

REPUBLIQUE ALGERIENE DEMOCRATIQUE ET POPULAIRE
Ministère de L'Enseignement Supérieur et de la Recherche Scientifique



UNIVERSITE A. MIRA – BEJAIA

FACULTE DE TECHNOLOGIE

DEPARTEMENT DE GENIE MECANIQUE

MEMOIRE DE FIN D'ETUDES

En vue d'obtention du diplôme de master en génie mécanique

Option : Fabrication Mécanique Et Productique

Thème :

Application des Réseaux de Neurones
Artificiels au Diagnostic des Défauts
Mécaniques des Machines Tournantes

Réaliser par : CHERRAT Lamine

Encadrant : Dr HARROUCHE Fateh

CHERIGUI Anis

Promotion 2021-2022

REMERCIEMENTS




On remercie Dieu le tout puissant de nous avoir donné la santé et la volonté d'entamer et de terminer ce mémoire.

Tous d'abord, ce travail n'aurait pas pu avoir le jour sans l'aide et l'encadrement de Mr : HARROUCHE Fateh On le remercie pour si conseils précieux, pour sa patience, sa rigueur et sa disponibilité durant notre préparation de ce mémoire.

Nos remerciements s'adressent également à tous les enseignants du département de génie mécanique pour leurs générosités et leurs professionnalismes dont ils ont su faire preuve durant tous notre parcours universitaire. Ainsi que tout le personnel de l'université A-MIRA Bejaia.

Finalement, On tient à remercier, messieurs les membres de jury pour le grand honneur qu'ils nous font en acceptant d'examiner et de juger ce modeste travail.



Je dédie ce modeste travail

A ma très chère mère

Quoi que je fasse ou que je dise, je ne saurai point te remercier comme il se doit. Ton affection me couvre, ta bienveillance me guide et ta présence à mes côtés a toujours été la bougie qui éclaire mon chemin, Que Dieu vous accorder santé, bonheur et longue vie.

A mon très cher père

Qui a consacré toute sa vie pour répondre à nos besoins et pour nos données la meilleure vie possible. Ta présence signifie beaucoup, Que Dieu vous accorder santé, bonheur et longue vie.

A mon grand frère

Les mots ne suffisent guère pour exprimer l'attachement, l'amour et l'affection que je porte pour vous, je vous souhaite beaucoup de réussite et de succès dans ta vie.

A mes deux petites sœurs

Sabrina et Anaïs qui je remercie infiniment pour toute leurs aides et à qui je souhaite tout le bonheur de monde.

A toute Ma famille


A mes deux grand père Mohamed et Meziane et grand-mère Fatima décidé tôt, A ma grand-mère Zhira que je souhaite une longue vie à toute mes tantes et tous mes oncles.

A tous mes amis

Anis, aissa, fahem, kouciela, soufiane, mazigh, Gaya, kamilia... Ça été un plaisir de vous connaître.

A mon binôme

Je remercie mon ami Anis cherigui qui a contribué à la réalisation de ce modeste travail.



L.A.M.P.V.E

Je dédie ce modeste travail

Tout d'abord je veux commencer à dédier ce modeste travail aux précieuses personnes qui nous ont quittés en une semaine, ma chère tante « jamila » et mon cher grand-père, Je n'oublierai jamais vos précieux conseils et je serai toujours fier de vous avoir comme mes ancêtres.

A mon très cher père

A mon exemple éternel, celui qui s'est toujours sacrifié pour me voir réussir, qui est toujours disponible pour nous, et prêt à nous aider. Que Dieu t'accorde une longue vie et une santé de fer. Et j'espère que je pourrais vous récompenser pour tous les sacrifices que tu as toujours consentis pour nous.

A ma très chère mère

Aucune dédicace ne saurait exprimer mon respect, mon amour éternel et ma considération pour les sacrifices que vous avez consenti pour mon instruction et mon bien être. Je vous remercie pour tout le soutien et l'amour que vous me portez depuis mon enfance. Que Dieu vous accorder santé, bonheur et longue vie.

A ma chère grand-mère

A la source de mes efforts, merci infiniment pour votre soutien et vos précieuse prières. Tu es la source de mon bonheur. Je te souhaite une bonne santé et longue vie.

A mon frère et mes deux petites sœurs

Yacine, Sarah et Nesrine, à que je leur souhaite beaucoup de bonheur et de réussite.

A toute la famille


A mes oncles et mes tantes, et particulièrement mon oncle Mourad qui m'a beaucoup aidé par ses conseils et son soutien. Que Dieu leur donne une longue et joyeuse vie.

A tous mes amis

Lamine, Youcef, Haithem, Samir, Abdnour, Aissa, fahem, kouciela, soufiane, Mazigh, Gaya, Idir, Mohand, ... Ça été un plaisir de vous connaître.

A mon binôme

Je remercie mon ami Lamine cherrat qui a contribué à la réalisation de ce modeste travail.




ANIS

Sommaire

Remerciement.....I
Dédicaces.....II
Sommaire..... IV
Liste des Figures..... IX
Liste des Tableaux..... XII
Nomenclature..... XIV
Introduction générale.....1

Chapitre I : Les Défaits Mécanique des Machines Tournantes

I.1-Introduction.....5
I.2- Principaux défauts des machines tournantes.....5
 I.2.1- Défaits liés à l’arbre.....5
 a- Balourd.....5
 b. Désalignement.....6
 I.2.2- Défaits d’engrenages.....7
 a- Défaits uniformes.....7
 b-Défaits localisés.....8
 c- Vibrations d’engrenages.....9
 I.2.3. Mauvais serrage mécanique.....10
 I.2.4- Défaits des roulements.....11
 a- Défaut sur la bague interne.....11
 b-Défaut sur bague externe12
 c- Défaits sur les éléments roulants.12
 d- Défaits sur la cage.....12
 I.2.4.1- La durée de vie des roulements.....12
 I.2.4.2- Principales défauts des roulements.....13
 I.2.4.3-Causes des défauts.....13
I.3. Les indicateurs de surveillance.....14
 I.3.1 Choix des indicateurs14
 I.3.2 Les indicateurs statistiques.....15



1- Moyenne : (Mean)15
2- Skewness : (Sk)15
3- Kurtosis : (Ku)16
4- Facteur de crête : (Fc)16
5- Ecart-type : (ET)17
I.4. Conclusion.....18

CHAPITRE II : Les Réseaux De Neurones Artificiels (RNA) Et Ces Applications En Diagnostic Des Défauts Mécanique Des Machines Tournantes

II .1- Introduction.....20
II.2- Historique.....20
II.3- Généralités sur les réseaux de neurones21
 II.3.1- Types de réseaux de neurones.....21
 II.3.2- Neurone biologique22
 II.3.3- Réseau formel.....23
 II.3.3- Apprentissage des Réseaux de neurones artificiels.....24
 II.3.4- Architecture des RNA.....25
II.4- Application des Réseaux de Neurones Artificiels dans le Diagnostic des Défauts Mécaniques des machines tournantes.....26
2.5- Conclusion.....28

CHAPITRE 3 : DEMARCHE EXPERIMENTALE

III.1. Introduction.....30
III.2- Réseau perceptron multicouches.....30
 III.2.1- Les couches de perceptron multicouche.....31
 III.2.2- Apprentissage du réseau perceptron multicouches.....32
III.3- Déroulement de la classification par le perceptron multicouche.....33
 III.3.1- Acquisition des signaux.....34
 III.3.2- Prétraitement des données.....34
 III.3.3- Construction du vecteur forme..34

III.3.4- Apprentissage et test du réseau..	34
III.3.5– Exploitation du réseau.....	34
III.4- Implémentation du PMC sous MATLAB.....	35
III.4.1- Création du réseau..	35
III.4.2- Apprentissage du réseau.	35
III.4.3- Test et validation du réseau.....	36
3.5 - Choix des paramètres du réseau..	36
3.5.1- Type du réseau..	36
3.5.2 - Prétraitement des données.....	36
3.5.3 - Nombre de couches cachées.....	37
3.5.4 - Nombre de neurones.....	37
3.5.5 - Initialisation des poids.....	37
3.5.6 - Taux d'apprentissage.....	38
3.5.7 - Fonction d'activation.	38
3.5.8 - Algorithme d'apprentissage.	38
3.5.9 - Critères d'arrêt.....	39
3.6 - Description de banc d'essais.....	39
3.6.1- Banc d'essai de roulements «the case western reserve university-bearing data center »...	39
3.7– Classification par les RNA.....	43
III.5- Conclusion.....	43

CHAPITRE 4 : RESULTATSET DISCUSSION

IV.1-Introduction.....	45
IV.2-Diagnostic des défauts de roulements par les RNA.....	45
IV. 2.1 Création de la base de données.....	46
IV.2.1.1 Préparation des observations	46
a- Division des signaux.....	46
b- Prétraitement et calcul des indicateurs.....	48
b.1) Indicateurs temporels..	48
b.2) Indicateurs fréquentiels.....	48

IV. 2.1.2 Constitution du vecteur forme de la base de données (Entrée du RNA).....	52
IV.2.2 Choix des classes de sortie (Sortie du RNA)	52
IV.2.3 Normalisation des données.....	53
IV.2.4 Classification de la base de données par à l'aide de l'outil de reconnaissance de forme par les RNA (nprtool)	53
IV.3 Les étapes à suivre dans l'outil de reconnaissance de forme.....	54
IV.3.1 Importation des bases de données globales (entrées et sorties).....	55
IV.3.2 Répartition des bases de données globales (entrées et sorties).....	55
IV.3.3 Apprentissage du réseau de neurones PMC.....	57
IV.3.4 Choix de la configuration finale du réseau de neurones(PMC).....	62
IV.4 Conclusion.....	66
Conclusion Générale.....	67
Référence Bibliographique.....	70

LISTES DES FIGURES

Numéro de figure	Titre	Page
Figure I.1	Représentation du balourd.	5
Figure I.2.	Allure spectrale d'un balourd.	6
Figure I.3	Désalignement angulaire et axial .	6
Figure I.4	Défaut d'usure.	7
Figure I.5	Défaut de piquûres.	7
Figure I.6	Défaut de fissuration.	8
Figure I.7	Défauts d'écaillage.	8
Figure I.8	Défauts de fracture.	9
Figure I.9	Représentation où N représente le nombre de dents.	9
Figure I.10	Représentation fréquentielle d'une seule dent détériorée.	10
Figure I.11	Représentation fréquentielle d'un Ensemble des dentures détériorées.	10
Figure I.12	Mouvais serrage mécanique et leur image vibratoire.	10
Figure I.13	Représentation d'un roulement.	11
Figure I.14	Exemple de deux distributions.	16
Figure II.1	Le neurone biologique.	22
Figure II.2	Schéma d'un neurone formel.	23
Figure II.3	Différents types de fonctions de transfert pour le neurone artificiel.	23
Figure II.4	Différentes architectures des RNA.	25
Figure III.1	structure d'un réseau perceptron multicouches.	31
Figure III.2	Organigramme de mise en place du (RNA) pour la classification des défauts.	33
Figure III.3	Etapas pour implémenter un PMC sous MATLAB	35
Figure III.4	Banc d'essai de roulements.	40
Figure III.5	Représentation des signaux temporels pour différents diamètres du défaut sur la bague intérieure.	42
Figure IV.1	Découpage d'un signal en tranches ou sections	47




Figure IV.2	Division en tranches du signal sans défaut.	49
Figure IV.3	Division en tranches du signal avec défaut de diamètre 0,028inch.	49
Figure IV.4	Variation de l'indicateur(ET).	50
Figure IV.5	Variation de l'indicateur(Fc).	50
Figure IV.6	Variation de l'indicateur(Acc).	50
Figure IV.7	Variation de l'indicateur(Ks).	50
Figure IV.8	Variation de l'indicateur(Ku).	50
Figure IV.9	Variation de l'indicateur(EBT).	50
Figure IV.10	Variation de l'indicateur(EB1).	51
Figure IV.11	Variation de l'indicateur(EB2).	51
Figure IV.12	Variation de l'indicateur(EB3).	51
Figure IV.13	Variation de l'indicateur(EB4).	51
Figure IV.14	Variation de l'indicateur(EB5).	51
Figure IV.15	Importation des bases de données (entrées et de sorties).	55
Figure IV.16	Répartition des bases de données (entrées et sorties).	56
Figure IV.17	Configuration initiale du réseau choisi	57
Figure IV.18	panneau de lancement de l'opération d'apprentissage	58
Figure IV.19	Résultats d'apprentissage, validation, et de test pour un seul neurone.	58
Figure IV.20	Résultats d'apprentissage pour un seul neurone dans la couche cachée.	59
Figure IV.21	Erreur minimale (mse) pour un seul neurone.	60
Figure IV.22	variations du gradient en fonction du nombre d'itération pour un seul neurone	60
Figure IV.23	4 Résultats d'apprentissage, validation, et de test pour un nombre de huit (8) neurones.	63
Figure IV.24	Résultats d'apprentissage pour un nombre de neurones égal à huit(8).	64
Figure IV.25	Erreur minimale (mse) pour un nombre de neurones égal à huit(8).	64
Figure IV.26	variation du gradient en fonction du nombre d'itération pour un huit(8) neurones.	65
Figure IV.27	Matrice de confusion des résultats de classification pour les bases d'apprentissage, validation, test, et la base globale.	65

LISTES DES TABLEAUX

Numéro de tableau	Titre	Page
Tableau I.1	Paramètres permettant de détecter un défaut sur une machine	14
Tableau I.2	les différents indicateurs	15
Tableau I.3	valeur Fc en fonction de la nature de vibration et les causes possibles.	17
Tableau III.1	Différents Algorithmes d'apprentissage.	38
Tableau III.2	Caractéristiques des défauts des roulements.	41
Tableau IV.1	<i>Etiquetage des classes.</i>	53
Tableau IV.2	<i>Valeurs de paramètres d'apprentissage, validation, et test en fonction du nombre de neurones dans la couche cachée.</i>	61

NOMENCLATURE

Notation utilisées	Signification	Unités
A	Amplitude	Pa
f_e	Fréquence d'engrènement	Hz
f_i	Fréquence initiale	Hz
f_{rot}	Fréquence de rotation de l'arbre	HZ
f_{ex}	Fréquence de la bague externe	HZ
$2f_e$	Harmonique 1	HZ
$3f_e$	Harmonique 2	HZ
N	Vitesse de rotation	mm/s
d_b	Diamètre des billes	mm
d_m	Diamètre moyen.	mm
α	angle de contact	Degré
C_R	une constante caractéristique de roulement	/
P_R	la charge équivalente sur le roulement	/
F_R	la fréquence de rotation	/
PMC	le Perceptron Multi Couches	/
ART	Adaptive Resonance Theory	/
RNP	Réseaux de Neurones Probabilistiques	/
RNA	Réseaux de neurones artificiels	/
RBF	Radial Basic Function.	/
ART	Adaptatif Resonance Theory.	/
SOM	Self Organized Map	/
ACP	analyse en composante principale	/
LM	Levenberg-Marquardt	/

RP	Resilient Backpropagation	/
SCG	Scaled Conjugate Gradient	/
OSS	One-Step Secant	/

Introduction générale

Introduction générale

La maintenance des machines tournantes est devenue ces dernières années, l'un des facteurs les plus importants dans plusieurs domaines (industrie, transport, ...). Cette importance est due au rôle de diagnostic dans la réduction des coûts de pannes et des taux de d'indisponibilité, ces interruptions non planifiées (les pannes) peuvent être très coûteuses. La perte de production pendant les réparations peut entraîner une perte de profits, si l'on y ajoute les problèmes de sécurité insuffisante pour le personnel, la qualité de production amoindrie et la perte éventuelle de réputation pour l'entreprise. Une telle maintenance n'est pas efficace sans tenir compte des méthodes de diagnostic, de la nature et de la complexité de l'installation de la machine surveillée et des mesures (pression, température, courant, vibration, etc.).

Les réseaux de neurones artificiels peuvent être utilisés pour la surveillance avec différentes manières. Il peut être utilisé comme outil de surveillance principal ou comme outil capable de reconstruire une quantité spécifique, par exemple la sortie du capteur. Cette estimation peut être utilisée, par exemple, pour évaluer des variables difficiles à mesurer ou à accéder. Sa valeur est importante pour la prise de décision et peut être utilisée pour prédire le développement futur au cours d'une période donnée. La surveillance utilise les réseaux de neurones comme outil de reconnaissance de formes. En fait, les problèmes de surveillance peuvent être considérés comme des problèmes de reconnaissance de formes. Les classes correspondent à divers modes de défaillance du système, et les formes représentent une série d'observations ou de mesures (données qualitatives ou quantitatives) du système.

Le mémoire est composé essentiellement de quatre principaux chapitre :

- Dans le premier chapitre, nous présentons les principaux défauts des machines tournantes tels que les défauts liés à l'arbre, engrenage, mauvaise serrages et les défauts des roulements (dans notre cas d'étude nous nous focalisons sur les roulements). Nous présentons aussi les indicateurs de surveillance utilisé en diagnostics des défauts.
- En deuxième chapitre, nous présentons les concepts et les bases des réseaux neurones artificiels (RNA) ainsi que l'état de l'art d'application de cette technique au diagnostic des défauts mécaniques des machines tournantes.

- Le troisième chapitre, décrit une approche expérimentale que nous suivons dans ce travail, En commençant par les différentes étapes de la mise en œuvre d'un système de diagnostic à base des Réseaux Neurones Artificiels (RNA).

Ensuite, nous présentons le banc d'essai de roulement et les signaux vibratoire prélevés, c'est dernier sont utilisé pour l'apprentissage, les tests et la validation du Réseaux(RNA).

- Le dernier chapitre est consacré aux résultats et discussions.

Enfin, nous terminons avec une conclusion générale, et quelques perspectives pour l'amélioration du travail.

CHAPITRE I
DEFAUTS MECANIQUES DES MACHINES TOURNANTES

I.1-Introduction :

Toutes les machines vibrent, et les vibrations générées représentent la somme de toutes les forces qui s'exercent sur la machine, la vibration mesurée et appelée signature vibratoire. Une quelconque modification, dans cette signature, nous renseigne sur l'état de santé de la machine. Le suivi de l'évolution dans le temps de la signature vibratoire, par les techniques d'analyse et d'interprétation des mesures de vibrations, aide à la mise en place d'une maintenance prédictive.

Dans la première partie de ce chapitre, nous présentons les défauts les plus courants dans les machines tournantes. Nous exposons ensuite, dans la deuxième partie les indicateurs utilisés dans le diagnostic de ces défauts par l'analyse des signaux vibratoires.

I.2- Principaux défauts des machines tournantes :

I.2.1- Défauts liés à l'arbre :

L'arbre est l'organe principal de la machine. C'est lui qui supporte et entraîne les organes mobiles en rotation, tels que les roues, les engrenages, etc. Le fonctionnement d'un arbre est caractérisé par un mouvement de rotation autour de son axe de rotation supporté par deux paliers à ses extrémités.

Nous présentons deux types de défauts pour les arbres, le déséquilibre massique des rotors (balourd) et la dégradation du lignage (désalignement). [1]

a- Balourd :

Un balourd, représenté par la figure 1.1, est caractérisé par un déséquilibre massique autour de l'axe de rotation qui produit des forces d'inertie, ces forces agissent sur les corps en rotation et surtout sur le roulement et excitent les paliers.




Figure I.1- Représentation du balourd.

L'allure spectrale, d'un balourd, est présentée par la figure 1.2. Elle est caractérisée par une composante dominante à la fréquence de rotation (f_r) de l'arbre.




Figure I.2- Allure spectrale d'un balourd.

b. Désalignement :

Le désalignement est dû au fait que l'arbre menant et l'arbre mené n'ont pas le même axe de rotation. Dans la figure I.3, nous présentons les différents types de désalignement ; désalignement axial et angulaire. [2]

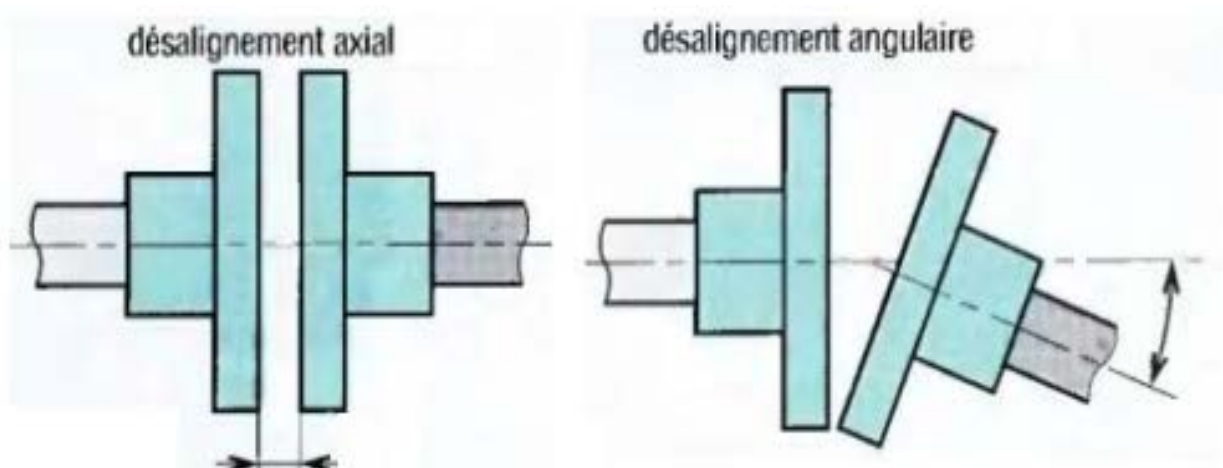


Figure I-3 Désalignement angulaire et axial [3].


I.2.2- Défauts d'engrenages :

Les engrenages ont pour fonction de transmettre une puissance d'un arbre en rotation à un autre arbre tournant à une vitesse généralement différente, les deux vitesses ont un rapport constant.

On peut distinguer pour les dentures d'engrenages deux types de défauts, des défauts uniformes et d'autres localisés. [4]

a- Défauts uniformes :

Les défauts uniformes concernent, en général toutes les dents, on peut citer deux exemples : **L'usure**, représentée par la figure I.4, est un enlèvement de matière dû au glissement des deux surfaces de contact. Il peut modifier le profil des dents et conduire à un mauvais fonctionnement de l'engrènement.



FigureI.4- Défaut d'usure.

Le défaut de **piqûres** (pitting) est présenté par la figure I 5. Il s'agit de trous plus ou moins profonds qui affectent toutes les dents, il peut évoluer suivant les matériaux jusqu'à la destruction de la denture.



FigureI.5- Défaut de piqures.

b- Défauts localisés :

Quant aux défauts localisés, ils ne concernent que quelques dents et se répartissent en trois types : La fissuration, l'écaillage et la fracture.

- **La fissuration** d'une dent représentée par la figure 1.6 conduit rapidement à la rupture de la dent.




Figure I.6- Défaut de fissuration.

- **L'écaillage** est représenté par la figure 1.7. Il s'agit également de trous ; mais ceux-ci sont moins nombreux, plus profonds et plus étendus que ceux du pitting.



Figure I.7- Défauts d'écaillage.

- **La fracture** qui est représentée par la figure 1.8, est un état de dégradation avancé de l'engrenage, elle génère des chocs importants sur le signal temporel.



Figure I.8- Défauts de fracture.

c- Vibrations d'engrenages :

Les vibrations induites par les engrenages ont une amplitude importante. Même en l'absence de défauts, les impulsions données à chaque engrènement provoquent des vibrations émergeant nettement du niveau global du bruit [5].

Le défaut soit significatif, si l'amplitude de la fréquence (raie) d'engrènement augmente ou s'il y a une génération d'autres fréquences (harmoniques et modulation de la fréquence d'engrènement) [6].

Les figures 1.9, 1.10 et 1.11 représentent les allures spectrales des différents cas d'une denture d'engrenage. [7]




Figure I.9- Représentation où N représente le nombre de dents.

Avec : A : l'amplitude

f_e : La fréquence d'engrènement

f_i : La fréquence initiale




Figure I.10- Représentation fréquentielle d'une seule dent détériorée.

Avec : f_1 : la fréquence dans le premier tour de l'engrenage

f_2 : la fréquence dans le deuxième tour de l'engrenage




Figure I.11- Représentation fréquentielle d'un Ensemble des dents détériorées

I.2.3. Mauvais serrage mécanique :

Lorsqu'un palier est desserré ou présente une possibilité de mouvement partiel dans le plan radial, il apparaît une vibration radiale à une fréquence égale à deux fois la vitesse de rotation. Cette vibration se produit sous l'effet du balourd initial et elle peut prendre une amplitude élevée en fonction du degré de desserrage du palier (Voir la figure I.12).

Une analyse du déphasage entre deux mesures prises orthogonalement sur un même palier permet de différencier une anomalie due à un balourd (force tournante), d'un défaut de serrage ou d'une déformation du support (force directionnelle due à la contrainte). [3]



Figure I.12- mauvais serrage mécanique et leur image vibratoire

I.2.4- Défauts des roulements :

Un roulement est un mécanisme, composé de bagues enduites d'une substance lubrifiante, qui est destiné à favoriser l'encastrement, le maintien de mouvement en rotation entre deux pièces. Les défauts de roulements sont la conséquence d'un balourd, d'un désalignement, d'un problème d'engrenage ou d'un manque de lubrification [8].

Les vibrations générées par des défauts de roulement se manifestent à des fréquences particulières ainsi qu'à leurs harmoniques, qui en général ne sont pas synchrones avec la vitesse de l'arbre. Ces fréquences correspondent aux éléments d'un roulement (voir la figure I.13) [9].

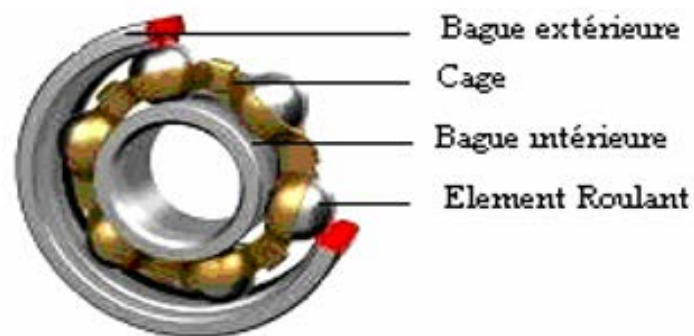


Figure I.13- Représentation d'un roulement [10]

a- Défaut sur la bague interne :

Il est caractérisé par la présence d'une raie à la fréquence caractéristique du défaut f_{bi} .

$$f_{bi} = \frac{N}{2} \left(1 + \frac{d_b}{d_m} \cos(\alpha) \right) (f_{rot} - f_{ext}) \quad (1.1)$$

f_{rot} : Fréquence de rotation de la bague interne

f_{ext} : Fréquence de rotation de la bague externe. En général elle est prise égale à zéro, si la bague extérieure est emmanchée (fixée) dans le carter.

N : Vitesse de rotation (rpm)

d_b : Diamètre des billes.

d_m : Diamètre moyen.

α : angle de contact

b- Défaut sur la bague externe :

Ce défaut est caractérisé par la présence d'un pic à la fréquence f_{be}

$$f_{be} = \frac{N}{2} \left(1 - \frac{d_b}{d_m} \cos(\alpha)\right) (f_{rot} - f_{ext}) \quad (1.2)$$

c- Défauts sur les éléments roulants :

La première fréquence caractéristique de défauts correspond à la fréquence de rotation de l'élément roulant (F_{er}) sur lui-même. De plus, cet élément roulant rencontre une première fois la bague interne et une seconde fois la bague externe dans chaque tour. Alors, il génère des chocs à deux fois cette fréquence.

$$f_{er} = \frac{1}{2} \frac{d_m}{d_b} \left(1 - \left(\frac{d_b}{d_m} \cos(\alpha)\right)\right) (f_{rot} - f_{ext}) \quad (1.3)$$

d- Défauts sur la cage :

Ces défauts se manifestent par la présence d'un pic à la fréquence f_{ca} et ses harmoniques.

$$f_c = \frac{1}{2} \left(1 - \frac{d_b}{d_m} \cos(\alpha)\right) f_{rot} + \frac{1}{2} \left(1 + \frac{d_b}{d_m} \cos(\alpha)\right) f_{ext} \quad (1.4)$$

I.2.4.1- La durée de vie des roulements : [11]

La durée de vie normale d'un roulement sous une charge est déterminée par la durée de l'usage et la fatigue des surfaces des éléments du roulement. La durée de vie est calculée comme suit:

$$L_h = \frac{\frac{C_R}{P_R}}{60 \cdot F_R}$$

Avec :

C_R est une constante caractéristique de roulement,

P_R : la charge équivalente sur le roulement

F_R : la fréquence de rotation.

I.2.4.2- Principales défauts des roulements :

Dans la plupart des cas, les défauts des roulements commencent par une perte locale de matériau sur une surface mate (bague intérieure et extérieure, éléments roulants) [12].

Le cas le plus rencontré est un défaut d'écaillage dû à la fatigue des roulements. L'écaillage de fatigue, est un phénomène normal qui conduit à une défaillance et ce, quel que soit les conditions d'utilisation et de fonctionnement. Ce défaut survient sous l'effet de la fatigue due aux contraintes de cisaillement alternées qui sévissent en sous-couche. L'écaillage localisé et prématuré résulte d'anomalies caractérisées telles qu'un mauvais montage, une surcharge, un défaut d'alignement, une mauvaise forme de logement. Ces défauts donnent naissance à des vibrations qui les caractérisent. [13]

On qualifie les principaux défauts :

- Le grippage, dû à l'absence de lubrification, à une vitesse excessive ou un mauvais choix du type de roulement. Ceci se manifeste par un transfert de matière arrachée sur les surfaces et redéposée par microsoudure.
- Les empreintes par déformation, dues à des traces de coups, des fissures ou des cassures.
- L'incrustation de particules étrangères, due à un manque de propreté au montage ou de l'entrée accidentelle d'impuretés.
- La corrosion de contact, due au mauvais choix d'ajustements entre les bagues et les logements ou les arbres.
- Les criques, fissures étroites ou autres amorces de cassures dues aux contraintes exagérées au montage ou au démontage.
- L'usure par abrasion, due à une mauvaise lubrification. L'usure par abrasion donne aux roulements un aspect gris, givré.

I.2.4.3-Causes des défauts :

Les roulements peuvent être endommagés par des causes externes comme :

- Contamination du roulement par des particules extérieures : poussière, grains de sable, ...
- Corrosion engendrée par la pénétration d'eau, d'acides, ...
- Lubrification inadéquate qui peut causer un échauffement et l'usure du roulement,
- Mauvais alignement du rotor,
- Courant qui traverse le roulement et qui cause des arcs électriques. [14]

Le tableaux I.2 présente quelques paramètres permettant la détection des défauts.

Paramètre / Défaut	Température	Pression	Débit	Analyse d'huile	Vibration
Déséquilibre					•
Arbre non aligné	•				•
Roulement	•			•	•
Palier	•	•	•	•	•
Engrenage	•			•	•
Frottement	•				•

Tableau I.1 Paramètre permettant de détecter un défaut sur une machine

I.3. Les indicateurs de surveillance :

I.3.1 Choix des indicateurs :

Le choix de ou des indicateurs (Tableau I.3) les mieux appropriées est fonction de :

- l'organe à surveiller (roulement, engrenage, palier, ...),
- la nature des vibrations (sinusoïdale, impulsionnel, ...),
- la plage de fréquences où le défaut est le plus facilement identifiable.
- certain nombre de traitements précoces à effectuer tel que, l'élimination des parties qui obscurcissent l'interprétation des signaux : bruit aléatoire, modulation d'amplitude ou de phase, phénomène de résonance, etc. Ces indicateurs doivent permettre une surveillance d'anomalies à un stade précoce, déterminant la nature et les états de dégradation. Selon donc les défauts redoutés, on choisira le ou les indicateurs les mieux appropriés en s'aidant du tableau I.2 [15].

Organe, type de vibration		Indicateur
Quelques exemples d'organe surveillés	Roulement	Accélération, kurtosis, Facteur crete, Cepstre, Démodulation d'amplitude
	Engrenage	Accélération, kurtosis, Facteur crete, Cepstre, Démodulation d'amplitude, Corrélation spectrale
	Palier fluides	Déplacement (relatif ou absolu)
Nom des vibrations générées	Vibration de type impulsional	Accélération, kurtosis, Facteur crete, Cepstre, Démodulation d'amplitude
	Vibration de type sinusoïdal	Déplacement, vitesse
Plages de fréquences où le défaut est plus facilement identifiable	Basses fréquences	Déplacement ou vitesse
	Moyennes fréquences	Vitesse ou accélération
	Haute fréquence	Accélération

Tableau I.2 : les différents indicateurs [15]

I.3.2 Les indicateurs statistiques :

Les indicateurs statistiques permettent de résumer un grand nombre de données, trop nombreuses pour être « lisibles », afin d'en dégager l'information utile.

1- Moyenne : (Mean)

Elle correspond au moment d'ordre 1, et caractérise la dispersion des variables autour de la moyenne, elle est donnée par :

$$M1 = \bar{X} = \frac{1}{N} \sum_{i=1}^N X_i$$

2- Skewness : (S_k)

Le skewness caractérise le taux de dissymétrie de la distribution d'amplitudes du signal par rapport à la valeur moyenne. Une fonction Skewness disponible sur Matlab, utilisée pour calculer le skewness d'un signal ($x = \text{skewness}(y)$) tel que y : le signal d'un défaut. [16].

Skewness est le moment d'ordre 3, il est donné par :

$$M_3 = s_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{x})^3$$

3- Kurtosis : (Ku)

Le Kurtosis vient du mot grec Kyrtoisis qui veut dire aplatissement ou convexity en anglais

C'est le moment d'ordre 4, il est donné par : [17]

$$M_4 = k_U = \frac{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x})^2\right)^2}$$

Le kurtosis de la distribution normale, il est supérieur à 3 si la distribution devienne plus centrée ce qui indique la présence d'un défaut et il est inférieur à 3 si la distribution est aplatie

Le Kurtosis prend une valeur égale à 3 pour un roulement sain et dépasse cette valeur dès d'un défaut de type écaillage [18].

Cette valeur est devenue la référence pour évaluer le degré d'aplatissement de la distribution par rapport à la distribution normale. Le mathématicien britannique Pearson a spécifié trois distributions : **mésokurtique**, **leptokurtique** ou **platykurtique**, représentant un aplatissement égal, supérieur ou inférieur à 3, respectivement.

La figure (I.14) montre deux exemples de distributions, (a) plus plate et (b) moins plate. [19]




Figure I.14. Exemple de deux distributions

4- Facteur de crête : (F_c)

Le Facteur crête, défini comme étant le rapport entre la valeur crête et la valeur efficace.

Il est donné par :

$$\text{facteur de crête} = \frac{\text{valeur crête}}{\text{valeur efficace}} = \frac{\sup|x(n)|}{\sqrt{\frac{1}{N_e \sum_{n=1}^{N_e} [x(n)]^2}}}$$

Le facteur de crête d'une distribution normale est compris entre 3 et 6, de ce fait il est un indicateur de la présence de chocs si sa valeur dépasse 6. [20]

Le facteur de crête comporte l'avantage de détecter les défauts avant la valeur efficace. Ceci provient du fait que pour un roulement sans défaut, le rapport reste sensiblement constant et augmente lorsqu'une dégradation apparaît alors que la valeur crête croît pendant que la valeur efficace reste à peu près constante. Si la détérioration du roulement croît, la valeur crête augmentera jusqu'à une valeur asymptotique et la valeur efficace, quant à elle, augmentera à son tour, rendant le facteur de crête sensiblement égal à sa valeur de départ.

Le tableaux I.3 présentes quelques valeur du facteur de crête en fonction de la nature de vibration et les causes possibles des défauts.

Nature de vibration	$F_{Crête} = \frac{v_{Crête}}{RMS}$	Causes possibles
Périodique de type sinusoïdal ou complexe	1.5 à 2.5	Balourd Désalignement
Aléatoire de type impulsif.	3 à 4	Roulement en bon état.
Périodique de type impulsif.	>4	Roulement écaillé.

Tableau I I.3- valeur Fc en fonction de la nature de vibration et les causes possibles.

5- Ecart-type : (ET)

l'écart type est une mesure de la dispersion des valeurs d'un échantillon statistique ou d'une distribution de probabilité. Il est défini comme la racine carrée de la variance ou, de manière équivalente, comme la moyenne quadratique des écarts par rapport à la moyenne. Il se note en général avec la lettre grecque σ (« sigma »), d'après l'appellation *standard deviation* en anglais. Il est homogène à la variable mesurée.

Il est donné par la formule suivant :

$$\sigma_x = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})$$

Avec : N : la taille de l'échantillon

\bar{X} : la valeur moyenne des données

X_i : la valeur de i dans l'ensemble des donnée

I.4. Conclusion :

Dans ce chapitre, on a présenté quelque défaut des machines tournantes (l'arbre, engrenage, mauvais serrage, roulement), ainsi que les causes principales des défauts et les symptômes provoqués, Dans notre cas d'étude on se focalise sur les roulements.

Dans le chapitre suivant, nous aborderons les réseaux de neurones artificiels, par la présentation de ces notions et concepts de base, et quelque travail réalisé comme application de cette technique en diagnostic des défauts mécaniques des machines tournantes.

CHAPITRE II

**Les Réseaux de Neurones Artificiels (RNA) et ces
Applications en Diagnostic des Défauts Mécanique des
Machines Tournantes**

II.1- Introduction :

Les réseaux de neurones sont des outils de l'intelligence artificielle. Ils se caractérisent par la capacité d'apprendre, de généraliser, de mémoriser, de classer, de s'adapter et de prendre des décisions. Ils sont utilisés dans divers domaines tels que la reconnaissance de formes, le contrôle et la robotique.

En maintenance industrielle, les réseaux de neurones sont utilisés pour résoudre des problèmes de diagnostic en classant automatiquement des signaux et des formes qui correspondent à différents états de fonctionnement normaux et anormaux d'une machine.

II.2- Historique :

L'origine de l'inspiration des réseaux de neurones artificiels remonte à 1890 où W. James, célèbre psychologue américain, introduit le concept de mémoire associative. Il propose ce qui deviendra une loi de fonctionnement pour l'apprentissage des réseaux de neurones, connue plus tard sous le nom de loi de Hebb. Quelques années plus tard, en 1949, J. Mc Culloch et W. Pitts donnent leurs noms à une modélisation du neurone biologique (un neurone au comportement binaire). Ce sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes.

Les premiers succès de cette discipline remontent à 1957, lorsque F. Rosenblatt développe le modèle du Perceptron. Il construit le premier neuro-ordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance des formes.

C'est alors qu'en 1960, l'automaticien Widrow développe le modèle Adaline (Adaptative Linear Element). Dans sa structure, le modèle ressemble au Perceptron, M. Minsky et S. Papert publient ensuite en 1969 un ouvrage qui met en évidence les limitations théoriques du Perceptron. Ces limitations concernent l'impossibilité de traiter des problèmes non linéaires en utilisant ce modèle.

Le renouveau de cette discipline reprend en 1982 grâce à J. J. Hopfield, un physicien reconnu. Au travers d'un article court, il présente une théorie du fonctionnement et des possibilités des réseaux de neurones. Alors que les auteurs s'acharnent jusqu'alors à proposer une structure et une loi d'apprentissage, puis à étudier les propriétés émergentes, J. Hopfield fixe préalablement le comportement à atteindre par son modèle et construit, à partir de la structure et la loi d'apprentissage correspondant au résultat escompté. Ce modèle est aujourd'hui encore très utilisé pour des problèmes d'optimisation.

C'est ensuite qu'en 1985 la rétro-propagation de gradient apparaît. C'est un algorithme d'apprentissage adapté au Perceptron Multi Couches. Sa découverte est réalisée par trois groupes de chercheurs indépendants. Dès cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau, en décomposant cette fonction en une suite d'étapes linéairement séparables.

Enfin, en 1989 Moody et Darken exploitent quelques résultats de l'interpolation multi variables pour proposer le Réseau à Fonctions de base Radiales (RFR), connu sous l'appellation anglophone Radial Basis Function network (RBF). Ce type de réseau se distingue des autres types de réseaux de neurones par sa représentation locale. [21]

II.3- Généralités sur les réseaux de neurones :

Un **réseau de neurones artificiels** est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement des neurones biologiques. Les réseaux de neurones sont généralement optimisés par des méthodes d'apprentissage de type probabiliste. Ils sont placés d'une part dans la famille des applications statistiques, qu'ils enrichissent avec un ensemble de paradigmes permettant de générer des classifications rapides, et d'autre part dans la famille des méthodes de l'intelligence artificielle auxquelles ils fournissent un mécanisme perceptif indépendant des idées propres de l'implémenteur, et fournissant des informations d'entrée au raisonnement logique formel. [22]

II.3.1- Types de réseaux de neurones :

Il existe plusieurs types de réseaux de neurones qui se différencient par leurs méthodes à aborder l'espace de données et leurs façons de répartir les différentes classes. Les architectures neuronales les plus utilisées en surveillance industrielle sont : [23]

- le Perceptron Multi Couches (PMC),
- les Réseaux à base de Fonctions Radiales (Networks based on Radial Functions),
- le modèle de Hopfield ,
- les réseaux de Kohonen. (Supervisé, et non supervisé),
- les réseaux ART (Adaptive Resonance Theory),
- les Réseaux de Neurones Probabilistiques (RNP).

Chaque méthode d'optimisation possède des avantages et des inconvénients. De nos jours, **les réseaux multicouches et la rétro-propagation de gradient** reste le modèle le plus étudié et le plus productif au niveau des applications.

II.3.2- Neurone biologique :

Dans le cerveau humain, le neurone est l'élément de base. Il reçoit des signaux en provenance de neurones voisins, les traite, engendre, conduit et transmet l'influx nerveux à d'autres neurones. La figure II.1 représente les éléments d'un neurone biologique. [24]




Figure II.1- Le neurone biologique

Le neurone est constitué de :

- **Les dendrites** : ce sont les récepteurs principaux du neurone pour capter les signaux qui lui parviennent.

- **Le corps cellulaire** : Il contient le noyau. C'est un sommateur à seuil. Il effectue une sommation des influx nerveux transmis par ses dendrites. Si la somme est supérieure au seuil, le neurone répond par un influx nerveux ou potentiel d'action qui se propage le long de son axone. Si la somme est inférieure au seuil, il reste inactif.

- **L'axone** : Il sert de moyen de transport pour les signaux émis par le neurone. Il se ramifie à son extrémité, là où il communique avec d'autres neurones.

- **Les synapses** : Ils permettent aux cellules nerveuses de communiquer entre elles. Les synapses se rencontrent surtout entre les axones et les dendrites.

II.3.3- Réseau formel :

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'oeuvre de MM. Mac Culloch et Pitts, Ils présentent un modèle assez simple pour les neurones et explorent les possibilités de ce modèle.

Le neurone représenté par la figure II.2 se compose d'une cellule possédant plusieurs entrées et une sortie. [25]

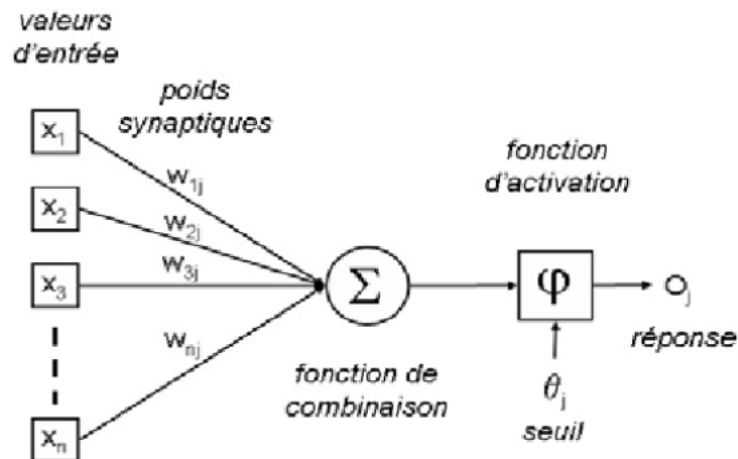


Figure II.2- Schéma d'un neurone formel

Il existe de nombreuses formes possibles pour la fonction de transfert. Les plus courantes sont présentées sur la figure II.3. On remarquera qu'à la différence des neurones biologiques dont l'état est binaire, la plupart des fonctions de transfert sont continues, offrant une infinité de valeurs possibles comprises dans l'intervalle $[0, +1]$ ou $[-1, +1]$.

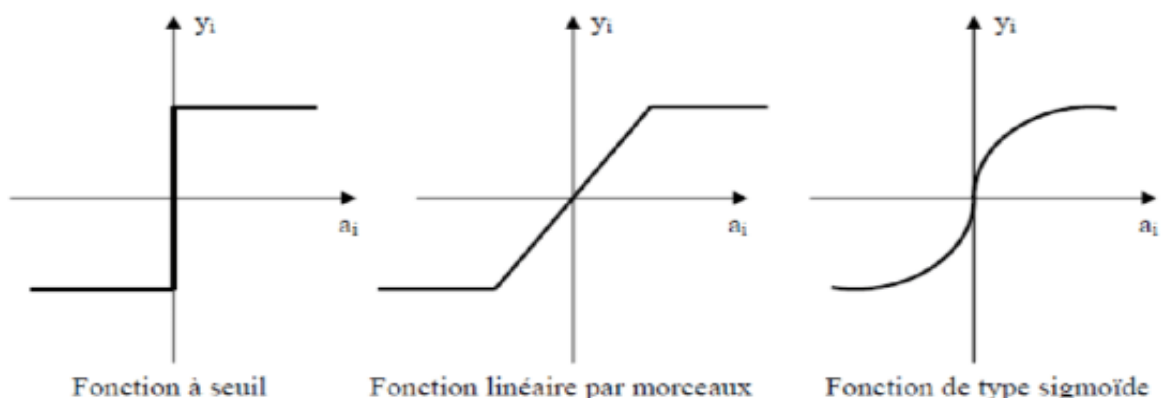


Figure II.3- Différents types de fonctions de transfert pour le neurone artificiel.

II.3.3- Apprentissage des Réseaux de neurones artificiels :

L'apprentissage des RNA, est une phase qui permet de déterminer ou de modifier les paramètres du réseau, afin d'adapter un comportement désiré. Plusieurs algorithmes d'apprentissage ont été développés depuis la première règle d'apprentissage de Hebb en 1949. Les RNA se divisent en deux principales classes, les réseaux à apprentissage supervisés et les réseaux à apprentissage non supervisés.

- Pour les réseaux à apprentissage supervisés (Perceptron, Adaline,...etc.), on présente au réseau des entrées, et au même temps es sorties que l'on désirerait pour cette entrée. Le réseau doit alors se reconfigurer, c'est-à-dire calculer ses poids afin que la sortie qu'il donne corresponde bien à la sortie désirée.
- Pour les réseaux à apprentissage non supervisé (Hopfield, Kohonen, etc.), on présente une entrée au réseau et on le laisse évoluer librement jusqu'à ce qu'il se stabilise. [26]

L'apprentissage des RNA se fait selon la stratégie suivante :

- Etape 1 :

- Les entrées d'un exemple sont injectées dans les cellules d'entrée du RNA.
- Le RNA calcule alors une sortie en fonction des états internes des neurones et des poids synaptiques des connexions.

- Etape 2 :

- La sortie obtenue est comparée avec la sortie désirée pour l'exemple.
- On obtient alors une erreur, particulièrement importante en début d'apprentissage car la réponse du RNA est à ce stade purement aléatoire.

- Etape 3 :

- Les poids synaptiques du RNA sont ensuite modifiés afin de réduire l'erreur calculée.

- Etape 4 :

- On réitère cette opération un grand nombre de fois, et ce pour chaque exemple de la base, jusqu'à ce que le RNA converge vers une configuration qui lui permette de résoudre le problème à traiter.

II.3.4- Architecture des RNA : [27]

Il existe différentes topologies de réseaux correspondant aux divers schémas géométriques de connexion entre les neurones. Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. La figure 2.4 présente une taxonomie possible en terme d'architecture de réseaux. La différence majeure porte sur la possibilité d'avoir des boucles dans le réseau. Par ailleurs, on notera la possibilité d'avoir des « couches » de cellules.

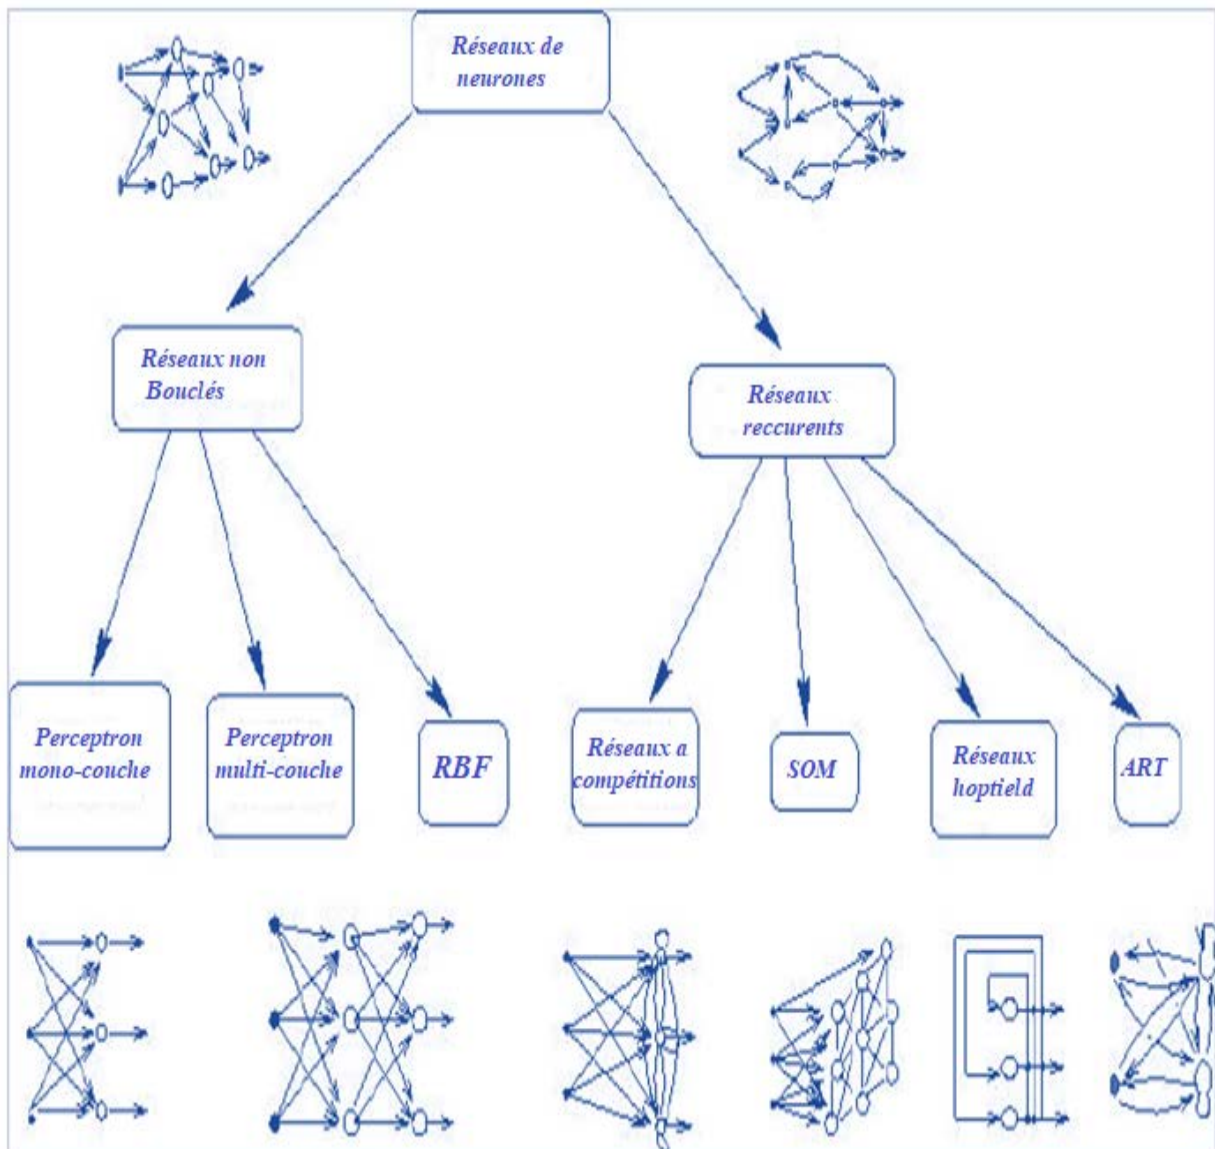


Fig. II.4- Différentes architectures des RNA. [28]

RBF: Radial Basic Function.

ART: Adaptatif Resonance Theory.

SOM: Self Organized Map.

II.4- Application des Réseaux de Neurones Artificiels dans le Diagnostic des Défauts Mécaniques des machines tournantes :

Les réseaux de neurones par leurs caractéristiques- décrites précédemment peuvent fournir une solution intéressante pour les problèmes de la maintenance des machines tournantes. De nombreux auteurs ont abordé ce sujet, on peut citer les travaux suivants :

A.C. Mac CROMICK ET A.K. NANDI (1996).

Appliquent les réseaux de neurones artificiels pour la classification automatique des états d'une machine. [29]

Leur expérience a trouvé les résultats suivant :

- ✓ Après une certaine itération (5000) le taux de succès de l'apprentissage est de 100 % mais le taux de réussite de teste et de 80 %
- ✓ -Le premier moment de chaque série temporelle a une plus grande influence sur les résultats plus importante que les autres moments.
- ✓ Le réseau qui a deux couches cachées (6 neurone et 4neurone), donne les meilleurs résultats car après 1000 itérations, il classe les données avec un succès de 100% pour l'apprentissage, et un taux de succès de 91.4 % pour le test.
- ✓ En utilisant un réseau de neurones avec deux couches cachées ayant six neurones dans chacune d'elles, donne un succès de 100 % pour l'apprentissage et de 99.4 % pour le test.

B.A. PAYA et al (1997).

Utilisant la transformée en ondelettes, pour le prétraitement des données. Les signaux utilisés ont été prélevés sur un banc d'essai de défauts de roulements et d'engrenages.

Six états de fonctionnements ont été étudiés et dédié le résultat suivant :

1. Roulement sans défauts, pignon sans défauts.
2. Roulement sans défauts, pignon avec défaut (a).
3. Roulement sans défauts, pignon avec défaut (b).
4. Roulement avec défauts, pignon sans défauts.
5. Roulement avec défauts, pignon avec défaut (a).
6. Roulement avec défauts, pignon avec défaut (b).

Le réseau employé a classé tous les cas avec un taux de succès de 96% en utilisant un réseaux multi couche avec 20 neurones dans la couche d'entrée et 14 et neurones dans la couche de sortie. [29]

D.YANG et J. PENMAN (2000).

Ils ont étudié quatre états des roulements en variant les données du courant électriques du moteur et celles des vibrations pour le diagnostic des roulements par la méthode des réseaux de neurones artificiels.

- N-N : roulement sans défauts et sans charge.
- F-N : roulement avec défaut et sans charge.
- N-F : roulement sans défauts et avec charge.
- F-F : roulement avec défaut et avec charge.

Ils ont trouvé que :

✓

Dans la phase d'apprentissage, tous les réseaux donnent un taux de succès égal 100%.

✓

Les résultats trouvés, montrent que les réseaux, contenant les données des vibrations, ont pu distinguer entre les quatre états avec un taux de succès de 100 % (taux de succès de 100 %).

✓

Les réseaux basés sur les données de vibrations sont plus performants que les réseaux basés sur les données du courant. [29]

L.B. JACK, A.K. NANDI (2000).

Ils ont utilisé un banc d'essai qui était réalisé pour étudier les défauts de roulements en utilisant les algorithmes génétiques pour sélectionner les données utilisées comme entrées des réseaux de neurones.

Ils étudient six états de roulements :

- Deux normaux ; un roulement est nouveau et l'autre est en état légèrement usé.
- Quatre anormaux (avec défauts).
- Défaut sur la bague intérieure.
- Défaut sur la bague extérieure.
- Défaut sur la cage.
- Défaut sur les éléments roulants.

Les auteurs trouvent que :

- La performance du réseau sans algorithmes génétiques avec l'entrée qui contient les valeurs du spectre, est meilleurs que celles de l'entrée qui contient les moments et les cumulant.

- L'utilisation des algorithmes génétiques réduit les nombres des entrées de 156 à 6, ce qui permet de réduire le temps de calcul et donc d'augmenter la performance du réseau. Le réseau de neurones idéal à 9 neurones dans sa couche cachée. [29]

2.5- Conclusion :

Ce chapitre a été consacré, à la présentation des réseaux neurones artificiels ensuite nous avons présenté leur histoire et leur développement dans le temps en suite des généralités (apprentissage et architecture) sur les réseaux de neurones artificiels (RNA).

Après avoir introduit leur concept de base, nous avons présenté une synthèse bibliographique de quelques travaux sur l'application des réseaux de neurones pour le diagnostic et la détection des défauts dans les machines tournantes. Les réseaux de neurones ont alors une large utilisation dans la maintenance industrielle.

Le chapitre suivant décrit, l'utilisation de la méthode de classification par réseaux de neurones pour la classification des défauts de roulement en basant sur l'analyse vibratoire, ainsi que son implémentation sous Matlab et la description du bancs d'essais étudié.

CHAPITRE III
DEMARCHE EXPERIMENTALE

III.1. Introduction :

Nous avons vu dans le chapitre précédent, que les réseaux de neurones artificiels ont une large application dans la maintenance industrielle des machines tournantes, et surtout le perceptron multi couche (PMC), Dans notre travail on va utiliser ce dernier type.

Dans ce chapitre, nous essayons d'utiliser ce réseau comme un outil de diagnostic des machines tournantes (roulements). L'objectif de ce travail est l'application de cette dernière pour l'automatisation du diagnostic de défaut des roulements à base d'un ensemble d'indicateurs des signaux vibratoire.

Ce chapitre est structuré en trois parties. La première partie contient les étapes de la mise en œuvre d'un réseau de type perceptron multi couche (PMC) pour le diagnostic.

La deuxième partie est consacrée à l'implémentation de perceptron multi couche utilisé comme un outil de diagnostic sous l'environnement MATLAB, en précisant le choix des différents paramètres du réseau.

Dans la troisième partie, nous présentons le banc d'essais et les signaux vibratoires prélevés.

III.2- Réseau perceptron multicouches :

Le réseau de neurones que nous allons utiliser s'appelle le « perceptron multicouche » (PMC). Ce type de réseau est dans la famille général des réseaux « propagation directe » (*feedforward*), c'est-à-dire qu'en mode normal d'utilisation, l'information se propage dans un sens unique, des entrées vers les sorties sans aucune rétroaction. Son apprentissage est de type supervisé. Dans cas uniquement, le signal d'erreur est « retro propage » vers les entrées pour mettre à jour les poids des neurones.

Le perceptron multicouche est un des réseaux de neurones les plus utilisé et pour des problèmes d'approximation, de classification et de prédiction. Il est habituellement constitué de deux ou trois couches de neurones totalement connectés.

III.2.1- Les couches de perceptron multicouche :

Le perceptron multicouche est organisé en trois parties :

➤ La **couche d'entrée** (input layer) :

La première couche est appelée couche d'entrée c'est un ensemble de neurones qui portent le signal d'entrée, cette couche recevra les indicateurs de surveillance, Sa taille est déterminée par le nombre de variables d'entrées.

Tous les neurones de cette couche sont ensuite reliés à ceux de la couche suivante.

➤ La **couche cachée** (hidden layer) :

Les couches cachées (couche cachée 1, couche cachée 2, ...). Il s'agit du cœur de notre perceptron, là où les relations entre les variables vont être mises en exergue.

Les fonctions d'activation sont en général non linéaires sur cette couche mais il n'y a pas de règle à respecter. Le choix de sa taille n'est pas implicite et doit être ajustée et pour avoir de bons résultats il faut essayer différentes tailles possibles.

➤ La **couche de sortie** (output layer) :

Cette couche représente le résultat final de notre réseau, sa **prédiction**.

Elle donne l'état de la machine. Sa taille est directement déterminée par le nombre de classes (ou modes de fonctionnement).

La figure III.1 présente la structure d'un réseau perceptron multi couche (PMC).

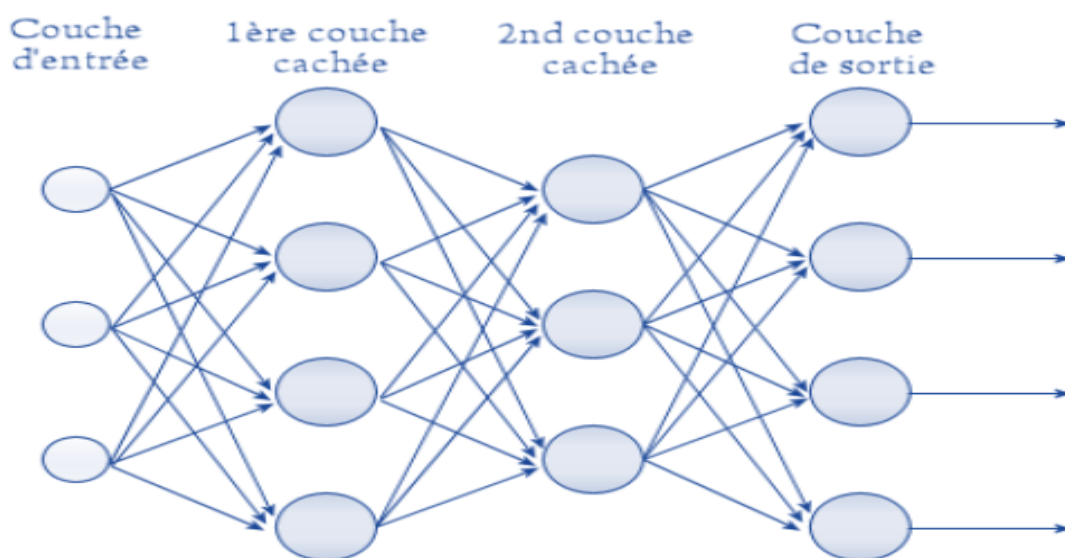


Figure. III.1- structure d'un réseau perceptron multicouches.

III.2.2- Apprentissage du réseau perceptron multicouches :

L'apprentissage du perceptron multicouche consiste à adapter les poids des neurones de manière à ce que le réseau soit capable de réaliser la tâche demandée.

On utilise l'algorithme de rétro-propagation (Parker et Lecun 1985). Cet algorithme repose sur la minimisation de l'erreur quadratique entre les sorties calculées et celles souhaitées. Le terme rétro-propagation du gradient provient du fait que l'erreur calculée en sortie est transmise en sens inverse vers l'entrée.

Il est défini par les étapes suivantes :

1. Initialiser les poids à des petites valeurs et les seuils du réseau.
2. Insérer à l'entrée du réseau une observation (exemple) de la base de données en forme de vecteur de caractéristiques, puis calculer sa valeur d'activation et sa fonction d'activation :

$$net_i = \sum_j w_{ij} O_j \quad (3.1)$$

$$O_i = f(net_i) \quad (3.2)$$

Avec :

f : La fonction d'activation.

O_i : La sortie du neurone i .

3. Évaluer l'erreur des sorties du réseau :

$$\delta_j = (d_j - O_j) O_j (1 - O_j) \quad (3.3)$$

d_j : La valeur de l'erreur désirée.

4. Ajuster les poids :

$$\Delta w_{ij} = \eta \delta_j o \quad (3.4)$$

η : La valeur de taux d'apprentissage.

5. Évaluer le signal d'erreur pour chaque couche cachée :

$$\delta_j = O_j (1 - O_j) \sum_k w_{kj} \delta_k \quad (3.5)$$

6. Ajuster les poids de la couche cachée en utilisant la formule (3.4).

7. Répéter les étapes 2 à 6 pour l'ensemble des observations de la base d'apprentissage tant que le critère d'arrêt n'a pas été atteint. La formule de calcul de l'erreur quadratique de l'ensemble de la base d'apprentissage définie comme suit :

$$E_p = \frac{1}{2} \sum_p \left(\sum_k d_{pk} - o_{pk} \right)^2 \quad (3.6)$$

Où p est l'indice d'un exemple de la base et k est l'indice du nœud de sortie. L'objectif est de minimiser cette erreur.

III.3- Déroulement de la classification par le perceptron multicouche :

Le traitement (classification) des différents états d'une machine par la méthode des réseaux de neurones artificiels se fait selon l'organigramme présenté par la figure III.2

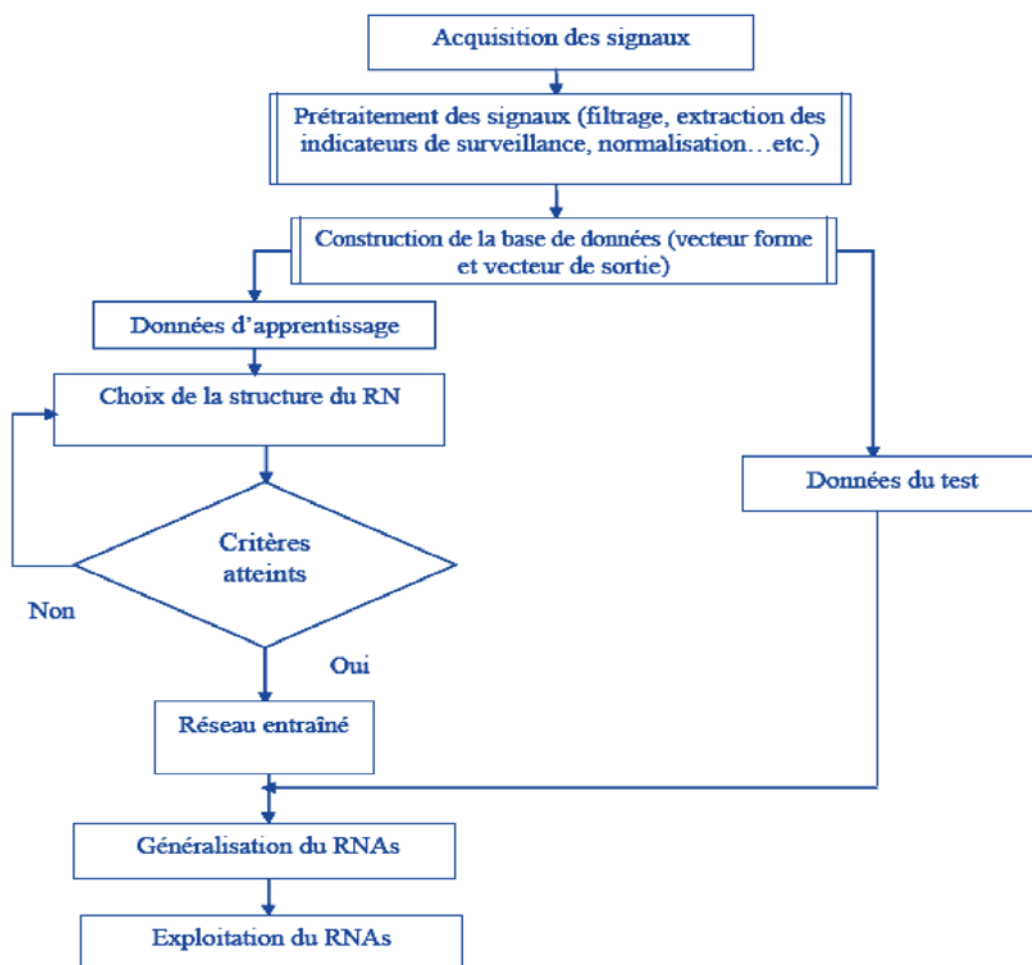


Figure III.2 Organigramme de mise en place du (RNA) pour la classification des défauts

III.3.1- Acquisition des signaux :

Dans cette étape, on collecte (enregistrer) les signaux vibratoires correspondant aux différents états du dispositif étudié (la machine).

III.3.2- Prétraitement des données :

Un prétraitement des données (entrées et sorties) est nécessaire pour éliminer toutes sorte d'informations inutiles existantes dans les différents signaux. Ainsi, cette étape consiste à faire un prétraitement sur la base de données (signaux), en utilisant les différentes méthodes du traitement de signal comme le filtrage, l'analyse spectrale, etc.

Aussi, on procède à une normalisation ou une sélection des données pour extraire les indicateurs les plus pertinents.

III.3.3- Construction du vecteur forme :

Le prétraitement des données permet d'extraire les indicateurs de surveillance correspondant à l'état de la machine. Ces indicateurs forment les vecteurs (matrice) de la base d'apprentissage et du test du réseau.

III.3.4- Apprentissage et test du réseau :

Une partie de la base des données est utilisée pour faire l'apprentissage du réseau, et l'autre est utilisée pour faire le test.

- L'apprentissage consiste à chercher une configuration optimale des paramètres du réseau (poids, biais,...etc.) correspondant à un taux de succès élevé.
- Une fois le réseau entraîné, il faut toujours procéder à des tests afin de vérifier que notre réseau réagit correctement.

III.3.5- Exploitation du réseau :

Après la détermination de la configuration optimale du réseau, ce dernier devient capable à classer d'autres états de la machine et décide l'existence ou non des défauts.

III.4- Implémentation du PMC sous MATLAB :

L'implémentation du réseau PMC sous MATLAB se fait selon le schéma suivant :

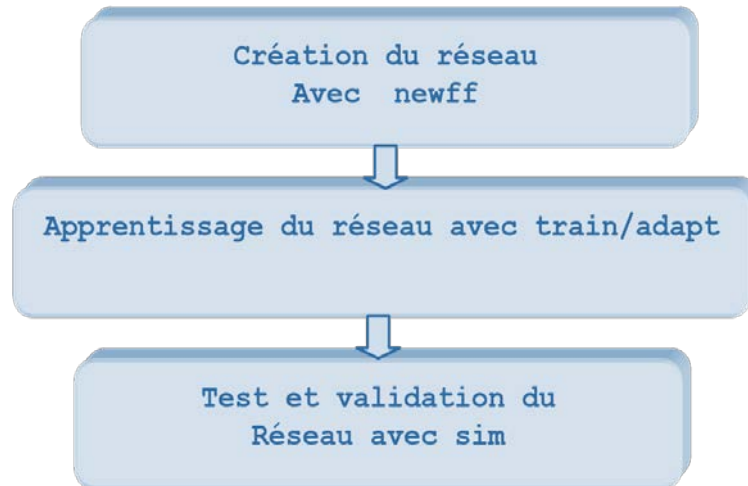


Figure III.3- Etapes pour implémenter un PMC sous MATLAB

III.4.1- Création du réseau :

La commande `newff` crée un réseau de neurones artificiel de type perceptron multicouche.

Syntaxe:

```
net = newff (PR, [S1, S2, ... Si], {TF1 TF2 TFNL}, BTF, BLF, PF)
```

PR: matrice des valeurs minimales et des valeurs maximales du vecteur d'entrée P.

Si : nombre des neurones dans la $i^{\text{ème}}$ couche (couches cachées et couche de sortie).

TFNL: fonction de transfert dans la $i^{\text{ème}}$ couche. (Tansig, purelin,...etc.)

BTF: fonction d'apprentissage par rétro-propagation du réseau. (trainlm,...etc.)

BLF : type d'algorithme utilisé (learngdm,... etc.)

PF : fonction de performance (mse, mae...etc.)

III.4.2- Apprentissage du réseau :

L'apprentissage se fait avec la fonction **train** pour l'apprentissage de type batch, c'est-à-dire, le calcul de l'erreur se fait après la présentation de tous les exemples d'apprentissage.

La syntaxe est : **net =train (net, P, T).**

Avec: **net**: réseau de neurones créé.

P:matrice des observations (entrée du réseau).

T: matrices des étiquettes (sortie du réseau).

Ou par **adapt** pour l'apprentissage de type incrémental, c'est-à-dire, l'erreur est calculée après chaque exemple. La syntaxe est la suivante :

net=adapt (net, P, T).

Avant d'exécuter les commandes **train** et **adapt**, il faut d'abord, entrer les paramètres d'apprentissage du réseau.

```
net.trainParam.lr = taux d'apprentissage.  
net.trainParam.show = fréquence d'affichage.  
net.trainParam.epochs = nombre max des itérations.  
net.trainParam.goal = Erreur minimale.
```

III.4.3- Test et validation du réseau :

Le test du réseau se fait avec la commande **sim** qui a la syntaxe suivante :

Y= sim (net, P)

Y: sortie calculée (réelle).

3.5 - Choix des paramètres du réseau :

Le succès d'un réseau de neurones artificiel, utilisé pour résoudre un problème de classification, est en relation directe avec la configuration du réseau. Car une mauvaise configuration (choix des paramètres) rend l'apprentissage plus lent ou sature le réseau, ou encore crée le sur-apprentissage du réseau. Ce qui n'est pas souhaitable, et surtout dans les problèmes du diagnostic industriel qui nécessite une décision rapide et précise sur l'état de santé des machines.

3.5.1- Type du réseau :

La synthèse bibliographique effectuée à la section 2.3, nous permet de choisir le type du réseau qui est le perceptron multicouche, parce qu'il est capable de résoudre les problèmes non linéaires.

Aussi, il s'implémente facilement sous MATLAB.

3.5.2 - Prétraitement des données :

Les données d'apprentissage ne sont pas présentées directement aux RNA, mais plutôt traitées d'avance. Le prétraitement des données (entrées/sorties) consiste à :

- a- Normaliser les valeurs de ces données, parce que les vecteurs d'entrées et de sorties des réseaux de neurones artificiels contiennent généralement des valeurs différentes. Et s'il existe un grand décalage entre eux, le réseau risque de se saturer ou d'échouer dans la classification.

Dans ce cas, une normalisation (rendre les valeurs très proches) des données est fortement demandée.

Il existe plusieurs méthodes pour normaliser un vecteur de forme, comme la méthode de normalisation par l'écart type et la moyenne. ($x_{nom} = \frac{x - x_{min}}{x_{max} - x_{min}}$)

b- Réduction de la taille des vecteurs d'entrées et de sorties, qui permet de construire des RNAs, avec moins de paramètres et mieux convient à apprentissage/généralisation. La réduction de la taille se fait par la méthode des algorithmes génétiques, analyse en composante principale (ACP)...etc. [30]

3.5.3 - Nombre de couches cachées :

Une des premières décisions à faire, est de déterminer combien de couches cachées sont nécessaires afin d'avoir un bon modèle. D'abord, on devrait affirmer qu'il n'y a aucun besoin d'avoir plus de couches cachées. Cette réponse est soutenue par les résultats théoriques et par beaucoup de simulations dans différents champs de technologie [31].

3.5.4 - Nombre de neurones :

Bien que le nombre de neurones dans les couches d'entrée et de sortie d'un réseau de neurones artificiels, puisse facilement être décidé pour le problème étudié. Il n'y a aucun critère pour déterminer le nombre des neurones convenable des couches cachées. Avec un nombre limité de neurones, le réseau ne sera pas performant sur l'apprentissage tandis qu'avec un nombre trop important de neurones il sera difficile à entraîner. On juge la performance d'un réseau sur sa capacité à généraliser les résultats et non pas sur sa capacité à mémoriser les résultats. C'est pour cela qu'il n'est pas toujours profitable d'utiliser un réseau avec un nombre élevé de neurones [32].

3.5.5 - Initialisation des poids:

Le choix des valeurs initiales des poids synaptiques pour l'apprentissage par l'algorithme de rétro-propagation du gradient, est l'un des aspects les plus importants qui affectent la procédure d'apprentissage des RNA. Pratiquement, il est nécessaire d'initialiser les poids aléatoirement avec des petites valeurs, par exemple, entre -0,5 et 0,5 [33].

3.5.6 - Taux d'apprentissage :

Le taux d'apprentissage η qui détermine l'ordre des incréments de poids à chaque étape d'ajustement, affecte certainement les performances de l'apprentissage t des RNAs. Généralement, on peut dire qu'une valeur grande du taux d'apprentissage peut causer des oscillations instables. Tandis qu'un taux d'apprentissage η plus petit peut ralentir la procédure d'apprentissage. Dans l'algorithme conventionnel de la rétro-propagation du gradient, on suppose que le taux d'apprentissage est une valeur fixe et doit être uniforme avec tous les poids [34].

3.5.7 - Fonction d'activation :

Comme les autres questions pratiques concernant les réseaux de neurones artificiels, il n'y a aucune réponse précise au sujet du choix de la fonction d'activation. Les fonctions d'activation les plus utilisées sont la fonction sigmoïde (pour les couches cachées) et la fonction linéaire (pour la couche de sortie). [35].

3.5.8 - Algorithme d'apprentissage :

Il est très difficile de savoir quel algorithme d'apprentissage sera le plus rapide en convergence pour un problème donné. Il dépendra de beaucoup de facteurs, y compris la complexité du problème, le nombre des données d'apprentissage, les valeurs des poids et le biais...etc.

Howard Demuth et Mark Beale présentent une comparaison entre les performances des différents algorithmes d'apprentissage par rétro-propagation du gradient [36].

Le tableau suivant présente les algorithmes qui sont examinés et leurs abréviations .

Abréviation	Algorithme
LM	trainlm - Levenberg-Marquardt
BFG	trainbfg - BFGS Quasi-Newton
RP	trainrp - Resilient Back propagation
SCG	trainscg - Scaled Conjugate Gradient
CGB	traincgb - Conjugate Gradient with Powell/Beale
CGF	traincgf - Fletcher-Powell Conjugate Gradient
CGP	traincgp - Polak-Ribiere Conjugate Gradient
OSS	trainoss - One-Step Secant
GDX	traingdx - Variable Learning Rate Backpropagation

Tableau III.1- Différents Algorithmes d'apprentissage.

3.5.9 - Critères d'arrêt :

Plusieurs critères d'arrêts peuvent être utilisés avec l'algorithme de rétropropagation des erreurs. Le plus commun consiste à fixer un nombre maximum de périodes d'entraînement, ce qui fixe effectivement une limite supérieure sur la durée de l'apprentissage. Ce critère est important car la rétropropagation des erreurs n'offre aucune garantie quant à la convergence de l'algorithme. Il peut arriver, par exemple, que le processus d'optimisation reste pris dans un minimum local. Sans un tel critère, l'algorithme pourrait ne jamais se terminer.

Un deuxième critère commun consiste à fixer une borne inférieure sur l'erreur quadratique moyenne, ou encore sur la racine carrée de cette erreur. Dépendant de l'application, il est parfois possible de fixer à priori un objectif à atteindre. Lorsque l'indice de performance choisi diminue en dessous de cet objectif, on considère simplement que le PMC a suffisamment bien appris ses données et on arrête l'apprentissage.

Les deux critères précédents sont utiles mais ils comportent aussi des limitations. Le critère relatif au nombre maximum de périodes d'entraînement n'est aucunement lié à la performance du réseau. Le critère relatif à l'erreur minimale obtenue mesure quant à lui un indice de performance; mais ce dernier peut engendrer un phénomène dit de sur-apprentissage qui n'est pas désirable dans la pratique, surtout si on ne possède pas une grande quantité de données d'apprentissage, ou si ces dernières ne sont pas de bonne qualité. [37]

3.6 - Description du banc d'essais :

Les signaux de simulation utilisés pour valider la capacité des réseaux de neurones artificiels à diagnostiquer les défauts dans les machines tournantes, sont enregistrés à partir du banc d'essai suivants:

3.6.1- Banc d'essai de roulements « the case western reserve university-bearing data center » :

Le banc d'essai (voir Figure.III.4) se compose d'un moteur "2 HP" (à gauche), d'un accouplement d'un transducer/encoder (centre), d'un dynamomètre (droit) et des circuits de commande (non montrés). Les roulements testés soutiennent l'arbre du moteur des deux cotés (coté entraînement et coté ventilateur). De simples défauts sous forme de points ont été créés sur les roulements d'essai, en utilisant l'usinage électro décharge .




Figure.III.4- Banc d'essai de roulements.

L'accès à la description et aux caractéristiques des différents roulements, et à la base de données des différents essais est possible sur le site web du laboratoire "[www.eecs.cwru.edu/laboratory/bearing/welcome overview.htm](http://www.eecs.cwru.edu/laboratory/bearing/welcome%20overview.htm)".

Le tableau III.2 représente les diamètres des défauts, leurs profondeurs et les marques de roulement utilisés.

Position du roulement	Emplacement du défaut	Diamètre [inches]	profondeur [inches]	Marque du roulement
coté entraînement	bague Intérieure	0.007	0.011	SKF
coté entraînement	bague Intérieure	0.014	0.011	SKF
coté entraînement	bague Intérieure	0.021	0.011	SKF
coté entraînement	bague Intérieure	0.028	0.050	NTN
coté entraînement	bague extérieure	0.007	0.011	SKF

coté entraînement	bague extérieure	0.014	0.011	SKF
coté entraînement	bague extérieure	0.021	0.011	SKF
coté entraînement	bague extérieure	0.014	0.050	NTN
coté entraînement	Bille	0.007	0.011	SKF
coté ventilateur	bague Intérieure	0.014	0.011	SKF
coté ventilateur	bague Intérieure	0.021	0.011	SKF
coté ventilateur	bague extérieure	0.007	0.011	SKF
coté ventilateur	bague extérieure	0.014	0.011	SKF
coté ventilateur	bague extérieure	0.021	0.011	SKF
coté ventilateur	Bille	0.007	0.011	SKF
coté ventilateur	Bille	0.014	0.011	SKF
coté ventilateur	Bille	0.021	0.011	SKF

Tableau III.2. Caractéristiques des défauts des roulements.

Les signaux ont été enregistrés à l'aide des accéléromètres, qui ont été fixés à la cage du moteur par aimant. Ces capteurs ont été placés à la position 12 heures "vertical", des deux cotés "accouplement et ventilateur" de la cage du moteur.

Les fréquences caractéristiques des éléments du roulement sont des multiples de la vitesse de rotation f_r :

- Fréquence de la bague intérieure: $f_{bi} = 5.415*(f_r)$
- Fréquence de la bague extérieure: $f_{be} = 5.584*(f_r)$
- Fréquence de la cage: $f_c = 0.3982*(f_r)$ - Fréquence de la bille: $f_b = 5.7135*(f_r)$

Tous les fichiers de données sont au format (*.mat). Chaque fichier contient trois données: signaux de vibrations des deux cotés et la vitesse de rotation du moteur. Pour notre étude nous avons considéré, seulement, des signaux du côté accouplement.

La Figure (III.5) représente les signaux temporels recueillis du côté de l'accouplement, pour différents diamètres de défauts, réalisés sur la bague intérieure, pour un couple moteur de 3HP. (HP : Horse Power)

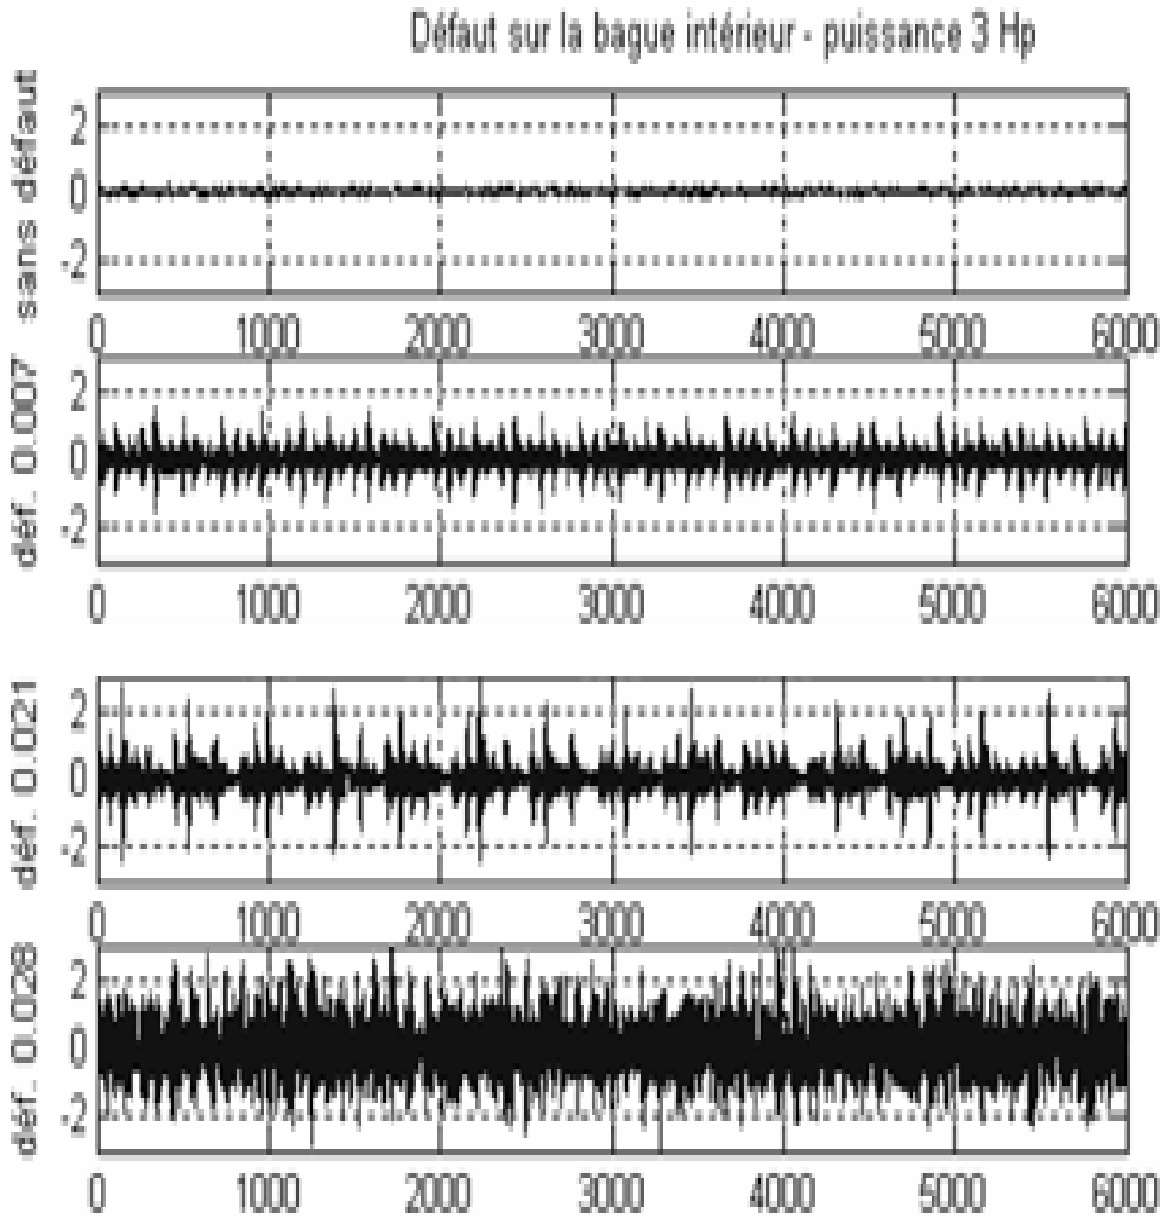


Figure III.5 Représentation des signaux temporels pour différents diamètres du défaut sur la bague intérieure.

3.7– Classification par les RNA:

Nous avons développé un programme sous environnement Matlab, qui offre la possibilité de classifier les différents états de santé des éléments des bancs d'essais étudiés, en utilisant les réseaux de neurones artificiels, et nous permet aussi de choisir et de varier les valeurs des paramètres du réseau utilisé. Comme nous avons aussi utilisé la boîte à outil Réseaux de Neurones Artificiels (Disponible sur MATLAB).

Les programmes sont exécutés sur un ordinateur HP Eliteook avec ram de 8G et une vitesse de 2.30 GHZ

III.5- Conclusion :

Ce chapitre est consacré aux méthodes expérimentales de diagnostic des machines tournantes en classant différents signaux correspondant à différents états de la machine au moyen de réseaux de neurones artificiels. Nous avons expliqué le processus étape par étape. Nous avons constaté que plusieurs paramètres étaient impliqués dans le succès des diagnostics basés sur les RNA. Malgré les travaux et les recherches qui ont été effectués sur le sujet, la difficulté de tels diagnostics réside toujours dans le choix des paramètres du réseau ; en partant des éléments du vecteur de forme, en passant par l'architecture du réseau, jusqu'au vecteur de sortie.

Nous notons ici qu'il n'y a pas de règles pour la sélection des paramètres des réseaux de neurones artificiels, ces paramètres varieront en fonction du problème étudié. Seule l'expérience peut être efficace pour faire un bon choix des paramètres. Nous n'oublierons pas la simplicité de mise en œuvre de réseaux de neurones multicouches de type perceptron dans l'environnement de langage MATLAB. Il suffit de déterminer les différentes valeurs correspondant aux différents paramètres du réseau puis d'exécuter les différentes commandes.

CHAPITRE IV
RESULTATSET DISCUSSION

IV.1-Introduction

Le grand nombre des paramètres qui influencent les performances des Réseau de neurones artificiels (de type perceptron multicouche) complique grandement l'utilisation de ces réseaux dans le diagnostic des défaut des machines tournantes. Cependant, ces paramètres n'ont pas le même impact et la même importance sur les performances de réseaux de neurones artificiel.

Ce chapitre décrit l'impact du choix de l'apprentissage et la configuration sur la performance du perceptron multicouche.

On a traite l'effet du nombre maximal d'itérations, du nombre de neurones dans la couche cachée, la valeur du taux d'apprentissage, et la valeur de l'erreur minimale, et du nombre des exemples d'apprentissage sur les performances du RNA.

On a appliqué le perceptron multi couche dans le diagnostic de roulement.

IV.2-Diagnostic des défauts de roulements par les RNA :

Dans cette partie du travail, les signaux que nous avons utilisé sont prélevés du banc d'essai Data centre bearing (défauts de roulements). Le réseau de neurones utilisé dans cette application, est **un réseau perceptrone multicouche** avec un apprentissage de type rétro-propagation du gradient. Les signaux que nous proposons d'étudier sont enregistrés pour les défauts de la bague intérieure dans les conditions suivantes:

- L'arbre tourne à une vitesse de 1730 tr/min.
- La puissance (couples résistants) est de 3HP.
- trois diamètres de défauts : 0.07, 0.21 et 0.28 inch, ont été créés sur la bague intérieure
- Les signaux sont prélevés du coté accouplement.

Avant de commencer la classification des différents défauts, on procède à un prétraitement des signaux.

HP : (horespower) unités de puissance.

IV. 2.1 Création de la base de données

L'ensemble des signaux disponible contient quatre signaux ; un signal sans défauts et les trois autres avec défauts. Comme, les systèmes à base des réseaux de neurones artificiels nécessitent une grande base de données pour faire la classification (Lou et Loparo, 2004), (Saravanan et al, 2009), (Dawu et al, 2009), (Sugumaran et al, 2007), et pour avoir suffisamment de données, nous avons divisé chaque signal en K_t tranches.

IV.2.1.1 Préparation des observations

a) Division des signaux

Pour avoir suffisamment de données, nous avons divisé chaque signal en K_t tranches de N_M points à condition que le nombre d'échantillons pour chaque tranche doit être suffisamment grand, pour couvrir un nombre suffisant du plus grand cycle correspondant à la plus grande période (la plus petite vitesse de rotation).

Nous disposons des signaux de longueur de 120800 points. L'arbre tourne avec une vitesse de 1730 rpm.

$$fr_{\text{arbre}} = \frac{1730}{60} = 28.83\text{HZ}$$

On a quatre fréquences caractéristiques correspondantes aux différents éléments du roulement (cage, bague extérieure et intérieure et les éléments roulants). La plus grande période correspond à la plus petite fréquence.

Dans notre cas, la plus grande période est la période de la cage :

$$f_{\text{cage}} = 0.9382 \times 28.83 = 11.48\text{HZ}$$

- la période :

$$T_{\text{cage}} = \frac{1}{f_{\text{cage}}}$$

- la fréquence d'échantillonnage :

$$f_e = 12\text{KHZ} = 12000\text{HZ}$$

- la période d'échantillonnage :

$$\Delta t = \frac{1}{f_e}$$

- le nombre de points par période :

$$N_p = \frac{T_{cage}}{\Delta t} = \frac{f_e}{f_{cage}} = \frac{12000}{11.48} = 1045.29 pts \cong 1046 pts.$$

Si nous prenons un coefficient de 5. La longueur nécessaire pour chaque tranche sera :

$$N_T = N_p \times 5 = 5230 pts.$$

Si on prend pour N_M une valeur de 2^n supérieur à N_T

$$N_M = 2^{13} = 8192 \text{ Échantillons.}$$

Alors le nombre de tranches dans le cas d'un recouvrement de 50%, soit $S_1 = \frac{N_M}{2}$

$$\text{Alors : } K_t = \frac{N_s - S_1}{N_M - S_1} = \frac{120800 - 4096}{4096} \cong 28 \text{ Tranches.}$$

Donc, chaque signal est divisé en 28 tranches.

Pour les quatre signaux, nous avons obtenu 112 tranches ; 28 tranches (signaux) pour chaque type de défaut ou pour chaque classe.

La Figure IV.1 présente le découpage d'un signal en tranches ou sections.

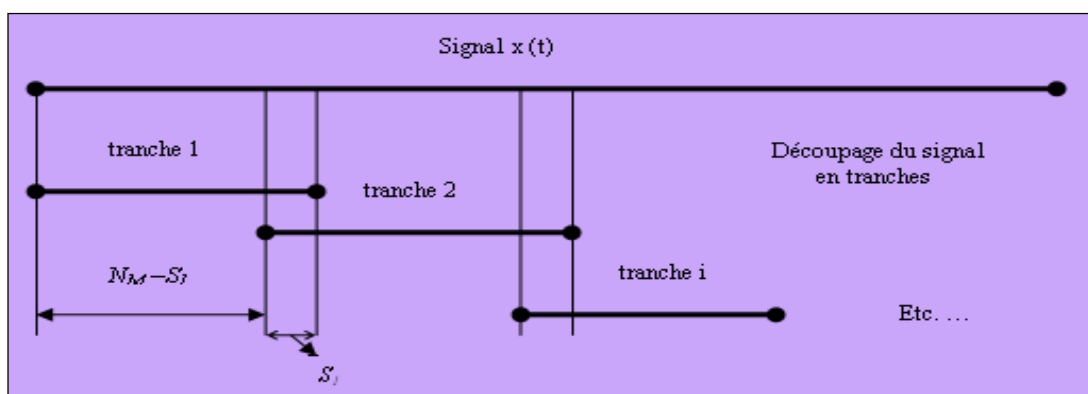


Figure IV. 1 Découpage d'un signal en tranches ou sections

b- Prétraitement et calcul des indicateurs**b.1) Indicateurs temporels**

Les indicateurs temporels cités précédemment sont calculés dans 5 bandes fréquentielles issues de la bande d'analyse '6KHZ', 4 sous bandes adjacentes de largeur 1500HZ, plus la bande totale. Les indicateurs considérés sont les moyennes des indicateurs calculés dans les cinq bandes. Les bandes de calcul sont alors : [0-1500HZ], [1500-3000HZ], [3000-4500HZ], [4500-6000HZ] et [0-6000HZ]. Le signal de chaque tranche a donc été centré puis filtré par des filtres de type passe-bande.

b.2) Indicateurs fréquentiels

Les indicateurs fréquentiels sont calculés dans la bande totale et en 5 bandes fréquentielles de largeur de 1000HZ, issues du spectre d'enveloppe des différentes tranches. Les indicateurs fréquentiels sont : E_{BT} calculé dans la bande [0-6000HZ], E_{B1} dans [0-1000HZ], E_{B2} dans [1000-2000HZ], E_{B3} dans [2000-3000HZ], E_{B4} dans [3000-4000HZ] et E_{B5} dans [4000-5000HZ].

- Remarques

- A la fin de cette phase de préparation des observations, on peut visualiser la division des 4 signaux en 28 tranches. L'exécution d'un sous-programme, sous environnement Matlab (voir [annexe IV.1](#)) conçu pour cet objectif, nous donne la division en tranches des 4 signaux. Les Figures IV.2 et IV.3 présentent respectivement la division du signal (sans défaut), et du signal avec défaut de diamètre de (0.028) inch .
- On remarque sur ces deux Figures précédentes une distinction claire entre les comportements vibratoires des tranches du signal (sans défaut) et les tranches du signal avec défaut (0,028inch). Cette distinction est due au défaut crée sur la bague intérieure du roulement (0,028inch).

Inch (pouce) : unité de mesure de la longueur

1 inch = 2,54 cm




Figure IV.2 Division en tranches du signal sans défaut.




Figure IV.3 Division en tranches du signal avec défaut de diamètre 0,028inch.

pour le calcul des indicateurs temporels et fréquentiels, un programme sous environnement Matlab est conçu pour cet objectif (voir annexe (1)).

Les Figures ; IV.4, IV.5, IV.6, IV.7, IV.8, IV.9, IV.10, IV.11, IV.12, IV.13, et IV.14 représentent graphiquement la variation des 11 indicateurs en fonction des 112 observations(nombre de tranches total).

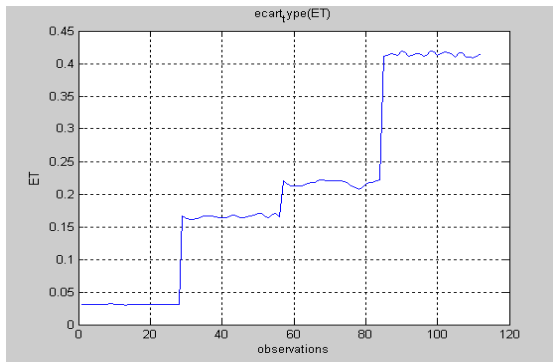


Figure IV.4 Variation de l'indicateur(ET).

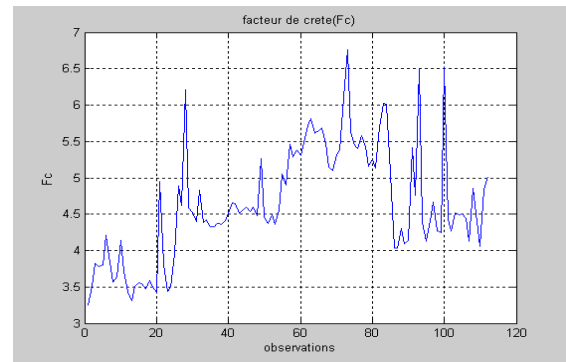


Figure IV.5 Variation de l'indicateur(Fc).

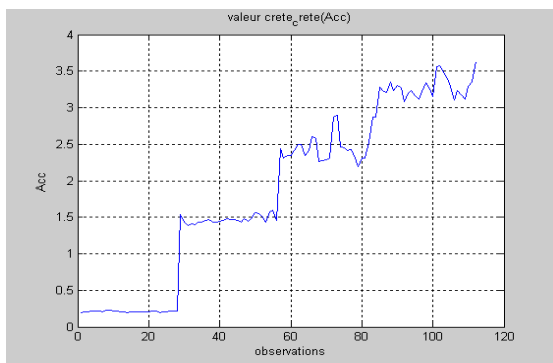


Figure IV.6 Variation de l'indicateur(Acc).

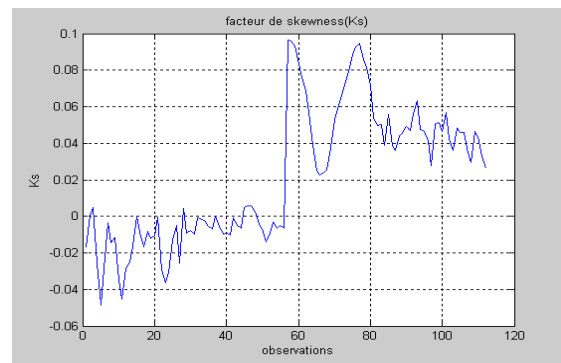


Figure IV.7 Variation de l'indicateur(Ks).

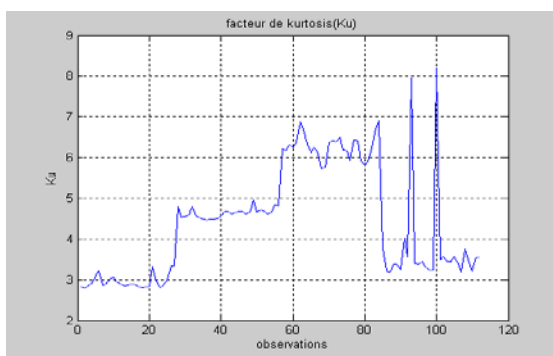


Figure IV.8 Variation de l'indicateur(Ku).

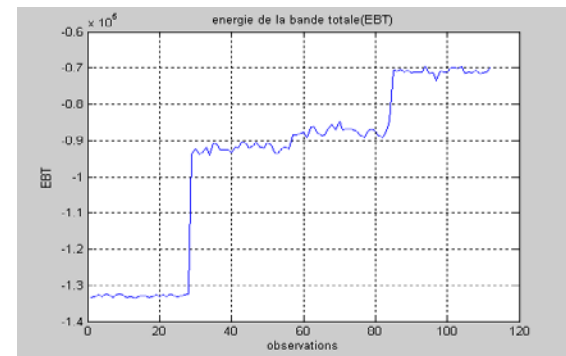


Figure IV.9 Variation de l'indicateur(EBT).




Figure IV.10 Variation de l'indicateur(EB1).

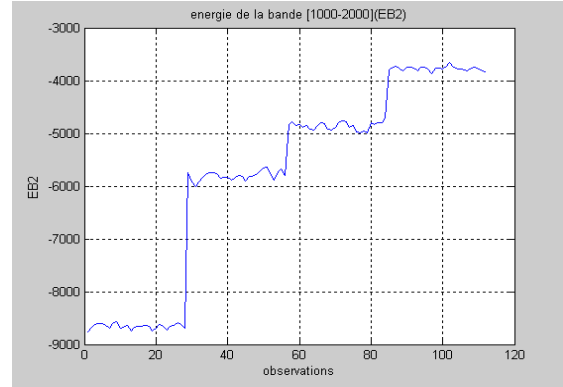


Figure IV.11 Variation de l'indicateur(EB2).




Figure IV.12 Variation de l'indicateur(EB3).

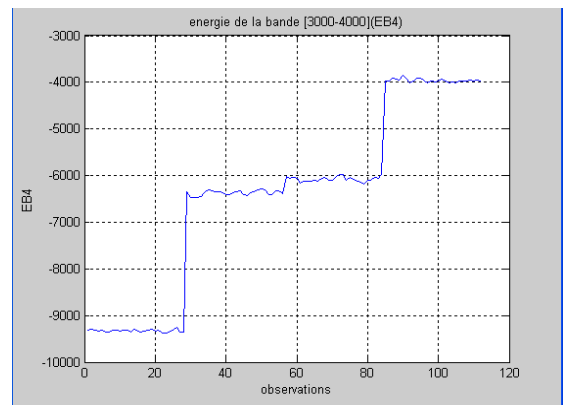


Figure IV.13 Variation de l'indicateur(EB4).



Figure IV.14 Variation de l'indicateur(EB5).

IV. 2.1.2 Constitution du vecteur forme de la base de données (Entrée du RNA) :

La composante du vecteur forme est constituée par les indicateurs calculés précédemment. Les données que l'on doit classer et traiter sont stockées dans un tableau de type observations/variables de la forme suivante :

$$base - donnée = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1M} \\ x_{21} & x_{22} & & x_{2M} \\ \vdots & & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{NM} \end{pmatrix} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_N \end{bmatrix}$$

Avec : N : le nombre d'observations

M : le nombre d'indicateurs

On a alors :

M : indicateurs représentés en colonnes, et N observations représentées en ligne qui seront divisées en N_c classes (w_1, w_2, \dots, w_{N_c}) ou modes de fonctionnement, Chaque classe w_i possède N_i observations.

Pour notre travail :

- N=112 ; observations (28 tranches pour chaque signal parmi les 4 signaux).
- M=11 ; le nombre d'indicateurs calculé dans la section (IV.2.1.1.b), ces indicateurs représente l'entrée du RNA qu'on va créer.
- $N_c = N_4$ (on a 4 classe qui représente les différentes modes de fonctionnement du système (un mode sans défauts et trois modes avec défauts correspondant au trois défauts créés sur la bague intérieure (0.7, 0.21, 0.28inch)). Et au même temps ces quatre classes représentent les quatre sorties du réseau (RNA).

IV.2.2 Choix des classes de sortie (Sortie du RNA) :

Le vecteur de sortie du réseau (RNA) contient les différentes classes correspondant aux différents états de fonctionnement du dispositif expérimental. Nous avons choisi quatre classes, chacune d'elles correspond à un diamètre du défaut.

Le Tableau IV.1 représente l'étiquetage des différentes classes étudiées:

<i>Classes</i>	<i>Diamètre du défaut</i>	<i>Etiquette</i>
<i>1</i>	<i>Sans défaut</i>	<i>1000</i>
<i>2</i>	<i>0.07 inch</i>	<i>0100</i>
<i>3</i>	<i>0.21 inch</i>	<i>0010</i>
<i>4</i>	<i>0.28 inch</i>	<i>0001</i>

Tableau IV.1 *Etiquetage des classes.*

Donc la répartition de la base de données en classes est la suivante :

- De la 1^{ème} ligne à la ligne 28 : classe1 (sans défaut).
- De la 29^{ème} ligne à la ligne 56 : classe2 (avec défaut ($\Phi = 0.007\text{inch}$)).
- De la 57^{ème} ligne à la ligne 84 : classe3 (avec défaut ($\Phi = 0.021\text{inch}$)).
- De la 85^{ème} ligne à la ligne 112 : classe4 (avec défaut ($\Phi = 0.028\text{inch}$)).

IV.2.3 Normalisation des données:

Afin d'améliorer les performances du PMC, il est préférable de normaliser les données du vecteur forme. La normalisation sous MATLAB se fait par la commande **Prestd**.

On divise la base de données obtenue en deux parties: Une base d'apprentissage (BA) qui entraîne le réseau, et une base de test (BT) des échantillons restants sur laquelle on mesure les performances du réseau.

IV.2.4 classification de la base de données à l'aide de l'outil de reconnaissance de forme par les RNA (nprtool) :

On a utilisé un réseau perceptron multicouches avec la configuration suivante :

Nombre d'individus total 112 (85 pour l'apprentissage, ...pour la validation, 27 pour le test).

- 11 neurones dans la couche d'entrée, correspondant aux éléments du vecteur forme.
- Une seule couche cachée.
- 4 neurones dans la couche de sortie correspondant aux différentes classes.
- La fonction de transfert tansig (Tangente sigmoïde) pour la couche cachée, et la fonction purelin (Linéaire) pour la couche de sortie.
- L'apprentissage se fait par l'algorithme de la rétro propagation du gradient conjugué trainscg (trainscg : scaled conjugate gradient back propagation).
- Fonction de performance : mse (Mean square error- Erreur quadratique moyenne).
- Les valeurs des paramètres suivants : nombre des neurones dans la couche cachée et le nombre maximal d'itérations, l'erreur minimale, et le taux d'apprentissage ne sont pas définis, car l'objectif de cette partie du travail est d'étudier leurs effets sur les performances du RNA.

•

Le critère qui nous permet d'évaluer les performances du réseau est le pourcentage de bonne classification (taux de succès) T.

$$T = \frac{N_{bc}}{N} \times 100$$

Avec :

N_{bc} : Nombre d'observations bien classées.

N : Nombre total d'observations.

IV.3-Les étape à suivre dans l'outil de reconnaissance de forme :

- 1- Lancer MATLAB
- 2- Taper sur la commande window l'expression suivant « **nprtool** »
- 3- clique sur **[entrer]**

IV.3.1 Importation des bases de données globales (entrées et sorties) :

Dans cette étape, on va importer les bases de données globales (entrées et sorties du réseau PMC), ces bases représentent les différents modes de fonctionnement (sans défauts et avec défauts). Pour les tailles des deux bases, la base de données (entrées) est une matrice de taille de (112×11) , et la sortie est de (112×4) .

La figure IV.15 montre cette étape d'importation de données.

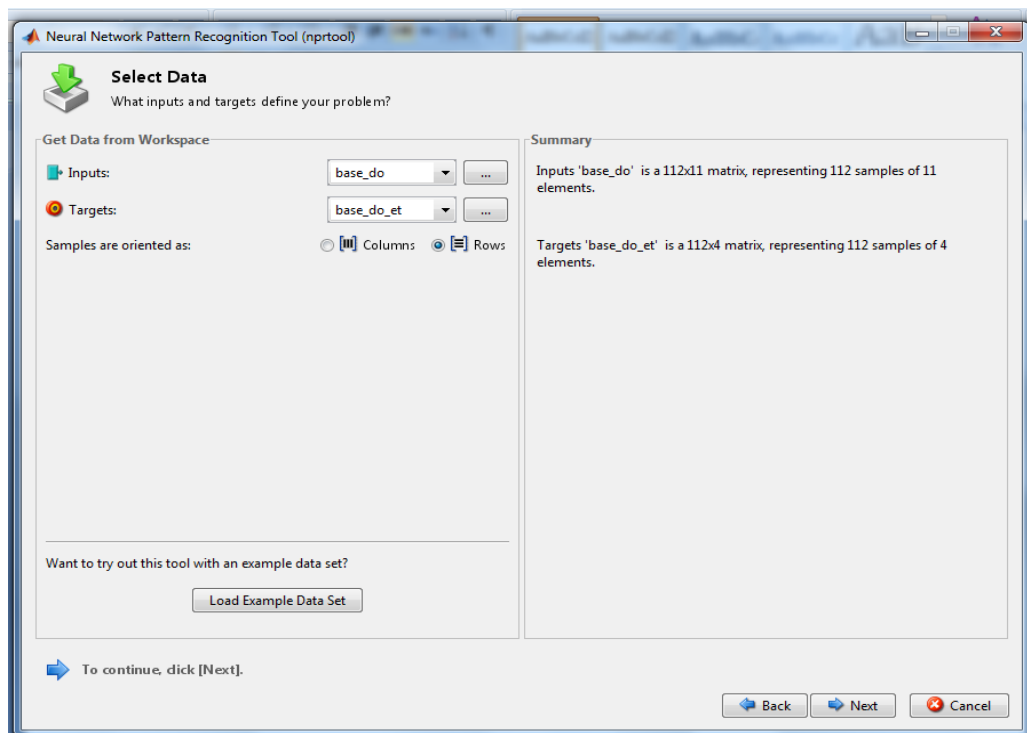


Figure IV.15 Importation des bases de données (entrées et de sorties).

IV.3.2 Répartition des bases de données globales (entrées et sorties) :

Les bases de données (entrées et sorties) sont divisées en trois parties, une partie pour l'apprentissage, une autre pour la validation, et le reste pour le test. Cette étape est effectuée pour nous permettre de faire l'apprentissage, la validation, et le test de notre réseau(PMC) choisi pour la classification.

Les individus de la base d'apprentissage (couleur bleu) sont présentés au réseau lors de l'apprentissage, ensuite le réseau est ajusté (poids) en fonction de son erreur entre les sorties calculées et les sorties désirées.

Les individus de la base de validation (couleur verte) sont utilisés pour mesurer la généralisation du réseau et pour arrêter l'apprentissage lorsque la généralisation cesse de s'améliorer.

Les individus de la base de test (couleur rouge), n'ont aucun effet sur l'apprentissage et fournissent donc une mesure indépendante des performances du réseau pendant et après l'apprentissage.

Remarque :

- On peut changer les pourcentages des individus des différentes bases de données en revenant sur le panneau représenté sur la figure IV.16

La figure IV.16 présente la répartition des bases de données (entrées et sorties)

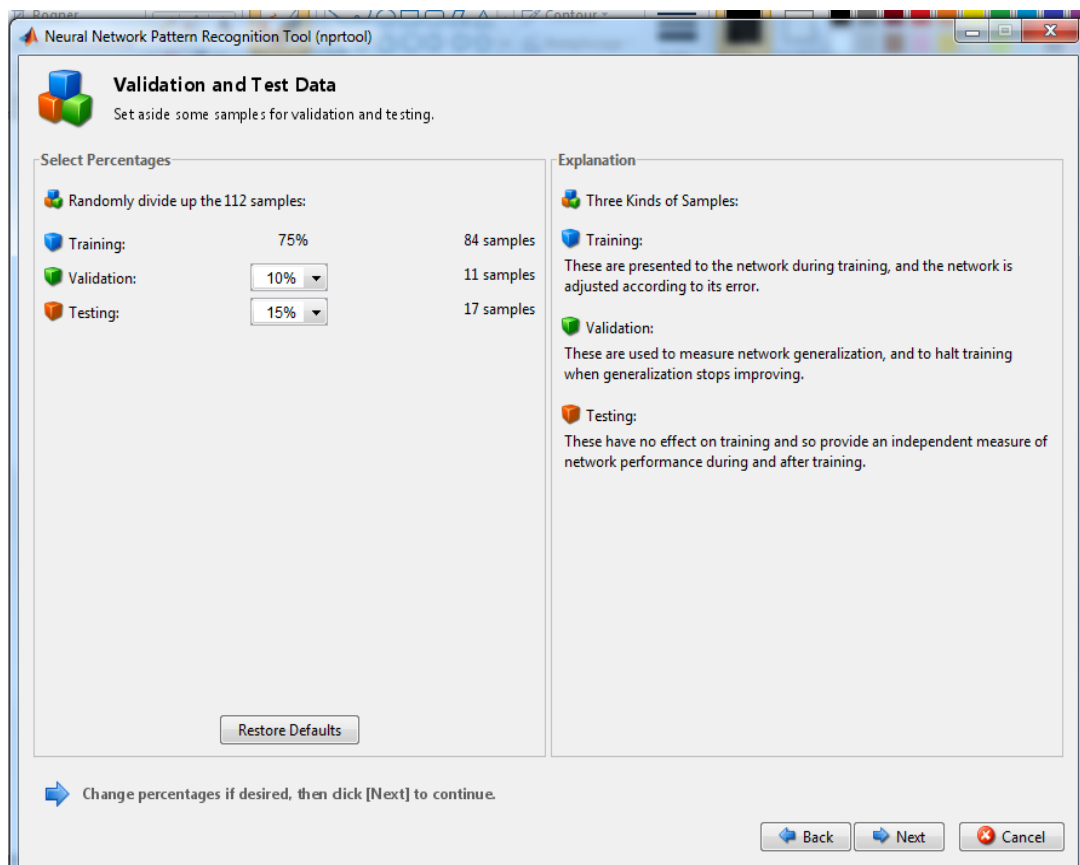


Figure IV.16 Répartition des bases de données (entrées et sorties).

IV.3.3 Apprentissage du réseau de neurones PMC :

Une fois la configuration initiale est faite avec les paramètres cités précédemment (section IV.2.4), on procède dans cette étape à l'apprentissage, c'est une étape très importante pour le réseau, un bon apprentissage nous mènera vers un réseau avec des meilleures performances. L'outil utilisé (nprtool), permet d'effectuer les opérations d'apprentissage, validation, et de test. Pour la procédure à suivre dans l'étape d'apprentissage, on commence par un seul neurone dans la couche cachée, et on lance l'apprentissage. On continue et à chaque fois on augmente le nombre de neurones et on relance à nouveau l'apprentissage jusqu'à l'obtention d'une erreur minimale de classification acceptable et un taux de bonne classification élevé. Pour la validation et le test, cet outil (nprtool) de classification permet de les faire simultanément avec l'opération d'apprentissage, les individus de la base de validation sont utilisés pour mesurer la généralisation du réseau et pour arrêter l'apprentissage lorsque la généralisation cesse de s'améliorer. Pour Les individus de la base de test n'ont aucun effet sur l'apprentissage et fournissent donc une mesure indépendante des performances du réseau pendant et après l'apprentissage.

La figure IV.17 présente le réseau PMC avec la configuration initiale, ainsi que comment introduire le nombre de neurones dans la couche cachée sur l'interface (sur la figure on a introduit un seul(1) neurone dans la couche cachée).

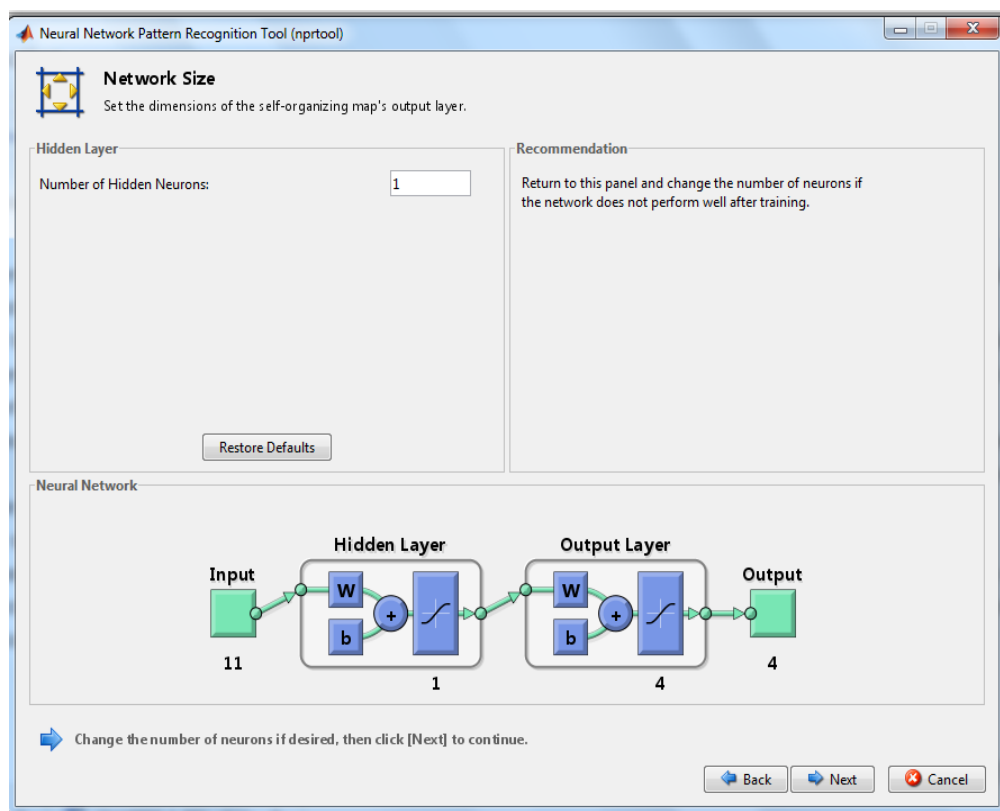


Figure IV.17 Configuration initiale du réseau choisi.

La figure IV.18 montre le panneau dans le quel, on lance l'opération d'apprentissage.

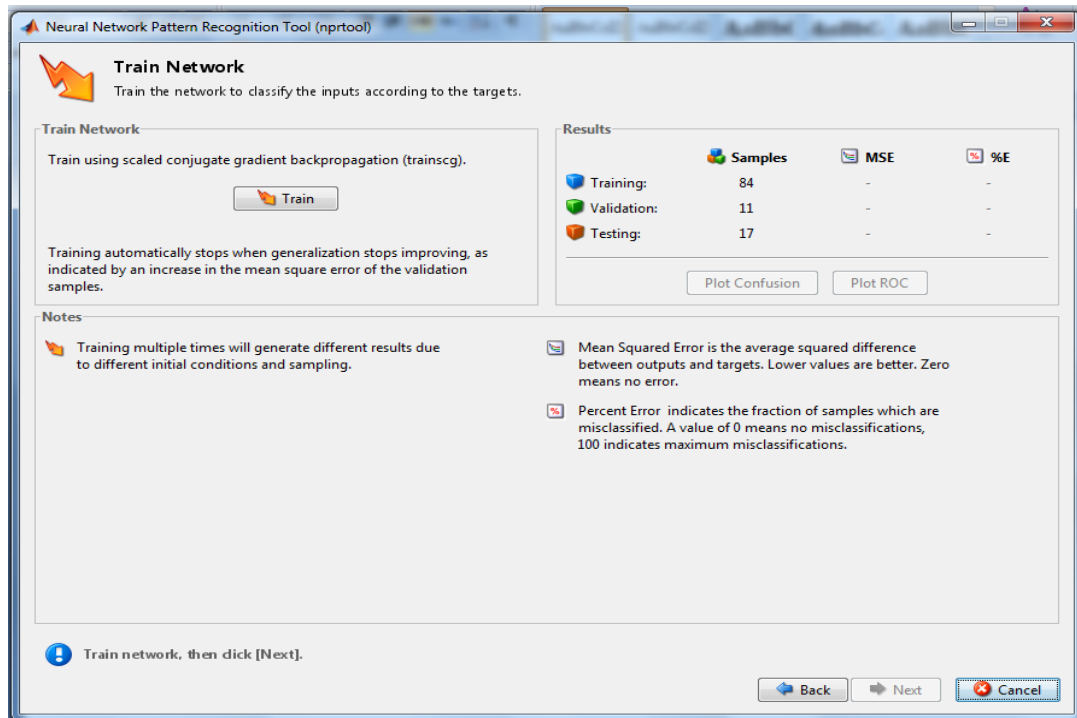


Figure IV.18 panneau de lancement de l'opération d'apprentissage.

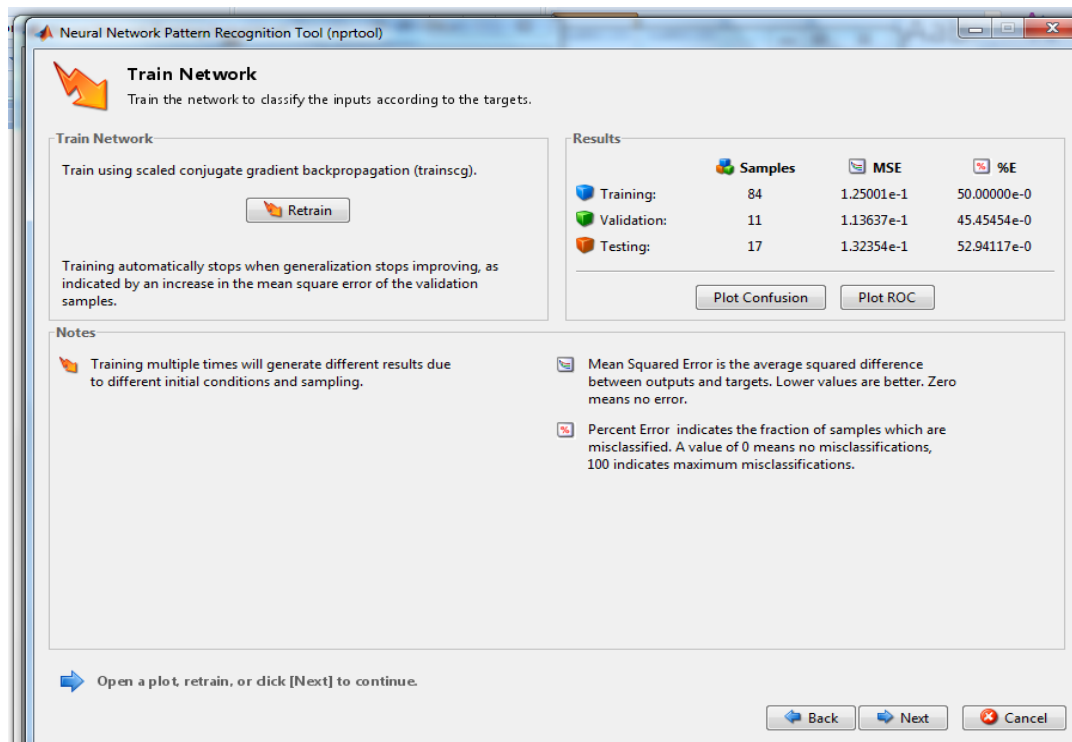


Figure IV.19 Résultats d'apprentissage, validation, et de test pour un seul neurone.

Les figures IV.19 et IV20 présentent les résultats des opérations d'apprentissage, validation, et de test pour un seul nombre de neurones dans la couche cachée.

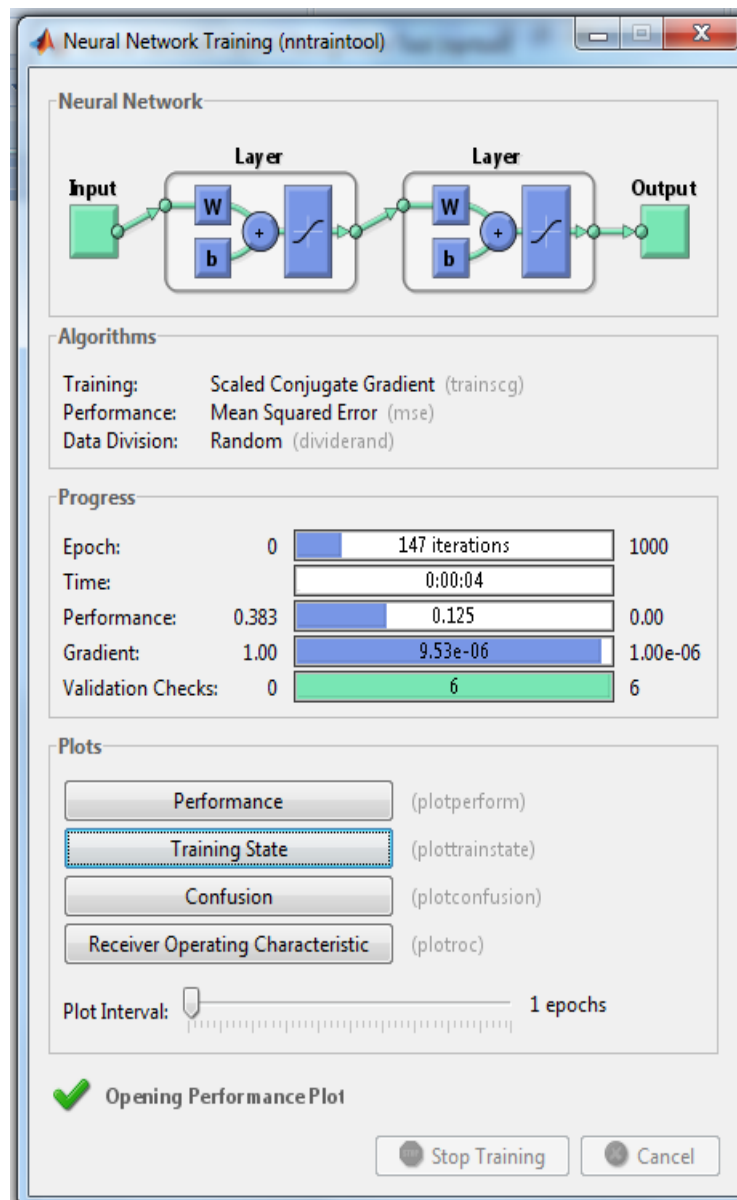


Figure IV. 20 Résultats d'apprentissage pour un seul neurone dans la couche cachée.

L'erreur minimale (mse) de l'apprentissage, validation, et de test est présentée sur la figure IV. 21, cette erreur minimale et pour le cas d'un seul neurone dans la couche cachée.




Figure IV. 21 Erreur minimale (mse) pour un seul neurone.

La figure IV. 22, présente la variation du gradient en fonction du nombre d'itérations lors de l'opération d'apprentissage.




Figure IV. 22 variations du gradient en fonction du nombre d'itération pour un seul neurone.

Discussion :

Pour les résultats d'apprentissage du réseau de neurones avec la configuration initiale, et avec un nombre de neurones dans la couche cachée égale à 1, on voit sur les figures IV.20 que le taux de mauvaise classification est de 50% (Donc le taux de bonne classification est de 50%), cette valeur est insuffisante. Pour améliorer le taux de bonne classification, on augmente le nombre de neurones dans la couche cachée, jusqu'à l'obtention d'une valeur de bonne classification acceptée. Le tableau IV.2 présente les valeurs des différents paramètres pour les trois opérations (apprentissage, validation, test), et à partir de ce tableau on fait notre choix de la configuration finale du réseau PMC, cette configuration elle doit nous donner les meilleures performances (meilleur taux de bonne classification).

Tableau IV. 2 Valeurs de paramètres d'apprentissage, validation, et test en fonction du nombre de neurones dans la couche cachée

Nombre de Neurones	Type de base de données	Nombre d'individus	Nombre d'itérations	Erreur Minimale (mse)	Taux de mauvaise classification	Gradient
1	Apprentissage(A)	84	147	1.25001×10^{-1}	50,00	9.53×10^{-6}
	Validation (V)	11	/	1.13637×10^{-1}	45.45454	/
	Test (T)	17	/	1.32354×10^{-1}	52.94117	/
2	A	84	155	7.14093×10^{-2}	28.57142	0,00225
	V	11	/	4.44235×10^{-6}	0	/
	T	17	/	5.88240×10^{-2}	23.52941	/
3	A	84	67	5.03542×10^{-7}	0	9.62×10^{-7}
	V	11	/	4.14591×10^{-7}	0	/
	T	17	/	5.40807×10^{-5}	0	/
4	A	84	18	1.64145×10^{-1}	50.00	0,00671
	V	11	/	1.46699×10^{-1}	45.45454	/
	T	17	/	1.61583×10^{-1}	52.94117	/

5	A	84	40	2.67467×10^{-1}	53.57142	0.0328
	V	11	/	9.09133×10^{-2}	18.18181	/
	T	17	/	2.64384×10^{-1}	52.94117	/
6	A	84	52	2.33123×10^{-7}	0	4.49×10^{-7}
	V	11	/	1.98902×10^{-7}	0	/
	T	17	/	1.98975×10^{-7}	0	/
7	A	84	42	2.69643×10^{-7}	0	6.44×10^{-7}
	V	11	/	2.98515×10^{-7}	0	/
	T	17	/	1.87945×10^{-7}	0	/
8	A	84	49	1.82707×10^{-7}	0	4.89×10^{-7}
	V	11	/	1.57109×10^{-7}	0	/
	T	17	/	4.34055×10^{-7}	0	/
9	A	84	50	3.03597×10^{-7}	0	7.71×10^{-7}
	V	11	/	2.95188×10^{-7}	0	/
	T	17	/	2.59810×10^{-7}	0	/
10	A	84	37	2.01246×10^{-7}	0	5.92×10^{-7}
	V	11	/	2.10011×10^{-7}	0	/
	T	17	/	1.70748×10^{-7}	0	/

IV.3.4 Choix de la configuration finale du réseau de neurones(PMC) :

A partir des résultats présentés dans le tableau IV. 2 lors des opérations (apprentissage, validation, test) effectués sur le réseau PMC avec une configuration initiale, et différents valeurs du nombre de neurones dans la couche cachée, on remarque bien que le taux de bonne classification atteint un pourcentage de 100% pour les trois opérations à partir d'un nombre de neurones égal à 6, cela veut dire que notre réseau devient très performant à partir de ce nombre de neurones. Donc, pour le choix de la configuration finale du réseau, on a choisi un réseau avec un nombre de neurones égal à 8, et avec les paramètres suivant :

- 11 neurones dans la couche d'entrée, correspondant aux éléments du vecteur forme (11 indicateurs).
- Une seule couche cachée.

- 4 neurones dans la couche de sortie correspondant aux quatre classes (mode de fonctionnement normaux et anormaux).
- La fonction de transfert **tansig (Tangente sigmoïde)** pour la couche cachée et la couche de sortie.
- L'apprentissage se fait par l'algorithme de la rétropropagation du gradient conjugué **trainscg (trainscg : scaled conjugate gradient backpropagation)**.
- Fonction de performance : mse (Mean square error- Erreur quadratique moyenne).
- nombre des neurones dans la couche cachée égal à 8, le nombre maximal d'itérations égal à 49, l'erreur minimale (mse) est de 1.82707×10^{-7} , et le gradient avec une valeur de 4.89×10^{-7} .

Les figures IV. 23, 24, 25, 26, 27 présentent les différents résultats obtenus par la configuration finale du réseau PMC.

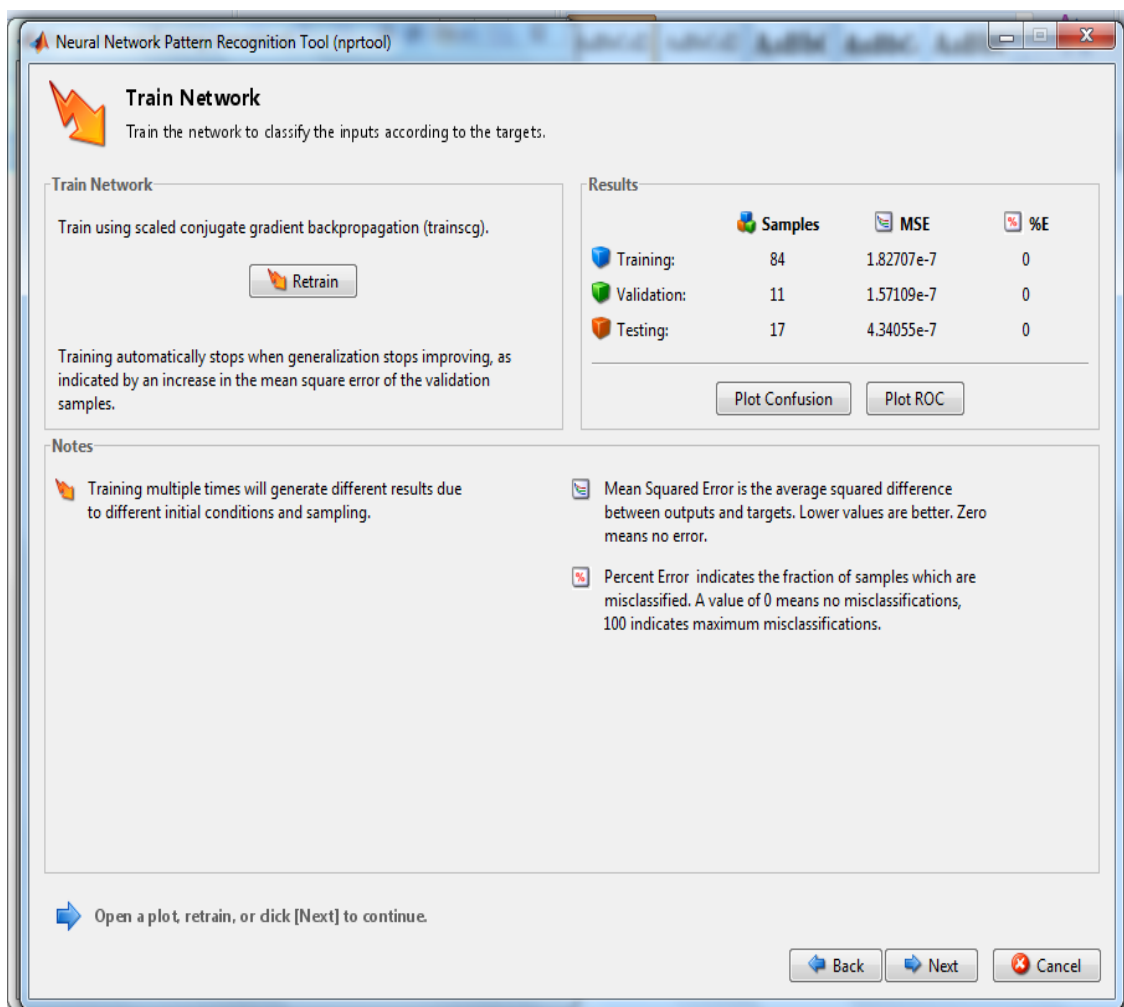


Figure IV.23 Résultats d'apprentissage, validation, et de test pour un nombre de huit(8) neurones.

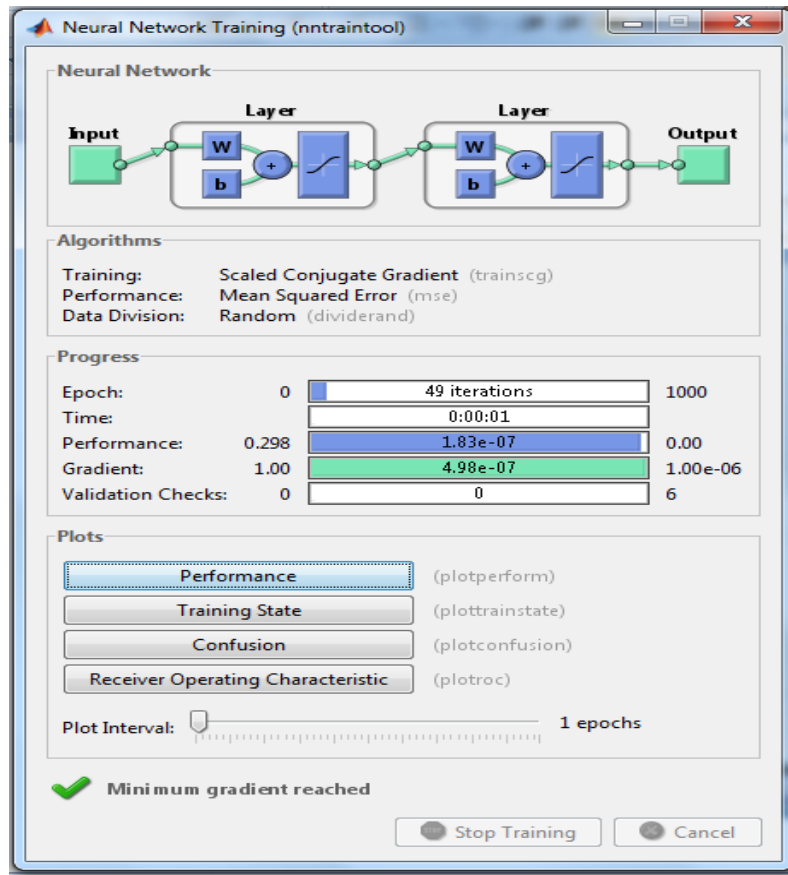


Figure IV. 24 Résultats d'apprentissage pour un nombre de neurones égal à huit(8).

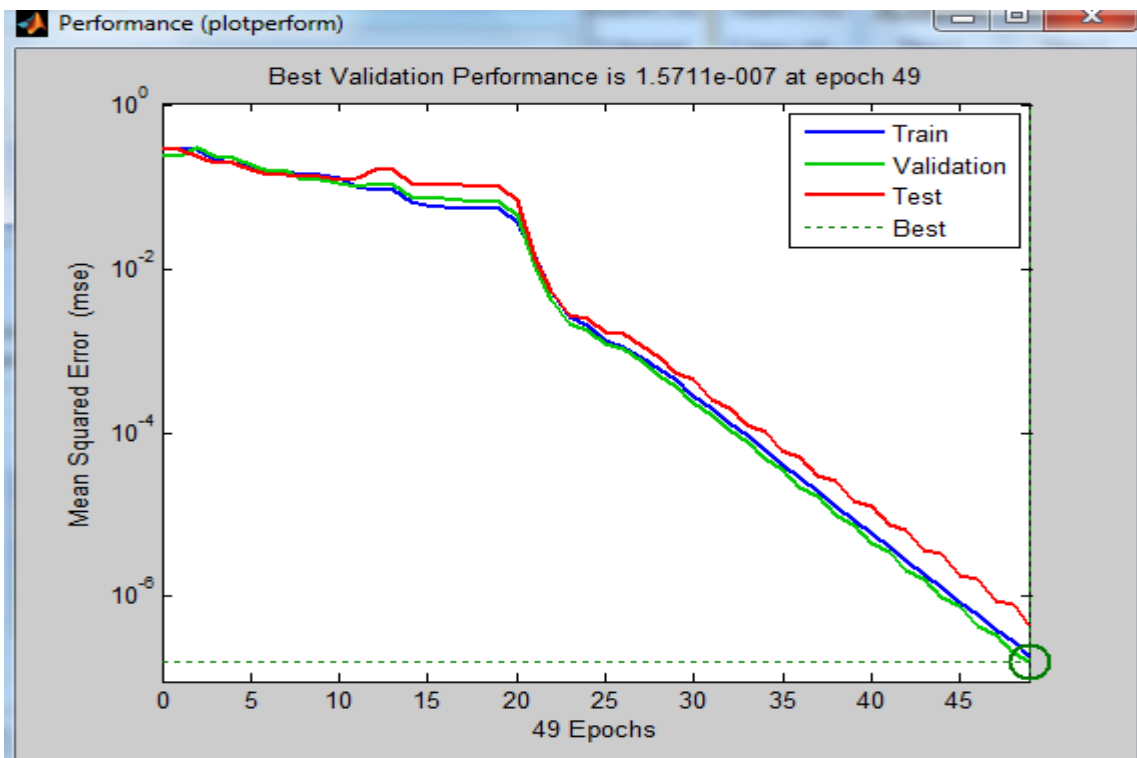


Figure IV. 25 Erreur minimale (mse) pour un nombre de neurones égal à huit(8).




Figure IV. 26 variation du gradient en fonction du nombre d'itération pour un huit(8) neurones.

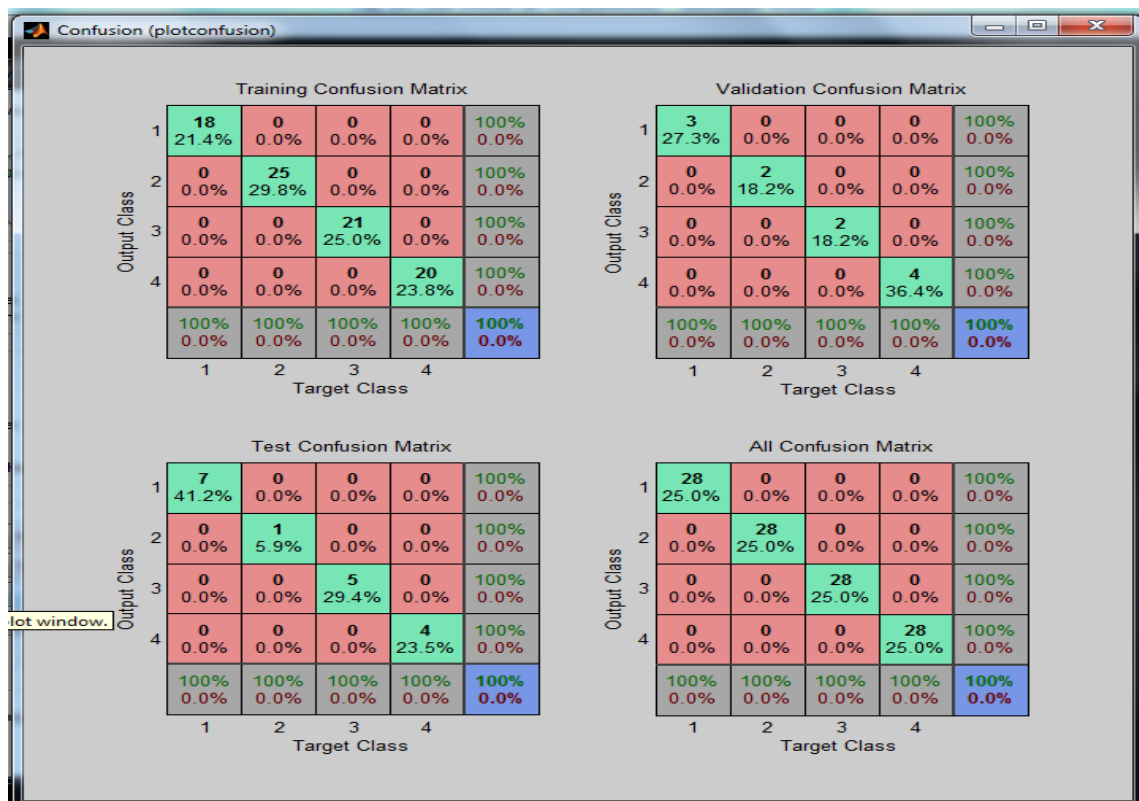


Figure IV. 27 Matrice de confusion des résultats de classification pour les bases d'apprentissage, validation, test, et la base globale.

IV.4 Conclusion

Pour ce dernier chapitre nous avons présenté les différents résultats obtenus lors de l'utilisation du perceptron multicouches (PMC) pour le diagnostic des défauts des roulements. Nous avons également étudié l'impact du choix du nombre de neurones dans la couche cachée du réseau PMC sur les performances de classification.

Tout d'abord, nous avons prétraité les signaux vibratoires de banc d'essais (Bearing Data Center) pour extraire les indicateurs de suivi les plus pertinents sur l'état de santé du système étudié. Ensuite, nous avons créé une base de données pour l'apprentissage, la validation et le test du réseau PMC. De plus, nous avons déterminé la configuration optimale du PMC pour le diagnostic des défauts de roulements.

Au cours de nos essais, nous avons constaté que l'augmentation du nombre de neurones dans la couche cachée, et par conséquent l'augmentation de la taille de la couche cachée, augmentait considérablement le taux de bonne classification et diminuait l'erreur minimale (mse) d'apprentissage. En ce qui concerne les critères de terminaison ; la valeur d'erreur minimale (mse) ne doit pas être très petite et le nombre maximal d'itérations ne doit pas être très grand. Si ces deux valeurs sont mal choisies vous courez le risque de saturer le réseau et de ne jamais arrêter le processus d'apprentissage.

Conclusion générale

Conclusion générale

Le travail effectué dans le cadre de ce mémoire s'inscrit dans le domaine de la surveillance et le diagnostic automatisés des systèmes mécaniques par analyse vibratoire.

Après avoir présenté un aperçu théorique, dans lequel nous avons montré les défauts courants dans les machines tournantes et les différentes méthodes de diagnostic par analyse vibratoire. Deux approches sont citées, en précisant leurs avantages et leurs inconvénients :

L'approche classique basé sur le jugement (décision) de l'homme sur l'état de santé des machines par l'analyse des signaux vibratoire, en utilisant les différentes méthodes du traitement de signal.

La deuxième approche dite moderne; est basée sur l'automatisation de la décision, en utilisant les différents algorithmes et règles de décision et surtout celles de l'intelligence artificielle.

Nous avons tout d'abord étudié l'état d'art de l'application des réseaux de neurones artificiels (RNAs) au diagnostic des défauts des machines tournantes. On a présenté la synthèse de quelques travaux réalisés sur ce sujet, dont le but était de savoir la méthodologie de l'utilisation des réseaux de neurones pour automatiser le diagnostic vibratoire.

Le réseau de neurone le plus utilisé en surveillance est le perceptron multicouche (PMC). Dans la suite du travail, nous avons également abordé, de manière approfondie la théorie des réseaux de neurones et particulièrement le réseau PMC. Aussi, on a présenté les étapes nécessaires pour implémenter le PMC sous Matlab et la démarche adoptée pour l'utiliser comme un outil de diagnostic. Nous avons expliqué en détail, le choix des différents paramètres pertinent à la structure et au fonctionnement du PMC.

Ensuite, nous avons présenté le banc d'essai étudié : banc d'essai de roulement (Data Bearing Center), et les signaux vibratoires correspondants.

Nous nous sommes intéressés à l'effet du paramètre : nombres de neurones dans la couche cachée. Ce paramètre a une influence directe sur le processus d'apprentissage du réseau. L'étude de l'effet de ce paramètre sur la performance en classification du réseau PMC, nous a conduit à trouver la configuration optimale appropriée pour le banc d'essai étudié. Aussi, On a montré que pour réussir un tel diagnostic vibratoire basé sur la méthode des réseaux de neurones artificiels, il faut :

- Bien choisir et traiter les descripteurs (indicateurs de surveillance) formant la base de données utilisée pour entraîner, valider et tester le PMC.
- Bien choisir les valeurs des paramètres et les fonctions du réseau PMC.

Par ailleurs, un des problèmes encore ouverts est celui de l'évaluation des performances de généralisation des réseaux de neurones utilisés en diagnostic des systèmes mécanique; qui nécessite toujours une grande base de données. Ce qui n'est pas disponible pratiquement. En effet, pour avoir suffisamment de données, il faut augmenter le nombre des essais (expériences). Et cela, nécessite la détérioration d'un grand nombre d'éléments (roulements, engrenage, pompes, etc.). Par conséquence, la facture des essais devient trop élevée, ce qui n'est pas au porté de tous les intéressés par ce domaine. La modélisation des dispositifs et des systèmes mécaniques, malgré sa difficulté, peut résoudre ce problème et fournir les données nécessaires pour réussir un diagnostic basé sur les réseaux de neurones artificiels.

Enfin, nous avons présenté et interprété les différents résultats expérimentaux en jouant sur la diversité des paramètres du réseau et la structure de la base de données, et en utilisant l'outil nprtool(neural network pattern recognition tool).

Références Bibliographiques

Références Bibliographiques

- [1] Derek Norfield, «Practical Balancing of Rotating Machinery». Elsevier2006. pp.217.
- [2] Nabti Mohamed Tahar « Etude de l'évolution des indicateurs spectraux et cepstraux dans la détection des défauts mécaniques » thème de magister université FARHAT Abas Setif, 2011.
- [3] TOUAFEK Ishak « Extraction d'indicateurs robustes pour le diagnostic des défauts mécaniques : comparaison de l'EMD et des ondelettes (WT), thèse de magister, université de FARHAT Abasse Setif.
- [4], Sidahmed M., « Détection précoce des défauts dans les engrenages par analyse vibratoire», 4ème journée d'étude des transmissions mécaniques, juin ,1990.
- [5], Lebold M., McClintic K.; Campbell R., Byington C., Maynard K., «Review of Vibration Analysis Methods for Gearbox Diagnostics and Prognostics», 54th Meeting of the Society for Machinery Failure Prevention Technology, Virginia, May 1- 4, 2000, pp. 623-634.
- [6] Marc Thomas, « Les vibrations des paliers fluides et d'engrenages», cours de Techniques de maintenance industrielle, ETS, École de technologie supérieure, Québec, Canada, Novembre 2002.
- [7] C. Breneur, Eléments de maintenance préventive de machines tournantes dans le cas de défauts combinés d'engrenages et de roulements, Thèse INSA de Lyon, 2002.
- [8] Rouget D., « De l'analyse d'avarie à la conception des montages de roulements». Revue Française de Mécanique, 1994, pp.181-186
- [9] D. Carreau, « Surveillance des roulements par analyse des vibrations ». CETIM-informations no1S, avril 1990.
- [10] H. Fenineche. Application des réseaux de neurones artificiels au diagnostic des défauts des machines tournantes, Thèse magister, UFAS 2008
- [11] Philippe Arquès, diagnostic prédictif et défaillance des machines (théorie-traitement-analyse reconnaissance-prédiction). Technipe Paris, livre édition 2009
- [12] J. Antoni, "Cyclic spectral analysis in practice," Mech. Syst. Signal Process., vol. 21, no. 2, pp. 597–630, 2007.
- [13] CHIEMENTIN Xavier thèse de doctorat en mécanique « Localisation et quantification des sources vibratoires dans le cadre d'une maintenance préventive conditionnelle en vue de fiabiliser le diagnostic et le suivi de l'endommagement des composants mécaniques tournants : application aux roulements à billes»octobre 2007

- [14] « Contribution au diagnostic de machines électromécaniques exploitation des signaux électriques et de la vitesse instantanée ». Thèse de Doctorat 10 Mars 2009.
- [15] A, Bekka.R.E.H, Antoni.J, Ménad. S « Etude des performances de la sélection d'indicateurs par couplage algorithmes génétiques – analyse discriminante linéaire » Soumis au journal européen des systèmes automatisés, janvier 2007.
- [16] E. Seier et D. Bonett, Two families of kurtosis measures, *Metrika*, (2003) 58, 59-70.
- [17] Amar Chiter « Détection et diagnostic des défauts de roulement : contribution à la maintenance des machines tournantes ». Thèse de Magistère en optique et mécanique de précision UFAS 2001
- [18] H. Martin et F. Honarvar. « Application of statistical moments to bearing failure detection » *AppliedAcoustics*, Vol. 44, pp. 67_77, 1995.
- [19] S. Brown « Measures of Shape » Oak road systems 2008-2016
- [20] A. Boulenger et C. Pachaud, *Diagnostic vibratoire en maintenance préventive*, Dunod, 1998.
- [21] « réseau de neurones artificiels » Le Grand Dictionnaire terminologique, Office québécois de la langue française (janvier 2020).
- [22] « réseau de neurones artificiels » Le Grand Dictionnaire terminologique, Office québécois de la langue française (janvier 2020).
- [23] Murphy,P.M.,Aha,D.W.(1994).« conférence sur les réseau neurones artificiel »
- [24] Simon HAYKIN, « *Neural Networks - A Comprehensive Foundation* ». Second Edition, Pearson Prentice Hall, India 2001, pp.823.
- [25] Gilles ZWINGELSTEIN, «*Diagnostic des défaillances théorie et pratique pou les systèmes industriels*», HERMES, paris, 1995
- [26] Hernandez N.G., *Système de diagnostic par Réseaux de Neurones et Statistiques : Application à la détection d'hypovigilance d'un conducteur automobile*, thèse de doctorat, LAAS 1999
- [27] Zemouri, R., « *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance*», Thèse de Doctorat, Université de Franche Comté, Besançon.2003, pp.277.
- [28] A.C. McCormick, A. K. Nandi, « *Rotating Machine Condition Classification Using Artificial Neural Networks*», *Proceedings of COMADEM '96*, University of Sheffield, 16th-18th July 1996.

- [29] b.a.PAYA, i.i ESAT et m.n. BADI, «Artificial neural network based fault diagnostics of rotating machinery using wavelet transform as a preprocessor», *Mechanical Systems and Signal Processing* 1997, 11(5), Academic Press , pp. 751-765.
- [30] Vojislav Kecman, «Learning and soft computing : support vector machines, neural networks, and fuzzy logic models», The MIT Press, Cambridge, The MIT Press Cambridge, London, 2001, pp.568.
- [31] Sergios Theodoridis, konstantinos koutroumbas, «Pattern recognition», second edition, Copyright 2003, Elsevier (USA), pp.710.
- [32] J. P. Marques de Sa, «Pattern Recognition Concepts, Methods and Applications», Springer 2001, pp.328.
- [33] Madan M.Gupta, Liang Jin, and Noriyasu Homma, « Static and Dynamic Neural Networks from Fundamentals to Advanced Theory», John Wiley & sons, inc. publication 2003, pp.751.
- [35] FEDALA Semchedine, «Le diagnostic vibratoire automatisé : comparaison des méthodes d'extraction et de sélection du vecteur forme», Mémoire de magister DOMP-UFAS, Sétif, 2005, pp.142.
- [36] L. B. Jack, A. K. Nandi, « Feature selection for ANNs using genetic algorithms in detection of bearing faults», *IEE proceeding vision, image and signal processing*, 147(3), 2000, pp.205-212.
- [37] Da-Ming Yang et James Penman, «Intelligent detection of induction motor bearing faults using current and vibration monitoring ». *Proceeding of COMADEM 2000*, 38 December 2000 Houston Texas USA, pp.461-470

ملخص:

الهدف من هذا العمل هو تطبيق الشبكات العصبية الاصطناعية لأتمتة تشخيص الآلات الدوارة من خلال تحليل إشارات الاهتزاز. تعتمد هذه التقنية على تصنيف التعرف على الأنماط وتهدف إلى زيادة الدقة وتقليل الأخطاء بسبب الحكم البشري الشخصي.

تعتمد فعالية البرنامج على الخطوات الأربع التالية، وهي: اكتساب إشارات الاهتزاز ، والمعالجة المسبقة للبيانات ، واستخراج الخصائص ، وأخيراً التعرف على هذه الخصائص بواسطة الشبكات العصبية

الكلمات الدالة:

الآلات الدوارة ، الاهتزازات الميكانيكية ، الشبكات العصبية الاصطناعية ، تشخيص الأعطال ، معالجة الإشارات

Résumé :

Le but de ce travail est d'appliquer les réseaux de neurones artificiels pour automatiser le diagnostic des machines tournantes en analysant les signaux vibratoires. Cette technique est basée sur la classification par reconnaissance de formes et vise à augmenter la précision et à réduire les erreurs dues au jugement humain subjectif.

L'efficacité du programme repose sur les quatre étapes suivantes, à savoir : l'acquisition des signaux vibratoires, le prétraitement des données, l'extraction des caractéristiques, et enfin la reconnaissance de ces caractéristiques par les réseaux de neurones.

Mots clés :

Machines tournantes, Vibrations mécaniques, Réseaux de neurones artificiels, Diagnostic des défauts, Traitement de signal.

Abstract :

The aim of this work is to apply artificial neural networks to automate the diagnosis of rotating machines by analyzing vibration signals. This technique is based on pattern recognition classification and aims to increase accuracy and reduce errors due to subjective human judgment.

The effectiveness of the program is based on the following four steps, namely: the acquisition of vibration signals, the pre-processing of data, the extraction of characteristics, and finally the recognition of these characteristics by neural networks.

Keywords :

Rotating machines, Mechanical vibrations, Artificial Neural Networks, Fault Diagnosis, signal processing.