instrument.

Bibliographie

Bibliographie

- [1] : NAIT-HAMOUD Mohamed Cherif, ‘‘ Segmentation et Classification du Signal ECG Par les SVM Flous Multi-classes ‘’, mémoire de magistère, Département des Mathématiques et Informatique, Université Cheikh Larbi Tbessi, Tébessa.
- [2] : M. Moavenian, and H. Khorrami, ‘‘A qualitative comparison of artificial neural networks and support vector machines in ECG arrhythmias classification’’, Expert systems with Applications, vol. 37, pp. 3088-3093, 2010.
- [3] : F. Sufi, I. Khalil, and J. Hu, ‘‘Handbook of information and communication security’’, pp.309-331, Springer, 2010.
- [4] : Lamine THIAW: ‘‘Identification de systèmes dynamiques non-linéaires par réseaux de neurones et multi modèles’’, thèse de doctorat. Université Paris XII, 2008.
- [5] : P.S. Sastry, ‘‘Memory Neuron Networks for Identification and Control of Dynamical Systems’’ IEEE Trans. On Neural Networks. Vol. 5, no.2, MARCH 1994
- [6] : L. Ljung. System Identification : Theory for the User. Englewood Cliffs, NJ, 1987.
- [7] : D. Urbain. Méthodes statistiques de sélection d’architectures neuronales : application à la conception de modèles de processus dynamiques. Master’s thesis, Université Paris 6, 1995.
- [8] : T. Cibas, F.F. Soulié, P. Gallinari, and S. Raudys. Variable selection with neural networks. NEUROCOMPUTING, 12 :223–248, 1996.
- [9] : G. Dreyfus. Réseaux de Neurones - Méthodologie et applications. Eyrolles, 2002.
- [10] : M. Schetzen. The Voltera and Wiener Theories of Nonlinear Systems. John Wiley, New York, 1980.
- [11] : Y. Gao and M.J. Er. Narmax time series model prediction : feedforward and recurrent fuzzy neural network approaches. Fuzzy Sets and Sytems, 150 :331–350,2005.
- [12] : Wei Z. Yang, Yam L.H., and Cheng L. Narmax model representation and its application to damage detection for multi-laer composites. Composite Structures, 68 :109–117, 2005.
- [13] : T. A. Johansen and B. A. Foss. Constructing narmax models using armax models.Int. J. Control, 58 :1125 – 1153, 1993.

- [14] : H.K. Fung Eric, Y.K.Wong, H.F. Ho, and M.P. Mignolet. Modelling and prediction of machining errors using armax and narmax structures. *Applied Mathematical Modelling*, 27 :611–627, 2003.
- [15] : M. Stone. An asymptotic equivalence of choice of model by cross-validation and akaike's criterion. *J. R. Stat. Soc.*, 38 :44–47, 1977.
- [16] : L. Breiman. Heuristics of instability and stabilization in model selection. *Annals of Statistics*, 24 :2350–2383, 1996.
- [17] : B. Efron and R.J. Tibshirani. Improvements on cross-validation : The .632+ bootstrap method. *J. of the American Statistical Association*, 92 :548–560, 1997.
- [18] : H. Akaike. Fitting autoregressive models for prediction. *Annal of the Institute of Statistical Mathematics*, 21 :243 – 247, 1969.
- [19] : H. Akaike. A new look at the statistical model identification. *IEEE Trans on Automatic control*, 9 :716 – 723, 1974.
- [20] : J. Rissanen. Modeling by shortest data description. *Automatica*, 14 :465 – 471,1978.
- [21] : Maïza Bekara. Optimisation de critères de choix de modèles pour un faible nombre de données. PhD thesis, Université de Paris XI, Novembre 2004.
- [22] : J.C. Carmona. Contribution à l'identification et la commande robuste de systèmes dynamiques complexes : de la théorie à l'application en mécanique. HDR, Université de la Méditerranée (Aix-Marseille II), Septembre 2004.
- [23] : T. A. Johansen. Robust identification of takagi-sugeno-kang fuzzy models using regularization. In *IEEE Conf. Fuzzy Systems*, New Orleans, 1996.
- [24] : T. A. Johansen. On tikhonov regularization, bias and variance in nonlinear system identification. *Automatica*, 33 :441–446, 1997.
- [25] : C. Foulard, S. Gentil et G.P. Sandaraz, " Commande et régulation par Calculateur " 3eme édition Eyrolles, 1982.
- [26] : K. S. Narendra and K. Parthasarathy, " Identification and Control of Dynamical Systems Using Neural Networks " , *IEEE Trans. On Neural Networks*. Vol. 1, No. 1, MARCH 1990

- [27] : Mr HABCHI Fares : ‘‘Identification et commande des systèmes non linéaires par les techniques neuronales’’, mémoire de magister, Département de génie électrique. université Abderrahmane MIRA de Bejaia,2013.
- [28] : Mr. Amar HODNI, ‘‘ ANALYSE DU SIGNAL ECG PAR RESEAUX DE NEURONES RECURRENTS’’, MEMOIRE DE MAGISTER, Département d’électronique, Université Mentouri Constantine, Année 2009.
- [29] : BOUREZG Assia, CHADBANE Fatima Zahra, ‘‘ DEBRUITAGE DES SIGNAUX ECG’’, Mémoire de Master Académique, Département d’électronique, Université MOHAMED BOUDIAF M’SILA, Année 2016.
- [30] : Boudiaf Hanane, ‘‘ Débruitage des signaux ECG à multi copies’’, Mémoire de Master, Département d’électronique, Université MOHAMED BOUDIAF M’SILA, Année 2017.
- [31] : S.A. Jones, "ECG Success, Exorcises in ECG Interprétation", A. A Davis 2008.
- [32] : K. Balkine, "Analyse et Modélisation d’Electrocardiogramme dans le cas de Pathologies Ventriculaires," Thèse de doctorat en Sciences, Université de Nice Sophia Antipolis-UFR Sciences, 2005.
- [33] : C. Cabrol, R. Vialle, "Anatomie du cœur humain." Université Paris - VI, Faculté de Médecine.
- [34] : SCHMIDT, Robert F., LANG, Florian, et HECKMANN, Manfred (éd.). Physiologie des menschen: mit pathophysiologie. Springer-Verlag, 2007. Or
- [35] : Michel Fischbach Guide pratique du cardiaque, prévention et suivi. Ed. Frison-Roche, 2002.
- [36] : K.Bensafia, ‘‘ Transmission sans fil, par voie GSM, et traitement du signal électrocardiographie (ECG)’’, mémoire de magister, département d’électronique, université Mouloud Mammeri, Tizi-Ouzou.
- [37] : Mr Omar BOURDJAM, ‘‘ Etude et Réalisation d’un Enregistreur Portatif d’ECG en Ambulatoire à base d’un Microcontrôleur. (1ere Unité d’un Système Holter)’’, MEMOIRE DE MAGISTER, département d’Instrumentation Electronique, UNIVERSITE DES SCIENCES ET DE LA TECHNOLOGIE « HOUARI BOUMEDIENE », Année 2012.

- [38] : CABASSON, Aline. Estimation et analyse des intervalles cardiaques. 2008. Thèse de doctorat. Université Nice Sophia Antipolis.
- [39] : FRANZ M. R., BARGHEER K., RAFFLENBEUL W., HAVERICH A. et LITHTLEN P. : Monophasic action potential mapping in human subjects with normal electrocardiograms : direct evidence for the genesis of the T wave. *Circulation*, 75 : 379–386, 1987.
- [40] : SILBERNAGL S. et DESPOPOULOS A. : Atlas de poche de physiologie. Flammarion Médecine- Sciences, 2001.
- [41] : ROWLANDS D. J., Comprendre l'Electrocardiogramme : Une nouvelle Méthode, 1ère partie l'ECG normal, Imperial Chemical Industries PLC, 1981.
- [42] : J.Sztajzel. Introduction à l'ECG: Service de Cardiologie, Hôpitaux Universitaires Genève.
- [43] : C.Lentner; Geigy Scientific Tables, heart circulation. CIBA-GEIGY, Volume 5.
- [44] : A.D. Waller, "A demonstration on man of electromotive changes accompanying the heart beat ", in: *Physiol.* 8, 229-234, 1887.
- [45] : I.E.W.Einthoven: "The man. The string galvanometer electrocardiograph", in: *Arch. Intern. Med.*, 148, 453-455, 1988.
- [46] : C. Fisch, "The clinical electrocardiogram", A classic, in: *Circulation* 62 (Suppl. III),1-4, 1980.
- [47] : D.M. Krikler, "Electrocardiography then and now. Where next?", in *Br. Heart J.*57, 113.
- [48] : HAMADOU EL MEHDI et BENDEHNOUN ALI « Développement et réalisation pratique d'un électrocardiographe ECG », Département de Génie Electrique, Spécialité électrotechnique, Centre Universitaire d'Ain Témouchent, année 2013/2014.
- [49] : F. Portet, « Pilotage d'algorithmes pour la reconnaissance en ligne d'arythmies cardiaques », Thèse de Doctorat, Université de Rennes 1. 2005.
- [50] : ARBATNI, Khaled. Réseaux de neurones appliqués à l'analyse et à la modélisation non linéaire du signal ECG. Mémoire de Magister en électronique. Université Mentouri de Constantine, Algérie, 2007.

- [51] : BOUKHATEM, MERZAK. CALCUL DU RYTHME CARDIAQUE PAR LA DETECTION DES PICS R POUR UN SIGNAL ECG. MASTER en GENIE ELECTRIQUE. Université M'hamed Bougara de Boumerdes, Algérie.2016.
- [52] : SAHRAOUI, Halima et ZAOUI, Halima. ETUDE ET REALISATION D'UN DISPOSITIF DE MESURE DU SIGNAL ELECTROCARDIOGRAMME (ECG). MASTER en GENIE BIOMEDICAL. Université Abou Bakr Belkaïd de Tlemcen, Algérie, 2016.
- [53] : RERBAL, Souhila. Traitement Numérique Du Signal Physiologique En Télémédecine. 2014. Thèse de doctorat.
- [54] : CHETTI, Imene Hachania et LATRACHE, Imene. Sécurisation des données médicales sous Android. Thèse de doctorat.
- [55] : Sebsadji Arslane, Sad Chaouch Mohamed EL Amine, " Mesure des données physiologiques avec un Smartphone", Mémoire de MASTER EN ELECTRONIQUE, DEPARTEMENT DE GENIE ELECTRONIQUE, Université Abdelhamid Ibn Badis Mostaganem, Année 2019.
- [56] : Daniel Tchiotsop. Modélisations polynomiales des signaux ECG. Application à la compression. Traitement du signal et de l'image [eess.SP]. Institut National Polytechnique de Lorraine - INPL, 2007. Français. tel-00197549
- [57] : C.H. Lu and C.C Tsai. Generalized predictive control using recurrent fuzzy neural networks for industrial processes. Journal of process control, 17 :83–92, 2007.
- [58] : M.N. Eskander. Neural network controller for a permanent magnet generator applied in a wind energy conversion system. Renewable Energy, 26 :463–477, 2002.
- [59] : A.A. Vartak, M. Georgiopoulos, and G.C. Anagnostopoulos. On-line gauss newtonbased learning for fully recurrent neural networks. Nonlinear Analysis, 63 :867–876,2005.
- [60] : S. Srivastava, M. Sing, M. Hanmandlu, and A.N. Jha. New fuzzy wavelet neural networks for system identification and control. Applied Soft Computing, 6 :1–17, 2005.
- [61] : K.S. Narendra and K. Parthasarathy. Identification and control of dynamical systems using neural networks. IEEE Transactions on Neural Networks, 1 :4–27, 1990.

- [62] : M. Husken and P. Stagge. Recurrent neural networks for time series classification. *Neurocomputing*, 50 :223–235, 2003.
- [63] : Tsung-Lin Lee. Back-propagation neural network for the prediction of the shortterm storm surge in taichung harbor, taiwan. *Engineering Applications of Artificial Intelligence*, 21 :63–72, 2008.
- [64] : T.G. Barbounis and J.B. Theocharis. Locally recurrent neural networks for longterm wind speed and power prediction. *Neurocomputing*, 69 :466–496, 2006.
- [65] : U. Konur and A. Okatan. Time series prediction using recurrent neural network architectures and time delay neural networks. *ENFORMATIKA*, pages 1305–1313, 2004.
- [66] : Q.P. Hu, M. Xie, S.H. Ng, and G. Levitin. Robust recurrent neural network modeling for software fault detection and correction prediction. *Reliability engineering & System Safety*, 92 :332–340, 2007.
- [67] : I. Guler and E.D. Ubeyli. A mixture of experts network structure for modeling doppler ultrasound blood flow signals. *Computers in Biology and Medecine*, 35 :565– 582, 2005.
- [68] : G. Carpenter and S. Grossberg. Neural dynamics of category learning and recognition: vigilance, memory consolidation and amnesia. (AAAS Symposium series), 1986.
- [69] : Wira PATRICE : " Réseaux de Neurones artificiels : architectures et applications ". Université de haute Alsace, laboratoire MIPS, 2009.
- [70] : Touzet CLAUDE : "Les réseaux de neurones artificiels-Introduction au connexionnisme". Editions la Machotte, 2016.
- [71] : Pierre Borne, Les réseaux de neurones - Présentation et applications, Editions Technip, coll. « Méthodes et pratiques de l'ingénieur », Paris.
- [72] : B. François, V. Michel, "Les réseaux de neurones artificiels", Presses Universitaires de France, Que Sais-je No 3042, 1re édition, 1996.
- [73] : B.Sylvain, Introduction aux Réseaux de Neurones, sylbarth@gmail.com.

- [74] : O. NERRAND, P. ROUSSEL-RAGOT, L. PERSONNAZ & G. DREYFUS « Neural Networks and Non-linear Adaptive Filtering: Unifying Concepts and New Algorithms. » Neural Computation, Vol. 5, pp 165-199, 1993.
- [75] : MERZOUKA NOURESSADAT, “ Etude des performances des réseaux de neurones dynamiques à représenter des systèmes réels : une approche dans l'espace d'état”, MEMOIRE DE MAGISTER, Département d'Electronique, UNIVERSITE DE SETIF 1.
- [76] : V.SRINIVASA .CHAKAVATHY AND JOYDEEP GHOSH » Scale-based clustering using the radial basis function network » IEEE Trans. On Neural Networks, Vol.7, No. 5, pp. 1250-12617, 1996.
- [77] : I. RIVALS, L. PERSONNAZ, G. DREYFUS & J.L. PLOIX « Modélisation, classification et commande par réseaux de neurones : principes fondamentaux, méthodologie de conception et illustrations industrielles » Publié dans : Les réseaux de neurones pour la modélisation et la commande des procédés, J.-P. Corriou coordonnateur, Lavoisier Technique et Documentation, Paris.1995.
- [78] : O. NERRAND, P. ROUSSEL-RAGOT, D. URBANI, L. PERSONNAZ, G.DREYFUS « Training Recurrent Neural Networks : Why and How? An Illustration in Process Modeling » IEEE Trans. On Neural Networks, Vol. 5, No. 2, pp. 178-184, 1994.
- [79] : HAYKIN, Simon. Neural networks and learning machines, –3rd ed, Copyright by Pearson Education. Inc., Upper Saddle River, New Jersey, 2009, vol. 7458.
- [80] : J.P. Nadal, «Réseaux de neurones : de la physique à la psychologie".
- [81] : D. Kadous" Utilisation des réseaux de neurones comme outil du datamining", Université Abou Bekr Belkaid, Tlemcen.
- [82] : G. Dreyfus. Réseaux de Neurones - Méthodologie et applications. Eyrolles, 2002.
- [83] : B. Irie and S. Miyake. Capabilities of tree-layered perceptrons. Proceedings of the IEEE Second International Conference on Neural Networks (San Diego), 1 :641–647, 1988.
- [84] : G. Cybenko. Approximation by superposition of a sigmoidal function. Mathematical Control Signals Systems, 2 :303–314, 1989.

[85] : P.J. Werbos. Backpropagation through time : What it does and how to do it. Proceedings of the IEEE, 78(10) :1550–1560, 1990.

[86] : D.E. Rumelhart, G.E. Hinton, and R.J. Williams. Learning representations by back-propagating errors. Nature (London), 323 :533 – 536, 1986.

[87] : P.D. Mandic and J.A Chambers. Recurrent neural networks for prediction – Learning algorithms, architectures and stability. JOHN WILEY & SONS, LTD, 2001.

Résumé

Le signal Electrocardiogramme (ECG) est un signal non stationnaire et non linéaire généré par un système non linéaire ; le cœur. Sa modélisation nécessite des techniques non linéaires. Nous avons utilisé les réseaux de neurones pour l'analyse et la modélisation de ce signal et l'objectif dans cette étude nous nous focalisons sur l'identification neuronale des signaux dynamiques ainsi une application sur l'Electrocardiogramme (ECG).

Mots-clés : Identification, Systèmes dynamiques non-linéaires, multi-modèles, réseaux de Neurones MLP, modèles récurrents, Electrocardiogramme

Abstract

The ECG is a nonlinear and non-stationary signal, generated from a nonlinear system; its modeling requires nonlinear approaches. We have used in this work the neural networks to analyze and identification of this signal, the objective of this study is the application of this technic on the Electrocardiogram signal (ECG).

الملخص

ان اشارة تخطيط القلب الكهربائيه هي اشارة غير ثابتة و غير خطية يتم انشاؤها بواسطة نظام غير خطي و مطابقتها تحتاج الى طرق غير خطية لذلك استعملنا نظام الشبكات العصبية من اجل دراسة ومطابقة هذه الاشارة والهدف من هذه الدراسة هو التركيز على تحديد الاشارات الديناميكية للخلايا العصبية وتطبيقها على التخطيط الكهربائي للقلب