

N° d'ordre : 06/2013-D/GM

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET
DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE DES SCIENCES ET DE LA TECHNOLOGIE
«HOUARI BOUMEDIEN»
FACULTE DE GENIE MECANIQUE ET DE GENIE DES PROCEDES



Thèse

présentée pour l'obtention du grade de Docteur
en Génie Mécanique

Spécialité : Maintenance et Isolation Vibro-Acoustique

par

BOUZOUANE BELAID

Thème

DIAGNOSTIC DES DEFAUTS DE MACHINES TOURNANTES :

"RECONNAISSANCE DES FORMES PAR RESEAUX DE NEURONES"

Soutenue publiquement le 15 septembre 2013, devant le jury composé de :

Mme. K. BOUHADEF	Prof	à l'USTHB/FGMGP	Présidente
M. HAMZAOUI Nacer	Prof	à l'INSA de Lyon, France	Directeur de thèse
M. A. MILOUDI	Prof	à l'USTHB/FGMGP	Examineur
M. OUELAA Nouredine	Prof	à l'Université de Guelma	Examineur
M. LAULAGNET Bernard	MC, HDR	à l'INSA de Lyon, France	Examineur
M. K. BRAHIMI	MCA	à l'USTHB/FGMGP	Examineur

Remerciements

Je tiens tout d'abord à exprimer ma profonde gratitude, et mes remerciements à mon directeur de thèse, Monsieur le Professeur Nacer Hamzaoui, pour son investissement, pour son expertise qu'il a mis à contribution tout au long de mon travail, pour son esprit critique qu'il a toujours exercé de manière constructive ainsi que pour ses conseils donnés avec les meilleures intentions et effets, sans oublier sa patience et son amitié.

Je tiens à remercier, Madame le Professeur K. Bouhadeb pour avoir accepté de présider le jury de thèse - après avoir présidé le jury de Magister - .Qu'elle trouve l'expression de ma gratitude et de mon profond respect.

Mes plus sincères remerciements vont à Monsieur, le Professeur Jean Louis Guyader, directeur du Laboratoire de Vibrations et Acoustique de l'INSA de Lyon pour avoir accepté ma présence au sein du LVA pour la réalisation de mes travaux expérimentaux dans le cadre de cette thèse.

Mes plus vifs remerciements et toute ma reconnaissance vont aussi à Monsieur le Professeur Abdel Hamid Miloudi pour la tâche de rapporteur sur ce travail qu'il a bien voulu assumer dont les remarques et encouragements m'ont été très précieuses.

Mes plus vifs remerciements et toute ma reconnaissance vont aussi à Monsieur Khaled Brahimi, Maître de Conférences, pour la tâche de rapporteur sur ce travail qu'il a bien voulu assumer.

Je remercie vivement Monsieur, le Professeur Nouredine Ouelaa pour l'honneur qu'il m'a fait d'accepter la lourde tâche de rapporter mon travail et l'intérêt qu'il y a porté.

Je remercie vivement Monsieur, le Professeur Bernard Laulagnet pour l'honneur qu'il m'a fait d'accepter la lourde tâche de rapporter mon travail et l'intérêt qu'il y a porté.

Je tiens aussi à exprimer ma gratitude à l'ensemble des enseignants du LVA, Goran Pavic, Nathalie, et toutes les autres personnes que je n'ai pas citées, l'expérience de mon séjour a été assez riche et agréable.

Je suis particulièrement reconnaissant à Madame Derouiche Abbassia et Messieurs les professeurs Taoufik Boukharouba, Ouali Nourdine, Ali Benyahia et Krimo Azouaoui ainsi que tous les collègues du laboratoire de Mécanique Avancée pour leurs encouragements.

*Des berceuses que chantent les mères
Aux nouvelles que lit le speaker
Vaincre le mensonge partout dans le monde
Dans le cœur, dans le livre, dans la rue
Quel bonheur fantastique que de comprendre
Comprendre ce qui s'en va et ce qui vient*

Nazim Hikmet
"Anthologie Poétique"

Résumé

Différentes méthodes sont mises en œuvre pour identifier la nature d'un défaut sur une machine tournante, en utilisant des mesures vibratoires ; elles diffèrent entre elles par leur précision, leur simplicité de mise en œuvre et leur sensibilité aux erreurs de mesure. L'identification d'une combinaison de plusieurs défauts est toujours difficile à mettre en œuvre par les méthodes classiques du traitement du signal, sachant que le signal vibratoire qui en découle est bruité, rendant ainsi toute identification fastidieuse.

Une méthode basée sur les réseaux de neurones est proposée pour identifier un défaut ou plusieurs combinaisons de défauts mécaniques. Nous proposons dans ce présent travail de comparer deux méthodes neuronales, la rétro propagation de l'erreur (RBP : Back Propagation) et les fonctions à base radiales (RBF : Radial Basis Function). Nous mettons en évidence leur capacité de remonter au défaut ainsi que leur sensibilité par rapport à un bruit de fond caractérisant d'autres sources indépendantes aux défauts. Cette évaluation se fera dans un premier à partir de simulations numériques de défauts, et par la suite une confrontation avec la mesure sera effectuée sur un banc d'essai constitué d'une transmission par engrenages à deux étages, et de paliers à roulements, avec et sans lubrification. Des défauts provoqués seront analysés dans cette étude.

Summary

A method based on neural networks is proposed to identify a defect or combination of several mechanical defects. We propose in the present work to compare two neural methods, the error back propagation (RBP: Back Propagation) and radial basis functions (RBF: Radial Basis Function). We demonstrate their ability to go back to default and their sensitivity to noise from other independent sources characterizing the defects. This evaluation will initially from numerical simulations of defects, and a subsequent confrontation with the measurement is performed on a test bench consists of a gear with two floors and roller bearings, with and without lubrication. Defects caused will be analyzed in this study.

□ □ □ □

مختلف أساليب تنفيذها (يعمل) إلى تحديد طبيعة الخلل في الجهاز الدوري من خلال استخدام التدابير الاهتزازي؛ الاختلاف بينهما من الدقة، على بساطة التنفيذ على التعقل في الأخطاء . تحديد مجموعة (الإجمالي) من عدة عيوب هو دائما من الصعب تنفيذ (العمل) من الاساليب الكلاسيكية من الاشارات، وهو يعلم أن تلك إشارة الاهتزازي الذي يتخذ من صنع التأثيرات الصوتية ، حتى إعادة تعريف المملة.

Sommaire

Introduction Générale	1
Chapitre 1. Analyse bibliographique et position du problème.....	4
1.1. Introduction.....	Erreur ! Signet non défini.
Chapitre II. ETUDE THEORIQUE	16
II.1. Notions de maintenance	16
II.1.1 Maintenance corrective	16
II.1.2 Maintenance Préventive	16
II.1.3 Paramètres de surveillance et de diagnostic.....	18
II.2 Signal vibratoire et notions de traitement de signal.....	19
II.2.1 Signal vibratoire et valeurs globales	19
II.2.2 Notions de traitement de signal.....	23
II.3 Réseaux de neurones	27
Couche d'entrée	28
II.3.1. Réseau à rétro propagation de l'erreur(BP)	29
II.3.2 Réseau à fonctions à base radiale (RBF).....	30
Chapitre III. EXPLOITATION NUMERIQUE	32
III.1 Système défectueux simulé numériquement.....	32
III.2 Réseau à rétro propagation de l'erreur (BP)	36
III.2.1 Influence du nombre de neurones sur la couche cachée.....	37
III.2.2 Nombre de neurones sur la couche d'entrée.....	43
III.3 Réseau à fonctions à base radial (RBF)	47
II.3.1 Influence de l'aplatissement de la gaussienne de la fonction de transfert	48
II.3.2 Influence de la fréquence d'échantillonnage.....	50
II.3.3 Test du réseau RBF	51
Chapitre IV. ANALYSE EXPERIMENTALE	54

IV.1 Introduction	54
IV.2 Description du banc d'essai et protocole expérimental.....	54
Défauts simulés.....	57
Neurones de la couche de sortie	57
IV.3 Détermination des fréquences propres de la structure.....	58
IV.4 Cas lubrifié	60
IV.5 Cas non lubrifié	66
IV.6 Utilisation des spectres	68
Conclusion Générale.....	72
Références bibliographiques.....	77
Annexe 1.	81
Annexe 2.	83

Liste des figures

Figure II.1 Représentation des différents types de maintenance.

Figure II.2 Les différents types de diagnostic dans la maintenance conditionnelle.

Figure II.3 Signal temporelle constitué de plusieurs fréquences.

Figure II.4 Signal temporelle mesuré sur une turbine à gaz ne présentant aucun défaut.

Figure II.5 Accélération crête et accélération crête à crête.

Figure II.6 Norme sur les niveaux vibratoires par rapport à la vitesse globale 10-1000 Hz

Figure II.7. Spectre d'un roulement défectueux.

Figure II.8. Signal simulé, son enveloppe et spectre de l'enveloppe.

Figure II.9. Spectre et cepstre d'un palier arbre multiplicateur à engrenages.

Figure II.10. Neurone formel.

Figure II.11. Réseaux de neurones.

Figure II.12. Fonction d'activation de la couche cachée du réseau BP.

Figure II.13. Fonction d'activation de la couche cachée du réseau RBF.

Figure III.14. Banc d'essai simulé

Figure III.15. Signal échantillonné.

Figure III.16. Signal simulé et son spectre pour la configuration sans défaut.

Figure III.17. Signal simulé et son spectre avec défaut de denture sur pignon.

Figure.III.18 Convergence du réseau dans le cas de 5 neurones dans la couche cachée sans bruit de fond

Figure.III.19 Convergence du réseau dans le cas de 10 neurones dans la couche cachée sans bruit de fond

Figure.III.20 Convergence du réseau dans le cas de 20 neurones dans la couche cachée sans bruit de fond

Figure.III.21 Taux global de détection en fonction du nombre de neurone sur la couche cachée

Figure.III.22 Taux global de détection en fonction du nombre de neurone sur la couche d'entrée -cas de vingt neurones sur la couche cachée-

Figure.III.23 Convergence du réseau dans le cas de 20 neurones dans la couche cachée 4096 neurones sur la couche d'entrée. Cas de sans bruit de fond

Figure.III.24. Erreur relative commise sur la détection du défaut de Roulement+Pignon1 en fonction de l'aplatissement σ^2

Figure.III.25. Taux de détection en fonction de la fréquence d'échantillonnage

Figure III.26. Taux de détection des défauts simulés

Figure IV 27. Banc d'essai (réducteur à deux étages)

Figure IV 28. Signal du défaut d'engrenage sur la roue 3 et sur la bague extérieure du roulement à $N = 1800$ tr/mn.

Figure IV.29. Spectres des défauts sur la roue1 à $n = 1800$ tr/mn

Figure IV.30. Modes de vibrations de la structure enveloppant le réducteur

Figure IV.31 Vitesse globale correspondant aux différents défauts simulés à $n = 1800$ tr/mn

Figure IV.32 RMS correspondant aux différents défauts simulés à $n = 1800$ tr/mn

Figure IV.33 Kurtosis correspondant aux différents défauts simulés à $n = 1800$ tr/m.

Figure IV.34. Spectre d'enveloppe dû aux différents défauts simulés à $n = 1800$ tr/mn

Figure IV.35 Cepstre dû aux différents défauts simulés à $n = 1800$ tr/mn.

Figure IV.36. Taux de détection des défauts simulés ($n = 1800$ tr/mn)

FigureIV.37 Kurtosis correspondant au cas non lubrifié. $n = 1800$ tr/mn

Figure IV.38. Taux de détection des défauts simulés dans les cas lubrifiés et non lubrifiés.

Figure.IV.39. Convergence du réseau dans le cas d'utilisation des spectres avec lubrification.

Figure.IV.40 comparaison des taux de détection dans le cas lubrifié à $n = 1800$ tr/ mn.

Liste des tableaux

Tableau 1. Défauts simulés.

Tableau 2. Défauts simulés et neurones associés.

Tableau 3. Jeux de test et leurs neurones de sortie sans bruit de fond - 5 neurones dans la couche cachée-.

Tableau 4. Jeux de test et leurs neurones de sortie avec et sans bruit de fond - 10 neurones dans la couche cachée-.

Tableau 5. Jeux de test et leurs neurones de sortie avec et sans bruit de fond - 20 neurones dans la couche cachée-.

Tableau 6. Jeux de test et leurs neurones de sortie sans bruit de fond - 20 neurones dans la couche cachée, M_1 , M_2 , M_3 et M_4 comme entrée du réseau.

Tableau 7. Jeux de test et leurs neurones de sortie avec et sans bruit de fond.

Tableau 8. Comparaison des réseaux RBF et BP en présence d'un bruit de fond.

Tableau 9. Défauts simulés.

Tableau 10. Jeux d'apprentissage et leurs sorties correspondantes.

Tableau 11. Exemples testés et leurs neurones de sortie correspondants ($n = 1800$ tr/mn).

Tableau 12. Exemples testés et leurs neurones de sortie correspondants ($n = 3000$ tr/mn).

Tableau 13. Exemples testés et leurs neurones de sortie correspondants ($n = 1800$ tr/mn). Cas lubrifié.

Nomenclature

Lettres minuscules

$x(t)$: Signal vibratoire

f : Fréquence

$y(t)$: Signal temporel

$\tilde{y}(t)$: Transformée d'Hilbert de $y(t)$

$\hat{y}(t)$: Signal analytique

$\left| \hat{y}(t) \right|$: Enveloppe de $y(t)$

$h(t)$: Réponse impulsionnelle

$e(t)$: Excitation

w_i : Poids du neurone

b : Biais du neurone

nn : Nombre de jeux d'apprentissage

m : nombre de neurones sur la couche de sortie

$e(k)$: Pas du gradient à l'étape k du réseau.

c_j : Centre de la fonction d'activation du neurone radiale pris habituellement égal à w_i .

f_{res} : Fréquence de résonance.

Lettres majuscules

V_g : Vitesse globale de la vibration

$V(t)$: Vitesse vibratoire

Ng : Niveau global (vibratoire)

RMS : Root Mean Square

F_c : Facteur de crête

Acc : Accélération vibratoire

$Acc_{crête}$: Accélération crête

Kurt : Kurtosis

T : Temps d'acquisition du signal

$S_x(f)$: Spectre

N : nombre d'échantillons représentant le nombre de neurone sur la couche d'entrée

F_e : Fréquence d'échantillonnage

T_e : Période d'échantillonnage

$C(\tau)$: Cepstre

N_c : Nombre de neurones sur la couche cachée.

E : Erreur quadratique commise sur la cible (sortie)

N_{imp} : Nombre d'impacts.

M_n : Moment statistique d'ordre n appelé aussi cumulant.

Lettres grecques

τ : Quéfrece

σ_j^2 : Caractérise l'aplatissement de la gaussienne de la fonction d'activation du neurone RBF.

τ_{rel} : Temps de relaxation.

ζ : Amortissement

δ : Dirac

Introduction Générale

Depuis l'avènement de l'ère industrielle l'homme s'est toujours intéressé à l'entretien de la machine, qui était beaucoup plus une solution corrective de type palliative ou curative. L'évolution des esprits par rapport à cette notion a conduit à la maintenance, qui doit être pensée, organisée et structurée.

Vu la complexité des machines et l'importance de ces dernières dans l'industrie, comme outil de production, un nouveau type de maintenance se développe ces dernières années : la maintenance conditionnelle.

Dans ce cadre les vibrations jouent un rôle de premier plan dans le diagnostic des défauts de machines tournantes. En effet, la modification de la signature vibratoire d'une machine tournante est souvent la première manifestation physique d'une anomalie, cause potentielle de dégradations, voire de pannes.

D'ailleurs, les paramètres globaux issus de cette signature sont de bons indicateurs pour surveiller l'état d'une machine tournante, nous pouvons citer : la vitesse vibratoire globale entre 10 et 1000 Hz, le facteur de crête ou le kurtosis.

Mais dès lors que l'on parle de diagnostic, d'autres techniques d'investigations sont nécessaires, tel que le spectre, souvent insuffisant notamment lorsqu'il s'agit d'un défaut à impact comme ceux générés par les roulements ou engrenages défectueux. L'analyse Cepstrale, l'analyse d'enveloppe, la transformée de Fourier à court terme ou la transformée d'ondelettes constituent des solutions qui peuvent résoudre ce type de problèmes. Néanmoins, ces dernières existent sur peu de systèmes de surveillance et restent de la compétence d'un spécialiste. De plus, la détection de plusieurs défauts reste

fastidieuse. En effet, le signal généré par un roulement peut être masqué par un bruit de fond ou par d'autres défauts.

Les systèmes mécaniques et plus particulièrement les machines tournantes devenant de plus en plus complexes, entraînent une maintenance de plus en plus difficile. Ajouter à cela des machines de plus en plus automatisées, un nouveau type de maintenance est en train de prendre place, basée sur la surveillance et la maintenance conditionnelle par réseaux de neurones.

Pour notre part, dans le présent travail nous développons une méthode qui consiste en une nouvelle approche de la maintenance conditionnelle, détection des défauts, se basant sur les réseaux neurones. Cette technique consiste à construire un système de réseau de neurones (ensemble d'automates) à partir duquel par un processus d'apprentissage nous injectons un ensemble de signaux correspondants à tous les défauts que peut rencontrer la machine lors de son fonctionnement, pour pouvoir identifier tout défaut non appris par le réseau. Par ailleurs cette technique est la base des systèmes experts actuellement en développement dans plusieurs laboratoires de recherche pour arriver à l'auto diagnostic des machines tournantes.

Le chapitre 1 portera sur l'analyse bibliographique et la position du problème où nous résumons l'essentiel des travaux réalisés dans ce domaine afin de construire notre problématique. Cette dernière s'articule autour de l'utilisation de deux types de réseaux et la détection de défauts combinés (Roulement et Engrenages) dans des cas défavorables.

Le chapitre 2 concerne le formalisme théorique, nous mettons ainsi en place les outils mathématiques nécessaires à la mise en œuvre de cette méthode. Nous passerons en revue le neurone élémentaire pour aller vers la notion de réseau de neurones nous

permettant de mettre en œuvre analytiquement les deux types de réseau utilisés dans le présent travail.

L'exploitation numérique et les résultats seront abordés dans le chapitre 3 où nous exposons les résultats obtenus sur des signaux numériques (simulation numériques) afin d'évaluer la capacité de cette méthode à remonter au défaut et d'établir les limites de cette méthode. Pour mettre en œuvre cette approche neuronale nous utilisons deux types de réseau : le réseau à rétro propagation de l'erreur (BP) et le réseau à fonction à bases radiales, l'étude sera menée sur des signaux combinés (défauts de roulement et d'engrenages). Ces deux réseaux seront comparés quant à leur aptitude à remonter aux défauts simulés (numériquement) ainsi que leur sensibilité par rapport à un bruit de fond caractérisant d'autres sources indépendantes aux défauts simulés.

Le chapitre 4 porte sur l'analyse expérimentale, la méthode est testée sur des signaux réels mesurés sur un banc d'essai réalisé au Laboratoire Vibrations Acoustique de L'INSA de Lyon. L'analyse portera dans un premier temps sur des signaux mesurés comme entrée du réseau. Et par la suite sur les spectres comme entrée du réseau, spectres calculés à partir des signaux mesurés. L'étude sera menée avec lubrification, correspondant au cas sans bruit de fond pour les signaux simulés numériquement, et sans lubrification correspondant au cas avec bruit de fond intense et donc au cas le plus défavorable lors de la détection des défauts. Cette analyse nous permettra de corroborer les résultats obtenus précédemment lors de la simulation numérique.

Nous terminons enfin par une conclusion générale et des perspectives.

Chapitre I. Analyse bibliographique et position du problème

Très tôt les industriels se sont intéressés à la maintenance conditionnelle, et dans ce cadre les vibrations jouent un rôle de premier plan dans le diagnostic des défauts de machines tournantes. L'analyse des vibrations s'est donc imposée comme un outil puissant pour le diagnostic de ce type de machines. La détection d'un défaut naissant dans la maintenance conditionnelle est très importante du fait que ce dernier peut s'accélérer rapidement et affecter ainsi les autres pièces.

Afin d'éviter les pannes intempestives, il serait donc intéressant de détecter le défaut naissant dans ce mécanisme ; l'importance de ce défaut comparée avec des seuils préétablis indique le moment adéquat pour l'arrêt et l'intervention sur la machine. Il est clair que certains problèmes peuvent être résolus par analyse des vibrations ; l'analyse spectrale ainsi que les outils en découlant (analyse cepstrale, analyse d'enveloppe) ont répondu et répondent toujours à ce type de problème [1] et [2]. Cependant, cette analyse n'est parfois pas aisée, la lecture des résultats de cette dernière ne permet pas, dans certains cas, de remonter directement au défaut à détecter.

En effet, la détection des défauts de roulements (défauts sur les bagues intérieure et extérieure ou sur l'élément roulant) est un cas illustrant ce type de problèmes. Les roulements sont d'ailleurs un très bon indicateur du bon fonctionnement d'une machine tournante, la détection d'une défaillance sur ce type de pièces prend toute son importance ici. La difficulté de détection dans ce genre de défauts est que le signal vibratoire qui en découle, s'étendant sur une large bande de fréquences, est chahuté par un bruit blanc. En plus, les fréquences caractéristiques nécessaires pour identifier la

nature du défaut naissant sont masquées par les basses fréquences telles que les fréquences d'engrènement par exemple. Un défaut sur les bagues intérieure ou extérieure provoque à chaque passage de l'élément roulant un choc, il s'ensuit sur le spectre une émergence spectrale en hautes fréquences. En effet, une des harmoniques de ce choc vient exciter les fréquences propres du roulement en question. La lecture et l'interprétation du spectre deviennent ainsi très complexes.

Bon nombre de méthodes ont été utilisées pour résoudre ces problèmes telles que la démodulation du signal non stationnaire pour déterminer l'enveloppe (analyse d'enveloppe) et calculer son spectre [4 – 8]. Les techniques utilisées [3] sont par exemple la transformée de Fourier à court terme, la transformée d'Hilbert ou la transformée de Wigner Ville, très rarement utilisée.

Par contre des problèmes surgissent lorsque l'endommagement du roulement devient important, des motifs viennent s'ajouter au spectre rendant ce dernier confus quant à son interprétation. En dépit des études déjà, réalisées dans le domaine des résonances en hautes fréquences, aucun modèle n'a pu résoudre clairement ce problème. Pour le surmonter et donner une explication, Mc Fadden et Smith [9] ont proposé un modèle qui décrit les vibrations d'un roulement affecté d'un défaut sur la bague intérieure et sous l'effet d'une charge constante radiale appliquée sur le roulement. La charge étant fonction du jeu diamétral, la vibration est modulée par l'impulsion due au passage de l'élément roulant sur le défaut avec la distribution de la charge sur le roulement. Ce modèle incorpore ainsi quantitativement les effets de géométrie du roulement de la distribution de la charge et de la fonction de transfert entre le roulement et l'accéléromètre. Ils arrivent ainsi à expliquer ce qui se passe lorsque le roulement est fortement endommagé. Plus tard, ils ont généralisé cette étude dans le cas où la bague intérieure est affectée de plusieurs défauts [10] ; les résultats obtenus par le modèle sont satisfaisant comparés à ceux obtenus expérimentalement.

Les tentatives pour expliquer les phénomènes engendrés par les défauts de roulement rendent compte de l'importance et de la complexité à identifier la nature des défauts de roulement dans une machine tournante. Pour expliquer la dégradation du signal vibratoire d'un roulement défectueux, des tentatives de modélisation du roulement en un système linéaire (masse ressort et amortissement) ont été réalisées [11].

La complexité et l'importance de la détection des défauts de roulements, particulièrement lorsque lorsqu'il s'agit de plusieurs défauts au même temps [12], ont conduit à pousser les investigations, notamment avec l'avènement des Wavelets (ondelettes) à la fin des années 80.

En effet, les auteurs de cette dernière référence [12], ont mis au point une technique de diagnostic des défauts de roulement basée sur la transformée discrète d'ondelettes (DWT) [13]. Les résultats obtenus pour détecter les défauts sur les bagues intérieure et extérieure lors du passage de l'élément roulant ont été satisfaisants. La méthode est assez intéressante car c'est un compromis entre les résolutions temporelle et fréquentielle, qui comme on le sait évoluent dans des sens opposés. Cette méthode est basée sur un filtrage en cascade du signal, elle est intéressante et donne de bons résultats notamment lorsque la bande de fréquence correspond au mode résonnant car c'est là que le défaut est dominant.

D'ailleurs, James and Ma [14] ont discuté d'une façon très intéressante les propriétés de la transformation d'ondelettes, appliquées au roulement, et l'ont comparée à la transformée de Fourier à court terme.

Jing and Qu [15] ont utilisé, pour éliminer le bruit blanc présent dans le signal recueilli suite à un défaut de roulement, l'ondelette continue de Morlet.

Cependant, dans [14] et [15], un seul défaut a été étudié à la fois à savoir sur la bague intérieure. Ce qui n'est pas le cas dans la référence [12], où plusieurs défauts ont été simulés simultanément (bague intérieure, bague extérieure et élément roulant).

L'inconvénient de la transformation d'ondelettes discrète est qu'il faut avoir une très forte cadence d'échantillonnage ie un signal vibratoire fortement échantillonné. Ce qui n'est pas toujours aisé – capacité des calculateurs -, la transformation d'ondelettes continue est alors fortement conseillée. En effet, l'auteur de la référence [16] utilise l'ondelette continue Morlet pour détecter des défauts sur les bagues intérieure et extérieure d'un roulement. Le principe est simple, il repose sur la capacité de l'ondelette à épouser ou à s'adapter au signal généré par les défauts en question. Il se détermine en calculant les coefficients d'ondelette : paramètre d'échelle et paramètre de translation ; le bon choix de l'ondelette mère est nécessaire. Ainsi, le spectre de la réponse impulsionnelle de l'ondelette permet de retrouver les fréquences caractéristiques du défaut. L'inconvénient est le temps de résolution très important.

Diverses techniques sont développées pour la détection de défauts de roulements et le challenge est de les extraire d'une façon efficace à partir du signal acquis et particulièrement dans le domaine temps – fréquence. Une nouvelle technique appelée ‘Basis Pursuit’ est récemment développée [17], elle est basée sur l'optimisation du choix de l'ondelette parmi celles connues. On obtient ainsi une meilleure résolution, même lorsque le signal est accompagné d'un bruit blanc. Le plus intéressant est que la représentation est en temps - fréquence et donc une meilleure interprétation des résultats obtenus. Pour plus de détails concernant la méthode d'optimisation se référer à [18] et [19].

La particularité de cette méthode est l'analyse du signal en temps – fréquence. En effet, ceci est intéressant du fait que le signal émis par ce type de défaut est non stationnaire. Elle présente par rapport aux autres méthodes, telles que la transformée de Fourier à court terme, une meilleure résolution et donc un diagramme moins dense et plus facile à interpréter.

Comme nous l'avons dit précédemment, en industrie la maintenance et la surveillance des systèmes mécaniques est d'une importance vitale en termes économique et de productivité.

Ces systèmes et plus particulièrement les machines tournantes devenant de plus en plus complexes, entraînent une maintenance de plus en plus difficile. Ajouter à cela des machines de plus en plus automatisée, un nouveau type de maintenance est en train de prendre place, basée sur la surveillance et la maintenance conditionnelle par réseaux de neurones.

Déjà en 1993, Liu et Iyer [20] développent une nouvelle approche pour le diagnostic des défauts de roulements, les réseaux de neurones sont utilisés pour diagnostiquer différents genres de défauts. Les données collectées pour cinq différents types de défauts ainsi que le roulement sans défaut sont utilisés pour entraîner le réseau. Plusieurs types de réseaux ont été utilisés et chaque fois il a été capable de distinguer le roulement normal des roulements défectueux. Néanmoins, malgré la bonne classification des différents défauts (à 94% de réussite), le réseau n'est pas capable à ce stade de remonter au type de défaut. Les réseaux de neurones sont intéressants du fait qu'on peut opérer en temps réel et manipuler des signaux distordus ou affectés d'un bruit blanc [21].

Les réseaux de neurones ont fait l'objet de nombreuses applications en mécanique, particulièrement dans l'analyse des signaux vibratoires et acoustiques pour la détection des défauts de machines tournantes. Nous pouvons citer les travaux de Wenlung Li et al. [22] sur l'étude expérimentale d'un système expert pour le diagnostic des balourds, sur une machine tournante, par réseaux de neurones en utilisant des signaux acoustiques. Les auteurs de cette référence ont utilisé un réseau à rétro propagation, (Backward propagation neural network, BPN). Le signal subit un prétraitement pour minimiser les effets du bruit blanc dans le signal. Le réseau utilisé

est à une couche cachée. Il a été prouvé que ce système expert donnait de bons résultats excepté qu'il existe un phénomène qui ressemble à de la résonance.

Les travaux de Samanta et al. [23] ont montré l'efficacité des réseaux de neurones pour le diagnostic des défauts de roulements. Le réseau utilisé est à deux couches cachées avec une sortie binaire caractérisant l'état de la machine : normal ou défaut de roulement. Les signaux vibratoires ne sont pas directement utilisés à l'entrée du réseau mais subissent au préalable un traitement. Trois méthodes ont été utilisées : la détection de l'enveloppe (démodulation), le filtrage et la transformée d'ondelettes. L'entraînement du réseau se fait par la rétropropagation (BPN). L'erreur simulée est sur l'élément roulant. Les résultats obtenus sont très intéressants, de plus cette méthode convient bien à une surveillance on-line.

De la même façon M. Yang et al. [24], utilisent comme entrée du réseau soit le spectre de puissance, le bispectre ou la bicohérence. Les résultats montrent là aussi que les défauts simulés, sur la cage et les bagues intérieure et extérieure, ont été diagnostiqués avec réussite.

Les réseaux de neurones sont très utilisés dans la détection des défauts de machines tournantes, l'article de Czeslaw et al. [25] traite du diagnostic dans un moteur à induction dans le cas du rotor, stator et défauts de roulement. Deux types de réseaux ont été utilisés : Perceptron à multicouches et la carte organisatrice de Kohonen [26, 27] et [45]. Cette dernière est utilisée comme une étape d'introduction pour classer ces défauts par rapport à l'état normal avant d'identifier la nature du défaut par le réseau perceptron à multicouches. La méthode a donné des résultats satisfaisants, néanmoins l'efficacité est meilleure pour la détection des défauts sur rotor et le stator que sur le roulement.

La grande difficulté avec la détection des défauts de roulement est que les signaux vibratoires qui en découlent sont souvent masqués par les signaux vibratoires générés par les autres composants de la machine et particulièrement ceux produits par les engrenages notamment ceux correspondants aux fréquences d'engrènement. Randall [28], tout en touchant le problème de ce type de diagnostic et notamment lorsque le défaut est naissant, propose pour cela des techniques autre que celles basées sur les réseaux de neurones, utilisant plutôt la séparation de ces signaux. Ces techniques reposent sur la différence des propriétés statistiques entre les deux signaux, ce sont des méthodes de filtrage : Adaptive Noise Cancellation (ANC) [29] et Discrete Random Separation (DRS) [30].

Nous avons rencontré peu d'articles utilisant les réseaux de neurones pour détecter les défauts de roulement à leur naissance, notamment lorsque le signal est masqué par un bruit blanc et d'autres émergences spectrales. C'est un problème qu'on essaye de résoudre que ça soit dans le domaine vibratoire ou acoustique. Comme nous l'avons déjà précisé, le diagnostic utilisant des méthodes d'intelligence artificielle est d'actualité, vu le type de machines complexe et automatisé utilisé ces dernières années dans les processus de production, il permet aussi une maintenance plus optimale.

L'article de Lai Wuxing et al. [31] est intéressant et édifiant pour approcher ce type de problème. En effet, chaque dent dans un engrenage est alternativement engrenée, d'où des conditions de charge qui changent alternativement. De plus un bruit blanc de type gaussien vient s'ajouter pour produire de mauvaises mesures rendant la détection d'un défaut sur l'engrenage difficile. Ce papier a pour but de proposer une approche permettant de classifier les défauts d'engrenage en vue d'une bonne identification, en utilisant deux étapes dans le traitement : la méthode des "cumulants" et la "Radial Basis Function" (BRF) network. La première sert à minimiser le bruit Gaussien et la deuxième est un réseau de neurone qui fournit de meilleures fonctions

utilisant des entrées non linéaires et permet une rapide convergence du réseau. Le réseau RBF est alors utilisé comme classificateur pour les différents états de l'engrenage : normal et défectueux avec ses différentes variétés. Les résultats ont montré que cette méthode de classification basée sur la combinaison des "cumulants" et du réseau RBF est très prometteuse et permet une meilleure précision.

Bien que le réseau à rétropropagation de l'erreur, "Back-Propagation (BP) network" a été très utilisé dans plusieurs applications d'engineering et que beaucoup de logiciels ont été développés dans ce sens, leur efficacité pour résoudre ce type de problème n'a pas été prometteuse. Et de plus, la détermination d'un réseau BP qui convient, telle que le nombre de neurones sur la couche cachée, est très difficile pour un utilisateur inexpérimenté. Le réseau BRF offre une nouvelle et meilleure méthode d'entraînement, un temps requis plus faible et une rapide convergence. De plus le nombre de neurones sur la couche cachée est déterminé automatiquement durant l'entraînement du réseau, d'où une architecture plus optimale.


Le réseau de neurone RBF est un réseau à retro propagation " feedforward network" [32, 33], il est constitué de trois couches : une couche d'entrée, couche cachée et une couche de sortie. L'avantage de ce type de réseau est que tous les neurones ne sont pas activés, ainsi le temps requis à l'entraînement du réseau est moindre. Les entrées de ce réseau sont différentes de celles des autres réseaux. En effet, l'entrée du RBF est un vecteur distance entre le vecteur W (poids de connexion) et le vecteur entrée de la première couche multiplié par le biais b , notée $\|dist\|$ [34]:

$$n = \|dist\| = \|W - p\| . b$$

Par la suite, l'activation du neurone se fait en utilisant une fonction de transfert du type Gaussienne :

$$a = f(n) = e^{-n^2}$$

La figure ci-dessous, montre un réseau RBF avec un neurone et R entrées. La figure peut être généralisée à un réseau à plusieurs neurones :



Radial Basis Neuron

La radial basis function est au maximum (égal à 1) lorsque l'entrée est nulle. Alors que la distance entre les poids du réseau diminue, la sortie augmente. Par conséquent, le Radial Basis Neuron agit comme un détecteur qui, produit une sortie égale à 1, à chaque fois que l'entrée p du réseau est identique aux poids synaptiques w de ce réseau. Ce qui explique l'intérêt de ce type de réseau à savoir un temps d'entraînement plus faible et une rapide convergence.

Dans la présente étude, nous utiliserons ce type de réseau pour la classification et la détection des défauts de roulement : Défaut sur les bagues intérieure et extérieure ainsi que sur l'élément roulant, dans notre cas la bille. Nous faisons ce choix car le diagnostic des roulements présente les mêmes difficultés que celui des engrenages, à savoir un signal vibratoire noyé par un bruit blanc, non stationnaire ainsi que des fréquences caractéristiques du roulement, nécessaires à l'identification, cachées par des émergences spectrales.

Cependant, un pré-traitement est nécessaire pour extraire à partir du signal les particularités et caractéristiques utiles et nécessaires à la détection des défauts de roulement avant de définir les entrées du réseau. Pour ce faire, plusieurs méthodes

subsistent : l'analyse d'enveloppe et la méthode des ondelettes (wavelets methods). En plus du bruit blanc et des autres vibrations qui proviennent de la machines et qui cachent les particularités et les caractéristiques du signal à analyser, l'analyse spectrale est inutile notamment lorsque le défaut est naissant. Le filtrage numérique est une autre méthode utilisée pour minimiser le bruit de et extraire le signal utile. Cependant, il faut avoir la connaissance du bruit blanc pour sélectionner la bande de fréquence du filtre, ce qui n'est pas du tout évident lorsqu'on fait du diagnostic.

Un pré-traitement est donc nécessaire pour extraire le signal utile, et de minimiser le plus possible ces parasites. Il serait par contre intéressant d'utiliser les différences statistiques des signaux pour les différencier. Ces dernières années, une méthode prometteuse a été développée, les statistiques d'ordre supérieur (High-order Statics) [35].

C'est pour cela que nous adopterons comme entrée du réseau non pas le signal acquis mais ayant subi un prétraitement, à savoir les moments statistiques et plus particulièrement les moments statiques centraux. Pour une variable $X(t)$ à N échantillons, ils sont donnés par [36,37] :

$$M_n = \int_{-\infty}^{+\infty} (x - \mu_x)^n f_x(x) dx$$

Numériquement, on a :

$$M_n = \sum_{i=1}^N (x_i - \mu_x)^n p(x_i)$$

M_n est le moment central d'ordre n , $f_x(x)$ est la densité de probabilité de X et μ_x est la moyenne :

$$\mu_x = \frac{1}{N} \sum_{i=1}^N x_i$$

De plus le troisième moment et quatrième sont appelés respectivement les coefficients Skewness et Kurtosis :

$$S_x = \frac{M_3}{\sigma_x^3}$$

et

$$k_x = \frac{M_4}{\sigma_x^4}$$

Où σ_x est l'écart type de X.

Le calcul de ces paramètres revient à dé-corréler le signal noyé dans un bruit blanc, du type Gaussien ou aléatoire, pour en extraire le signal utile, ce dernier constituera l'entrées du réseau.

Pour détecter les défauts naissants dans un roulement sur les bagues intérieure et extérieure ainsi que sur l'élément roulant, notre approche sera neuronale. Nous utiliserons un réseau du type Radial Basis Function (RBF) où nous étudions les différents paramètres de ce dernier en vue d'une efficacité optimale quant à la classification et la détection des différents défauts pré-cités.

Comme nous l'avons cité auparavant, les entrées de ce réseau subiront un pré-traitement en deux étapes. Une première étape qui consiste en l'application de la méthode des ondelettes (Wavelets Method) afin de dé corrélér le signal des autres vibrations de la structure, telles que les fréquences d'engrènement, rendant le signal utile plus faible, Il s'agit là de défauts naissants. Une deuxième étape, qui consiste à dé-corréler le signal d'un éventuel bruit blanc, du type mécanique, pour avoir un rapport signal-bruit le plus important possible. Pour cela, notre démarche consiste à utiliser la différence des propriétés statistiques des signaux en utilisant la théorie des statistiques d'ordre supérieur (Theory of High-Order Statistics).

Notre démarche se fera en deux phases. Une première phase qui consiste à simuler des signaux théoriques de défauts de roulements afin de déterminer les paramètres optimaux du réseau. Et une deuxième phase en une analyse expérimentale afin d'évaluer et de tester l'efficacité de cette démarche. Nous apporterons ainsi, une contribution à la maintenance conditionnelle des systèmes mécaniques et plus particulièrement des machines tournantes.

Pour notre part, nous proposons une méthode basée sur les réseaux de neurones pour identifier un défaut et plusieurs combinaison de défauts mécaniques. Nous comparons deux types de réseaux, celui utilisant la rétro propagation de l'erreur (RBP : Back Propagation) et celui utilisant les fonctions à base radiales (RBF : Radial Basis Function). Nous mettons en évidence leur capacité de remonter au défaut ainsi que leur sensibilité par rapport à un bruit de fond caractérisant d'autres sources indépendantes aux défauts. Cette évaluation se fera dans un premier à partir de simulations numériques de défauts, et par la suite une confrontation avec la mesure sera effectuée sur un banc d'essai constitué d'une transmission par engrenages à deux étages, et de paliers à roulements, avec et sans lubrification. Des défauts provoqués seront analysés dans cette étude.

Chapitre II. ETUDE THEORIQUE

II.1. Notions de maintenance

La maintenance est l'ensemble des actions permettant de maintenir ou rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé tout en préservant la sécurité des personnes et des biens , elle a, essentiellement, pour but :

D'augmenter la durée de vie des matériels.

De diminuer la probabilité des défaillances en service.

De diminuer les temps d'arrêt en cas de révision ou de panne...

Nous distinguons deux types de maintenance : la maintenance corrective et la maintenance préventive.

II.1.1 Maintenance corrective

Elle est effectuée après la détection d'une panne et destinée à remettre un équipement dans un état lui permettant d'accomplir une fonction requise. Cette maintenance est utilisée lorsque l'indisponibilité du matériel n'a pas de conséquences majeures sur le processus de production ou quand les contraintes de sécurité sont faibles. (Extrait norme NF EN 13306 X 60-319). Elle peut être curative (réparation) ou palliative (dépannage et donc provisoire)

II.1.2 Maintenance Préventive

Elle est effectuée avant la panne ou l'arrêt de la machine. La définition donnée par l'AFNOR est la suivante : « Maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien » (extrait norme NF EN 13306 X 60-319).

- Maintenance systématique :

Elle s'effectue suivant un échéancier établi selon le temps . La Définition selon la norme européenne est : « Maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage mais sans contrôle préalable de l'état du bien » (extrait norme NF EN 13306 X 60-319).

- Maintenance conditionnelle :

Elle est subordonnée au franchissement d'un seuil bien déterminé, significatif de l'état de dégradation du bien. Définition de la norme européenne : « Maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent » (extrait norme NF EN 13306 X 60-319).

- Maintenance Prévisionnelle :

Appelée aussi maintenance prédictive, elle est exécutée en suivant les prévisions extrapolées (liée donc au futur) de l'analyse et de l'évaluation de paramètres significatifs de la dégradation de l'équipement. La figure ci-dessous (Figure II.1) est une représentation des différents types de maintenance.




Figure II.1 Représentation des différents types de maintenance

II.1.3 Paramètres de surveillance et de diagnostic

Plusieurs paramètres peuvent être envisagés pour mettre en œuvre la maintenance conditionnelle :

Analyse vibratoire : Mesure globale, analyse spectrale,

Analyse des huiles : Analyse physico-chimique (viscosité, teneur en eau, acidité) traduisant la dégradation de l'huile.

Analyse des particules : analyse des particules contenues dans l'huile, traduisant donc * l'usure.

Analyse thermique : thermographie infrarouge.

Analyse structurelle : analyse des fissures.

Nous retiendrons la maintenance conditionnelle par analyse vibratoire et par conséquent le signal vibratoire pour mettre en œuvre le diagnostic des défauts de machines tournantes par réseaux de neurones.




Figure II.2 Les différents types de diagnostic dans la maintenance conditionnelle

II.2 Signal vibratoire et notions de traitement de signal

Nous mettons en place, dans ce qui suit, les outils mathématiques nécessaires au traitement des signaux ainsi qu'à la détermination des valeurs globales ou indicateurs à partir de la connaissance et la prise du signal.

II.2.1 Signal vibratoire et valeurs globales

Très souvent le signal qui a pour origine des sollicitations multiples est inexploitable où toute interprétation devient difficile et fastidieuse (Figure II.3).




Figure II.3 Signal temporel constitué de plusieurs fréquences

Dans la réalité le problème devient beaucoup plus complexe (cf. Figure II.4) où toute interprétation devient impossible




Figure II.4 Signal temporel mesuré sur une turbine à gaz ne présentant aucun défaut

Comme le signal mesuré est numérique et donc échantillonné, nous allons caractériser le signal non pas par ces échantillons mais par une seule valeur qui peut être une valeur particulière du signal ou une grandeur caractéristique comme la moyenne ou les moments d'ordre élevés. Nous passons ainsi à une forme plus exploitable du signal, c'est ce que nous désignons par indicateurs temporels.

Un indicateur scalaire associé à un signal vibratoire est observé le plus souvent sous sa forme temporelle sur une durée déterminée en fonction de la cinématique de l'installation. C'est une grandeur représentative du signal pouvant être la valeur efficace (RMS en vitesse ou en accélération) ou la valeur crête ou une combinaison de ces deux grandeurs (facteur de crête, kurtosis).

Cette valeur n'a pas forcément de signification intrinsèque mais son évolution dans le temps reflète l'apparition ou l'aggravation d'un défaut.

a – Accélération crête et accélération crête à crête :

Les accélérations crête (Acc_c) et l'accélération crête à crête (Acc_{cc}) ne sont pas des grandeurs statistiques mais des grandeurs lues directement sur le signal. Elles

permettent pour la première valeur d'avoir un aperçu sur le niveau vibratoire et pour la deuxième d'avoir un aperçu sur le changement du signal (cas des chocs par exemple).




Figure II.5 Accélération crête et accélération crête à crête.

b - Vitesse globale ou RMS en vitesse :

Cet indicateur qui représente la valeur efficace de la vitesse vibratoire est révélateur des phénomènes de basses fréquences, ce sont des phénomènes de haute énergie et donc destructeur. Une augmentation du balourd ou d'un défaut de lignage par exemple se traduisent par une augmentation de cet indicateur. Il est donné par l'expression suivante :

$$V_g (mm/s) = \sqrt{\frac{1}{t_2 - t_1} \int_{t_1}^{t_2} V(t)^2 dt} \quad (1)$$

Nous pouvons aussi exprimer cette valeur en accélération appelée RMS en accélération, il représente aussi la valeur efficace de l'accélération :

$$RMS(mg) = \sqrt{\frac{1}{t_2 - t_1} \int_{t_1}^{t_2} Acc(t)^2 dt} \quad (2)$$

Cette valeur est révélatrice des phénomènes de hautes fréquences tels que ceux générés par les défauts d'engrenage et de roulements.

Dans la présente étude, la vitesse globale $V_g(\text{mm/s})$ déterminée entre 10 – 1000 Hz et le RMS (mg) sont calculés à partir du spectre de la vitesse vibratoire (10 – 1000 Hz) pour V_g et du spectre de l'accélération (0 – 10 kHz).

Ces deux niveaux globaux N_g sont donnés par l'expression suivante :

$$N_g = \frac{\sum_{i=1}^N S_i}{N} \quad (3)$$

S_i , le vecteur spectre

N , taille du vecteur Spectre

c – Facteur de crête F_c :

La vibration d'un rotor en bon état est de type harmonique, le facteur de crête correspondant, défini comme étant le rapport de l'accélération crête sur la l'accélération efficace, est proche de $\sqrt{2}$.

Si une dégradation survient ce rapport devient supérieur à 3, le suivi de ce rapport permet de détecter les apparitions de défauts sans toutefois permettre d'en diagnostiquer la source.

$$F_c = \frac{Acc_{\text{crête}}}{Acc_{\text{eff}} (\text{RMS})} \quad (4)$$

c – Kurtosis Kurt :

Le Kurtosis correspond au rapport du moment d'ordre 4 d'un signal vibratoire $s(t)$ sur un temps d'observation T sur le moment d'ordre 2 élevé au carré. La valeur du Kurtosis d'un signal dont la distribution est gaussienne vaut 3, par conséquent, en tant qu'indicateur de défauts induisant des forces d'excitation périodiques, il ne pourra les détecter que si sa valeur est supérieur à 3, ceci impose que la période de répétition des chocs minimale soit au moins de 2.8 fois le temps de relaxation. Cet indicateur permet

de détecter et de suivre des défauts induisant des chocs comme ceux générés par les défauts de roulements :

$$\text{Kurt} = \frac{\frac{1}{T} \int_0^T \dot{x}(t)^4 dt}{\left[\frac{1}{T} \int_0^T \dot{x}(t)^2 dt \right]^2} \quad (5)$$

Le Kurtosis comme le facteur de crête permet de détecter des défauts de chocs. Néanmoins, il est plus sensible à ce type de défauts que le facteur de crête. Il est à noter que les niveaux vibratoires tolérables pour une machine tournante sont donnés par la norme AFNOR sur la vitesse globale 10-1000 Hz :




Figure II.6 Norme sur les niveaux vibratoires par rapport à la vitesse globale 10-1000 Hz

II.2.2 Notions de traitement de signal

a - Transformée de Fourier et spectre

La représentation fréquentielle $S_X(f)$ permettant d'accéder aux composantes spectrales d'un signal $x(t)$ est donnée par :

$$S_X(f) = \int_{-\infty}^{+\infty} x(t) \cdot \exp(-j2\pi ft) dt \quad (6)$$

où f est la fréquence et $j^2 = -1$ et $|S_X(f)|$ représente le spectre d'amplitude.

En formulation discrète nous obtenons :

$$X(f) = \sum_{k=0}^{N-1} x(k \cdot T_e) \exp(-2j\pi f T_e) \quad (7)$$

où T_e est la période d'échantillonnage

et N le nombre d'échantillons correspondant à la durée du signal à analyser.

L'image de cette transformation dans le domaine fréquentiel appelé spectre est donné par la figure II.7, où 5100 Hz représente la fréquence de résonnance du roulement portant le défaut sous forme de rayure sur la bague extérieure:




Figure II.7. Spectre d'un roulement défectueux.

b - Analyse d'enveloppe

La nature non-stationnaire d'un défaut de roulement, correspondant à des impacts (rayure sur l'une des deux bagues), entraîne une modulation d'amplitude du signal vibratoire en question. Ainsi, la périodicité de cette enveloppe correspond à la périodicité du défaut analysé. Le pic présent dans le spectre de l'enveloppe ainsi

détecté, comme nous le verrons par la suite, correspond à la fréquence caractéristique du défaut en question.

Nous développons dans ce qui suit l'aspect mathématique de la détection de l'enveloppe par la méthode de filtrage.

L'utilisation de la méthode de filtrage reste tributaire de la connaissance des fréquences propres du système à analyser. Comme le défaut simulé a été réalisé sur la couronne extérieure, en pratiquant des rayures sur son chemin de roulement, nous avons opté pour la détermination des fréquences propres de la couronne extérieure par approche expérimentale.

La technique de l'enveloppe par filtrage est assez sélective puisqu'elle prend en considération uniquement le mode de vibration dont le rapport signal-bruit est assez élevé. Néanmoins comme nous le verrons plus tard, l'influence du bruit de fond reste dominante.

D'une manière générale, ceci nous conduit à associer à tout signal temporel $y(t)$ un signal en quadrature, donné par :

$$\tilde{y}(t) = \frac{1}{\pi} \int \frac{y(\tau)}{t - \tau} d\tau \quad (8)$$

où $\tilde{y}(t)$ est la transformée de Hilbert de $y(t)$ et τ une variable temporelle.

Comme nous pouvons constater, $\tilde{y}(t)$ n'est autre que la convolution de $y(t)$ avec la fonction

$$\frac{1}{\pi \cdot t}, \text{ soit : } \tilde{y}(t) = y(t) * \frac{1}{\pi \cdot t} \quad (9)$$

La fonction définie par la relation ci-dessous, dans le domaine complexe, n'est autre que le signal analytique :

$$\hat{y}(t) = y(t) + j\tilde{y}(t) \quad (10)$$

Le module de $\hat{y}(t)$ définit l'enveloppe de $y(t)$, soit sa démodulation :

$$\left| \hat{y}(t) \right| = \sqrt{y(t)^2 + \tilde{y}(t)^2} \quad (11)$$

Le spectre de l'enveloppe permet de déterminer la fréquence du choc ce qui permet d'identifier la nature du défaut (cf. Figure II.8)




Figure II.8. Signal simulé, son enveloppe et spectre de l'enveloppe

c - Analyse cepstrale

Le cepstre est une autre façon de démoduler le signal, le cepstre de $x(t)$ est donné par :

$$C[x(t)] = C[\tau] = TF^{-1}[\log TF[x(t)]] \quad (12)$$

τ étant de dimension temps est appelé quéfrence

TF l'opérateur de la transformée de Fourier

Si $x(t)$ est un signal vibratoire alors c'est le produit de convolution de la réponse impulsionnelle de la structure $h(t)$ et l'excitation $e(t)$:

$$x(t) = h(t) \otimes e(t)$$

En injectant $s(t)$ dans l'expression (11), nous aurons :

$$C[x(t)] = C[h(t)] + C[e(t)] \quad (13)$$

$C[h(t)]$ représente le cepstre de la réponse impulsionnelle

$C[e(t)]$ représente le cepstre de l'excitation permettant d'identifier la nature du défaut

(cf Figure II.9)




Figure II.9. Spectre et cepstre d'un palier arbre multiplicateur à engrenages

II.3 Réseaux de neurones

Un neurone élémentaire est un automate qui se compose de plusieurs entrées x_i et d'une sortie a (cf. Figure II.10) et d'une fonction de transfert des entrées vers la sortie.

f est la fonction d'activation ; les paramètres w_i et b , respectivement les poids des connexions et biais, sont les inconnues du problème, permettant d'adapter le réseau à la sortie désirée.




Figure II.10. Neurone formel

La sortie a , est donnée par l'expression suivante:

$$a = f\left(\sum_{i=1}^N w_i x_i + b\right)$$

(14)

La généralisation du neurone à un système plus grand pour résoudre des problèmes plus complexes, nous amène aux réseaux de neurones. Ceci nécessite l'introduction de plusieurs sorties et d'au moins une couche intermédiaire appelée couche cachée comportant plusieurs neurones (cf. Figure II.11)

Chaque neurone est paramétrable, par modification des poids w_i et des biais b_i afin d'adapter le réseau, à partir du vecteur d'entrée X , au vecteur de sortie A .

$$X = (x_1, \dots, x_N) \text{ et } A = (a_1, \dots, a_m).$$

Pour cela, nous disposons d'une base d'apprentissage appelée aussi jeu d'apprentissage et comportant un ensemble de vecteurs X_m et A_m , m étant le nombre de jeux d'apprentissage. L'apprentissage supervisé consiste, pour chaque jeu, à évaluer les paramètres w_i et b_i afin de minimiser l'erreur globale entre la sortie désirée et la sortie calculée par le réseau. L'étape ultime du réseau est son utilisation, nous présentons au réseau un jeu non appris X et par interpolation, si X ressemble à X_j , il aura l'étiquette A_j .




Figure II.11. Réseaux de neurones

Les sorties a_i sont données par :

$$a_m = f_2 (a_1^1 w_{m,1}^2 + a_2^1 w_{m,2}^2 + b_m^2) \quad (15)$$

Avec :

$$a_2^1 = f_1 (x_1 w_{2,1}^1 + + x_N w_{2,N}^2 + b_2^1)$$

$$a_1^1 = f_1 (x_1 w_{1,1}^1 + + x_N w_{1,N}^2 + b_1^1)$$

II.3.1. Réseau à rétro propagation de l'erreur (BP)

Ce réseau appelé Back propagation (BP) comporte trois couches : une couche d'entrée, une couche cachée et une couche de sortie. La fonction d'activation utilisée dans la couche cachée est du type sigmoïde (cf. Figure II.12) :

$$f_1(x) = \frac{e^{kx} - 1}{e^{kx} + 1} \quad (16)$$




Figure II.12. Fonction d'activation de la couche cachée du réseau BP

En utilisation courante, la fonction d'activation sur la couche de sortie est prise du type linéaire $y = x$.

En présentant le premier jeu d'apprentissage et après initialisation aléatoire des biais et poids de connexion, le réseau calcule la sortie a_i . Par la suite, cette dernière est comparé avec la sortie désirée s_i , en calculant l'erreur quadratique :

$$E = \sum_{i=1}^m (a_i - s_i)^2$$

(17)

L'erreur est alors rétro propagée dans le réseau par modification de ses paramètres en utilisant la descente en gradient :

$$w_{ij}^k(t) = w_{ij}^k(t-1) - e(k) \frac{\partial E}{\partial w_{ij}} \quad (18)$$

$e(k)$ est le pas du gradient à l'étape k du réseau.

Le processus est renouvelé à chaque présentation d'un nouvel exemple d'apprentissage par modification itérative des poids w_i et b_i jusqu'à ce que le réseau converge.

II.3.2 Réseau à fonctions à base radiale (RBF)

Ce réseau appelé radial basis function (RBF) est un réseau à rétro propagation de l'erreur dont la fonction d'activation de la couche cachée est une gaussienne (cf. Figure II.13) :

$$f_1(x) = \exp \left[-\frac{(x - c_j)^T (x - c_j)}{2\sigma_j^2} \right], \quad j = 1, \dots, N_c \quad (19)$$

N_c est le nombre de neurones sur la couche cachée.

$2\sigma_j^2$ Caractérise l'aplatissement de la gaussienne, caractérisant par conséquent la variance.

c_j désigne le centre de la fonction d'activation du neurone radiale pris habituellement égal à w_i .

Nous avons donc :

$$f_1(x) = \exp \left[-\frac{\|x_i - w_{ij}\|^2}{2\sigma_j^2} \right], \quad j = 1, \dots, N_c \text{ et } i = 1, \dots, N \quad (20)$$

$\| \cdot \|$ Représente la norme euclidienne et N , le nombre de neurones de la couche d'entrée.

Contrairement aux neurones sigmoïdes, les neurones radiaux travaillent localement permettant de réduire considérablement la taille des calculs et de traiter ainsi des problèmes avec une entrée du réseau comportant plusieurs neurones.




Figure II.13. Fonction d'activation de la couche cachée du réseau RBF

Chapitre III. EXPLOITATION NUMERIQUE

III.1 Système défectueux simulé numériquement

Afin de mettre en évidence la capacité de la technique neuronale à remonter aux défauts à diagnostiquer, nous avons jugé utile de faire cette première évaluation par simulation numérique de défauts. Nous simulons un banc d'essai (cf. Figure III.14) et nous injectons dans les signaux un défaut de roulement sous forme de choc et un défaut de denture sur les pignons 1 et 2.




Figure III.14. Banc d'essai simulé

Caractéristiques :

Fréquence de rotation du moteur : $f_M = 100 \text{ Hz}$

Nombre de dents du pignon 1 : $z_1 = 60 \text{ dents}$; $f_1 = 100 \text{ Hz}$

Nombre de dents du pignon 2 : $z_2 = 30 \text{ dents}$; $f_2 = 200 \text{ Hz}$

Fréquence d'engrènement : $f_e = 6000 \text{ Hz}$

Fréquence de résonance du roulement défectueux : $f^* = 2900 \text{ Hz}$

Les signaux de défauts simulés sont donnés par l'expression suivante :

$$x(t) = \left(\sum_{i=1}^k A_i \sin(2\pi f_i t) \right) + \left(\int_0^t B \exp\left(\frac{-1}{\tau_{rel} (1-\zeta)}\right) \sin(2\pi f_{res} (t-\zeta)) \sum_{n=0}^{N_{imp}} \delta(t-\zeta) d\zeta \right) \quad (21)$$

La première partie génère un spectre de raies, correspondant à la fréquence de rotation de la roue portant le défaut et ses 17 harmoniques, permettant de simuler un défaut de denture caractérisé par un signal périodique dont la fondamentale correspond à la fréquence de rotation du pignon défectueux. La deuxième partie génère un choc périodique qui simule un défaut de roulement de fréquence de résonance f_{res} , τ_{rel} étant le temps de relaxation, N_{imp} le nombre d'impacts et ζ l'amortissement.

L'entrée du réseau est constitué du signal échantillonné (cf.figure III.15) avec les variations des valeurs A_i et B en fonction du défaut simulé.




Figure III.15. Signal échantillonné

Les défauts simulés sont du type usure d'une dent sur chaque pignon (1 et 2) et du type rayure sur la bague extérieure pour le roulement 1. Les défauts seront appliqués sur chaque élément de façon indépendante, allant d'un défaut naissant jusqu'à son aggravation. Ensuite nous procédons à une combinaison simultanée des défauts de roulement et d'engrenage.

Une grande partie de ces signaux simulés servira à générer les signaux utilisés comme jeux d'apprentissage et une autre partie servira à tester le réseau.

Tableau1. Défauts simulés

Défauts simulés
Pignon1 (100 Hz)
Pignon 2 (200 Hz)
Roulement 1
Fréquence de résonance : 2900 Hz

La sortie est binaire, 1 caractérise la présence d'un défaut et 0 l'absence de défaut. Le nombre de neurones sur la couche de sortie est en fonction du nombre de défauts à diagnostiquer. Les jeux d'apprentissage et leurs sorties correspondantes sont donnés par le tableau2 :

Tableau 2. Défauts simulés et neurones associés

	Neurones de la couche de sortie
Normal (sans défauts)	(1 ; 0 ; 0 ; 0 ; 0 ; 0)
Défaut de pignon 1	(0 ; 1 ; 0 ; 0 ; 0 ; 0)
Défaut de pignon 2	(0 ; 0 ; 1 ; 0 ; 0 ; 0)
Défaut bague extérieure du roulement1	(0 ; 0 ; 0 ; 1 ; 0 ; 0)
Défaut de pignon 1 + roulement1	(0 ; 0 ; 0 ; 0 ; 1 ; 0)
Défaut de pignon 2 + roulement1	(0 ; 0 ; 0 ; 0 ; 0 ; 1)

Pour générer les signaux, nous avons adopté les valeurs de A_i et B comme suit :

- Normal (sans défaut) :

Roulement : $B = 0$. et $B = 0.2$

Engrenages : $A_1 = 0.4$ ses harmoniques sont d'amplitudes nulles

- Défaut de roulement :

02 dégradations : $B = 0.3$ et $B = 0.5$

- Défaut d'engrenage1 :

1ère dégradation :

$$A_i^I = (1.5, 1., 1.1, 1.2, 1.3, 1.2, 1.1, 1., 1.1, 1.2, 1.3, 1.2, 1.1, 1., 1.1, 1.2, 1.3, 1.2)$$

2ème dégradation :

$$A_i^{II} = (1.9, 1.4, 1.5, 1.6, 1.7, 1.6, 1.5, 1.4, 1.5, 1.6, 1.7, 1.6, 1.5, 1.4, 1.5, 1.6, 1.6)$$

- Défaut d'engrenage1 et roulement : C'est une combinaison du groupe défaut roulement et du groupe défaut engrenage 1

Nous ferons de même pour le défaut d'engrenage 2 et roulement. La combinaison de ces groupes de signaux nous a permis de simuler 32 signaux différents pour l'apprentissage et 6 signaux pour tester le réseau. Les signaux utilisés pour l'apprentissage et le test du réseau ont la forme illustrée par la figure III.16 et la figure III.17.




Figure III.16. Signal simulé et son spectre pour la configuration sans défaut




Figure III.17. Signal simulé et son spectre avec défaut de denture sur pignon

Pour mettre en œuvre l'approche neuronale, Nous comparons deux types de réseau : le réseau à rétro propagation de l'erreur (BP) et le réseau à fonction à bases radiales (RBF).

III.2 Réseau à rétro propagation de l'erreur (BP)

Ce réseau très utilisé pour résoudre certains problèmes mécaniques, pose néanmoins certaines difficultés dans sa mise en œuvre. Les difficultés concernent le nombre de neurones sur la couche caché et le nombre de neurones sur la couche d'entrée. Ce dernier est déterminé par la fréquence d'échantillonnage utilisée et qui détermine le nombre d'échantillons du signal à traiter, le signal étant celui simulé ou mesuré et qui détermine ainsi le taux d'apprentissage.

Une étude paramétrée a été faite pour optimiser le nombre de neurones sur la couche cachée ainsi que le nombre de neurones sur la couche d'entrée.

A titre indicatif, pour optimiser ces deux paramètres, des études peuvent être menées en utilisant des méthodes se basant sur la logique floue (Fuzzy logic) [38], le neuro_floue [39] ou les algorithmes génétiques [40] et [41].

III.2.1 Influence du nombre de neurones sur la couche cachée

Trois signaux ont été retenus pour chaque groupe (normal, défaut de pignon1, défaut de pignon2, défauts de pignon 1 + roulement et défauts de pignon 2 + roulement) pour tester le réseau ; les autres ont été utilisés pour l'apprentissage. Les calculs ont été menés séparément avec et sans bruit de fond. Nous avons utilisé en premier lieu cinq (05) neurones dans la couche cachée par la suite dix (10) neurones et enfin vingt (20) neurones sur la couche cachée. Trois cents (300) itérations ont été prévues pour atteindre la cible (convergence du réseau) avec une erreur de 10^{-4} .

1. Cas de cinq neurones sur la couche cachée

Les résultats montrent que le réseau ne converge pas (cf. figure III.18), le nombre de neurones sur la couche cachée étant largement insuffisant et ce à partir de la septième itération.




Figure.III.18 Convergence du réseau dans le cas de 5 neurones dans la couche cachée sans bruit de fond

En effet, le tableau 3 illustrant l'activation des neurones de sortie dans le cas sans bruit de fond en utilisant les signaux non injectés dans la base d'apprentissage, montre des résultats erronés quant à la capacité du réseau à remonter aux défauts. Nous constatons que des neurones qui devaient converger vers zéro sont activés. Le cas avec bruit de fond (signaux chahutés), correspondant en pratique au cas de vitesse de rotation élevé ou au cas non lubrifié, complique encore plus l'identification des défauts.

Tableau 3. Jeux de test et leurs neurones de sortie sans bruit de fond – 5 neurones dans la couche cachée

Groupe de signaux	Amplitudes	Sorties du réseau sans bruit de fond
<i>Normal</i>	$B = 0.05$; $A_i = 0.4$	(0.3 ; 0.8 ; 0.1 ; 0.3 ; 0.02 ; 0.4)
	$B = 0.10$; $A_i = 0.4$	(0.5 ; 0.2 ; 0.5 ; 0.9 ; 0.03 ; 0.4)
	$B = 0.25$; $A_i = 0.4$	(0.6 ; 0.6 ; 0.01 ; 0.9 ; - 0.3 ; 0.7)
<i>Défaut Eng1</i>	$A_i = A_i^I + 0.1$; $B = 0.05$	(0.6 ; 0.5 ; 0.1 ; 0.03 ; 0.5 ; 0.6)
	$A_i = A_i^I + 0.2$; $B = 0.10$	(0.6 ; 0.4 ; 0.5 ; 0.9 ; 0.02 ; - 0.8)
	$A_i = A_i^I + 0.3$; $B = 0.25$	(0.1 ; 0.2 ; 0.5 ; 0.01 ; - 0.2 ; 0.5)
<i>Défaut Eng2</i>	$A_i = A_i^I + 0.1$; $B = 0.05$	(0.6 ; 0.02 ; 0.1 ; 0.6 ; 0.5 ; 0.9)
	$A_i = A_i^I + 0.2$; $B = 0.10$	(- 0.6 ; 0.3 ; 0.5 ; 0.2 ; 0.7 ; 0.5)
	$A_i = A_i^I + 0.3$; $B = 0.15$	(0.3 ; 0.7 ; 0.6 ; 0.5 ; 0.9 ; 0.6)
<i>Eng1 + roul</i>	$A_i = A_i^I + 0.1$; $B = 0.35$	(0.5 ; 0.2 ; 0.8 ; - 0.8 ; 0.4 ; 0.1)
	$A_i = A_i^I + 0.2$; $B = 0.40$	(0.7 ; 0.5 ; 0.03 ; 0.02 ; 0.2 ; - 0.8)
	$A_i = A_i^I + 0.3$; $B = 0.45$	(0.8 ; 0.3 ; 0.1 ; 0.03 ; 0.5 ; 0.9)
<i>Eng2 + roul</i>	$A_i = A_i^I + 0.1$; $B = 0.35$	(0.6 ; 0.8 ; - 0.4 ; 0.3 ; 0.8 ; 0.5)
	$A_i = A_i^I + 0.2$; $B = 0.40$	(0.1 ; 0.7 ; 0.01 ; 0.6 ; 0.1 ; 0.2)
	$A_i = A_i^I + 0.3$; $B = 0.45$	(0.9 ; 0.5 ; - 0.3 ; 0.01 ; 0.8 ; 0.3)

2. Cas de dix neurones sur la couche cachée

La figure III.19 montre que le réseau converge mieux que précédemment à partir de la vingt cinquième itération, le nombre de neurones sur la couche cachée étant suffisant.




Figure.III.19 Convergence du réseau dans le cas de 10 neurones dans la couche cachée sans bruit de fond

En effet, le tableau le tableau 4 illustrant l'activation des neurones de sortie dans le cas sans et avec bruit de fond en utilisant les signaux non injectés dans la base d'apprentissage, montrent de meilleurs résultats que le cas avec cinq (10) neurones sur la couche cachée quant à la capacité du réseau à identifier la nature du défaut. Nous constatons que seuls les neurones correspondant aux défauts simulés sont activés. Les autres étant faiblement activés.

Néanmoins, le cas avec bruit de fond (signaux chahutés) du type gaussien , correspondant en pratique au cas de vitesse de rotation élevé ou au cas non lubrifié, complique encore plus l'identification des défauts.

Tableau 4. Jeux de test et leurs neurones de sortie avec et sans bruit de fond - 10 neurones dans la couche cachée

Groupe de signaux	Amplitudes	Sorties du réseau sans bruit de fond	Sorties du réseau avec bruit de fond
Normal	B = 0.05 B = 0.10 B = 0.25	(0.8 ; 0.2 ; 0.1 ; 0.3 ; 0.2 ; 0) (0.7 ; 0.1 ; 0.1 ; 0.3 ; 0.1 ; 0.1) (0.6 ; 0.1 ; 0.2 ; <u>0.4</u> ; 0.1 ; 0.2)	(0.5 ; 0.7 ; 0.3 ; 0.6 ; 0.7 ; 0.6)
Défaut Pig1	$A_i = A_i^I + 0.1$; B = 0.05 $A_i = A_i^I + 0.2$; B = 0.10 $A_i = A_i^I + 0.3$; B = 0.25	(0.2 ; 0.9 ; 0.1 ; 0.2 ; 0.1 ; 0.1) (0.1 ; 0.9 ; 0.2 ; 0.1 ; 0.2 ; 0.1) (0.2 ; 0.8 ; 0.1 ; 0 ; <u>0.3</u> ; 0.1)	
Défaut Pig2	$A_i = A_i^I + 0.1$; B = 0.05 $A_i = A_i^I + 0.2$; B = 0.10 $A_i = A_i^I + 0.3$; B = 0.15	(0.2 ; 0.1 ; 0.9 ; 0.1 ; 0.1 ; 0.1) (0.1 ; 0.1 ; 0.8 ; 0.3 ; 0.2 ; 0.1) (0.1 ; 0.2 ; 0.8 ; 0.3 ; 0.1 ; 0.1)	
Pig1 + roul	$A_i = A_i^I + 0.1$; B = 0.35 $A_i = A_i^I + 0.2$; B = 0.40 $A_i = A_i^I + 0.3$; B = 0.45	(0.1 ; <u>0.3</u> ; 0.2 ; 0.1 ; 0.7 ; 0) (0.2 ; <u>0.3</u> ; 0 ; 0 ; 0.8 ; 0.1) (0 ; <u>0.2</u> ; 0 ; 0.2 ; 0.8 ; 0.1)	(0.6 ; 0.4 ; 0.1 ; 0.6 ; 0.5 ; 0.3)
Pig2 + roul	$A_i = A_i^I + 0.1$; B = 0.35 $A_i = A_i^I + 0.2$; B = 0.40 $A_i = A_i^I + 0.3$; B = 0.45	(0 ; 0.1 ; <u>0.2</u> ; 0.1 ; 0.1 ; 0.7) (0.1 ; 0 ; <u>0.3</u> ; 0.2 ; 0 ; 0.9) (0.1 ; 0.1 ; <u>0.3</u> ; 0.1 ; 0.1 ; 0.8)	

A la lecture de ces résultats nous montrons que le neurone correspondant au défaut simulé, et ce pour chaque groupe de signaux, commence à s'activer. Ces résultats sont valables pour des signaux sans bruit de fond. Ce qui n'est pas le cas des signaux perturbés par un bruit de fond. En effet, tous les neurones sont fortement activés, entraînant ainsi une identification erronée.

Le résultat le plus intéressant est illustré par le premier groupe des signaux (normal), dans le troisième signal correspondant au signal sans défaut nous injectons un défaut de roulement naissant dont l'amplitude est inférieure à celle correspondant au défaut de roulement. Nous constatons que le neurone 4 de sortie n'est pas totalement activé pour indiquer l'apparition du défaut de roulement mais le réseau a tendance beaucoup plus à

indiquer un cas sans défaut (normal). La même chose est constatée dans les cas Engrenage1 + Roulement et Engrenage2 + Roulement. En effet, le réseau a tendance à identifier un défaut d'engrenage 1 ou un défaut d'engrenage 2 (neurones 5 ou 6 activés) au lieu d'activer le neurone 4.

3. Cas de Vingt neurones sur la couche cachée

La figure III.20 montre que le réseau converge à partir de la dix huitième itération, le nombre de neurones sur la couche cachée étant largement suffisant.




Figure.III.20 Convergence du réseau dans le cas de 20 neurones dans la couche cachée sans bruit de fond

Le cas de vingt neurones sur la couche cachée montre clairement que le réseau remonte au défaut simulé. En effet, à chaque le neurone correspondant au défaut simulé est fortement activé comme l'illustre le tableau 5 alors que les autres Par contre, malgré une légère amélioration, le problème persiste toujours pour le défaut Engrenage + Roulement.

En effet le neurone correspondant au défaut d'engrenage reste toujours légèrement activé et donc le réseau a tendance à identifier un défaut d'engrenage plutôt qu'un défaut Engrenage + Roulement

Pour le cas avec bruit de fond, le réseau n'arrive toujours pas à identifier clairement la nature du défaut simulé et ceci est d'autant plus vrai que le bruit de fond devient intense.

Tableau 5. Jeux de test et leurs neurones de sortie avec et sans bruit de fond - 20 neurones dans la couche cachée

Groupe de signaux	Amplitudes	Sorties du réseau sans bruit de fond	Sorties du réseau avec bruit de fond
Normal	$B = 0.10$; $A_i = 0.4$	(0.9 ; 0 ; 0 ; 0 ; 0 ; 0.)	(0.6 ; 0.3 ; 0.3 ; 0.2 ; 0.3 ; 0.4)
Défaut Eng1	$A_i = A_i^I + 0.3$; $B = 0.15$	(0 ; 1 ; 0 ; 0 ; <u>0.2</u> ; 0.)	
Défaut Eng2	$A_i = A_i^I + 0.3$; $B = 0.15$	(0 ; 0 ; 1 ; 0 ; 0.2 ; 0.1)	
Eng1 + roul	$A_i = A_i^I + 0.3$; $B = 0.45$	(0 ; <u>0.3</u> ; 0 ; 0 ; 0.8 ; 0.1)	(0.1 ; 0.4 ; 0.2 ; 0.2 ; 0.6 ; 0.3)
Eng2 + roul	$A_i = A_i^I + 0.3$; $B = 0.45$	(0. ; 0. ; <u>0.3</u> ; 0. ; 0. ; 0.8)	

En effet, la figure III.21 confirme bien qu'il ya une amélioration quant à la capacité du réseau BP à remonter au défaut simulé quand le nombre de neurone sur la couche cachée augmente. Néanmoins, cette aptitude à identifier le défaut diminue en présence d'un bruit de fond et plus particulièrement quand ce dernier devient intense.

Par contre, l'augmentation du nombre de neurones sur la couche cachée augmente le nombre d'itération nécessaires à la convergence ce qui fait accroître, considérablement, le temps de calcul.

Après avoir vu l'influence du nombre de neurones sur la couche cachée, il serait intéressant d'étudier la convergence du réseau en fonction du nombre de neurones sur la couche d'entrée.




Figure.III.21 Taux global de détection en fonction du nombre de neurone sur la couche cachée

III.2.2 Nombre de neurones sur la couche d'entrée

Le nombre de neurones sur la couche d'entrée représente au fait le nombre d'échantillons du signal à introduire au réseau. Ce nombre dépend bien sûr de la fréquence d'échantillonnage des signaux simulés à introduire lors de l'apprentissage. Le nombre de neurones sur la couche cachée utilisé dans le cas présent étant de 20 neurones, compte tenu de l'étude effectuée précédemment. La durée du signal étant de 10 secondes.

La figure III.22 représentant le taux de détection global du réseau BP, utilisant 20 neurones sur la couche cachée, en fonction du nombre de neurone sur la couche d'entrée caractérisant le nombre d'échantillons du signal simulé, montre que la capacité du réseau à remonter au défaut augmente avec le nombre d'échantillons et donc le nombre de neurones dans la couche d'entrée augmente avec l'accroissement de la fréquence d'échantillonnage pour une durée du signal identique. Néanmoins, le réseau BP reste toujours incapable d'identifier le défaut en présence d'un bruit de fond et ceci est d'autant plus vrai que le bruit de fond devient plus intense.




Figure.III.22 Taux global de détection en fonction du nombre de neurones sur la couche d'entrée -cas de vingt neurones sur la couche cachée-

La figure montre aussi qu'à partir d'un certain nombre de neurones élevé (autour de 2000 échantillons) sur la couche d'entrée et donc à partir d'une certaine cadence d'échantillonnage le réseau devient pratiquement incapable d'identifier le défaut, ceci s'explique par le phénomène du sur-apprentissage [42]. D'ailleurs la figure III.23 illustrant la convergence du réseau pour le cas, sans bruit de fond avec 20 neurones sur la couche cachée et 4096 neurones sur la couche d'entrée, montre clairement que le réseau ne converge pas et ce à partir de la huitième itération.




Figure.III.23 Convergence du réseau dans le cas de 20 neurones dans la couche cachée 4096 neurones sur la couche d'entrée. Cas de sans bruit de fond

Bien que le réseau à rétro propagation de l'erreur (BP) soit très utilisé dans la classification, comme nous venons de le voir dans notre cas, il n'est pas adapté du tout en présence d'un bruit de fond. En effet, le réseau ne classe pas les défauts en présence d'un bruit de fond (même modéré), ce qui rend toute identification impossible. En plus, l'inconvénient le plus contraignant est qu'il utilise une mémoire très importante du fait que tous les neurones sont activés ; dans notre cas nous avons utilisé 2048 échantillons pour chaque signal. Le réseau RBF, travaillant localement, permet de traiter des signaux de taille plus importante.

Avant de mettre en œuvre ce type de réseau, nous avons jugé intéressant d'utiliser les moments d'ordre n dans notre cas les premiers moments (cumulants) : M_1 , M_2 , M_3 et M_4 . L'auteur de référence bibliographique [31] a utilisé les quatre premiers moments déterminés à partir des échantillons du signal, comme entrée du réseau et ce pour diminuer dans un premier temps le nombre de neurones sur la couche d'entrée dans le souci de rapidité du traitement. Et dans un deuxième temps pour diminuer l'effet du bruit de fond. Cette méthode a été utilisée sur un réducteur à un étage pour identifier des

défauts d'engrenage uniquement. Nous avons tenté de l'appliquer dans notre cas aux défauts combinés.

Pour illustrer ce cas, nous avons adopté 20 neurones sur la couche cachée et 4 neurones sur la couche d'entrée correspondant à M_1 , M_2 , M_3 et M_4 . A titre indicatif le moment d'ordre n est donné par :

$$M_n = \frac{1}{T} \int_0^T X(t)^n dt$$

En discret, nous obtenons :

$$M_n = \frac{1}{N} \sum_{i=1}^N X_i^n$$

Où X_i représente les échantillons du signal et N le nombre d'échantillons suite à l'échantillonnage du signal.

Les résultats obtenus n'ont pas été du tout satisfaisant du fait qu'il faut une base de données très riche à savoir un nombre de signaux pour l'apprentissage du réseau très élevé car le nombre de neurones sur la couche d'entrée étant faible (4 neurones). Même si c'est faisable en simulation par contre dans la réalité (en pratique sur une machine tournante) il sera difficile de constituer une base de données suffisante pour l'apprentissage du réseau. Bien que l'auteur de la référence bibliographique [31] l'ait utilisé pour des défauts d'engrenages et a donné des résultats satisfaisants, ce n'est pas le cas pour des défauts combinés.

En effet le tableau 6 illustrant le test du réseau pour des défauts accentués, seuls et combinés : défauts sur le roulement1 (défaut bague extérieure) et pignon 2, montre clairement que le réseau ne converge pas et ne remonte pas aux défauts simulés. Les résultats présentés dans ce tableau correspondent au cas sans bruit de fond en utilisant les quatre premiers moments comme entrée du réseau avec 32 signaux injectés pour

l'apprentissage, ce qui n'est pas mal comme base de données.

Tableau 6. Jeux de test et leurs neurones de sortie sans bruit de fond - 20 neurones dans la couche cachée, M_1 , M_2 , M_3 et M_4 comme entrée du réseau

Groupe de signaux	Sorties du réseau sans bruit de fond
Défaut Pignon 2	(0.5 ; 0.2 ; -0.6 ; 0 ; 0.8 ; 0.1)
Défaut Roulement 1	(-0.5 ; 0.8 ; 0.3 ; 0.4 ; 0.2 ; 0.1)
Défaut roulement1+Pignon2	(0.7 ; 0.3 ; 0 ; 0.4 ; 0.8 ; 0.1)

Comme nous venons de le montrer à travers l'étude menée sur le réseau à rétro propagation de l'erreur ou back propagation (BP), ce dernier n'arrive pas à classer correctement les défauts combinés et donc de remonter aux défauts simulés dans le cas de signaux chahutés (présence de bruit de fond). De plus, une base de donnée (jeux d'apprentissage) importante est nécessaire pour l'apprentissage du réseau ce qui fait augmenter d'une façon considérable le temps de calcul. La plupart des documents consultés [43], [44] conseillent d'utiliser dans ce cas le réseau fonction à bases radiales qui présentent une meilleure souplesse notamment en ce qui concerne le nombre de neurones sur la couche cachée qui dans ce cas est optimisé directement par ce réseau.

III.3 Réseau à fonctions à base radial (RBF)

Ce réseau comme nous le verrons présente une meilleure aptitude de classification des défauts et donc une meilleure capacité à identifier les défauts même en présence de bruit de fond. Travaillant localement, ce qui n'est pas le cas pour le réseau BP, le réseau RBF présente l'avantage de pouvoir utiliser un nombre important de neurones sur la couche d'entrée et donc d'utiliser des signaux à très forte cadence d'échantillonnage lors de l'apprentissage.

Le nombre de neurones sur la couche cachée est déterminé automatiquement par le réseau pour permettre une convergence rapide et efficace du réseau [46] et [47].

Avant d'exploiter ce réseau, il serait intéressant de faire une étude paramétrée sur l'aplatissement σ^2 de la gaussienne (cf. Eq. 20 Chap. II.3.2) de la fonction de transfert utilisée dans le réseau RBF ; une étude sera menée aussi pour étudier l'influence de la fréquence d'échantillonnage des signaux utilisés lors de l'apprentissage sur la convergence du réseau.

Les résultats obtenus seront par la suite comparés avec ceux obtenus avec le réseau BP afin de choisir le réseau le plus adapté lors de l'analyse expérimentale et afin aussi de définir les limites de l'approches neuronale quand nous traitons ce type de problèmes.

Pour les applications qui vont suivre, trois signaux ont été retenus pour chaque groupe (normal, défaut pignon1 et défaut pignon 1 + roulement) pour tester le réseau. Les calculs ont été menés séparément avec et sans bruit de fond. Vingt (20) neurones sur la couche cachée ont été nécessaires pour atteindre la cible avec une erreur de 10^{-4} .

II.3.1 Influence du coefficient d'aplatissement de la gaussienne de la fonction de transfert

Au fait si nous regardons plus en détail le rôle de la fonction de transfert dans le réseau et plus particulièrement au niveau de la couche cachée, elle agit comme un filtre local à chaque neurone et c'est celle qui détermine si le neurone s'active ou pas pour permettre au réseau de converger vers la sortie désirée. Cette fonction au niveau du réseau RBF est une gaussienne, il nous semble intéressant de voir l'influence du coefficient d'aplatissement σ^2 (cf. Annexe 1) de cette dernière qui n'est autre que la bande passante.

Pour évaluer l'influence de l'aplatissement de la gaussienne, sur la convergence du réseau, de la fonction de transfert utilisée dans le réseau RBF, nous avons adopté 4096

neurones sur la couche d'entrée correspondant à 4096 points sur chaque signal lors de l'apprentissage et le test du réseau. En effet, le réseau RBF permet comme nous l'avons cité auparavant d'intégrer de grandes capacités de calcul à la différence du réseau BP. Le calcul a été fait sans et avec bruit de fond modéré. Nous avons présenté uniquement les résultats pour le cas du défaut sur Pignon1+ roulement puisque c'est le cas qui présente le plus de problèmes de convergence. L'erreur est calculée sur le quatrième neurone de la couche de sortie correspondant au défaut Roulement + Pignon1 (cf. Tableau2, p33).




Figure.III.24. Erreur relative commise sur la détection du défaut de Roulement+Pignon1 en fonction de l'aplatissement σ^2

La figure III.24 montre clairement que pour des aplatissements σ^2 faible le réseau ne converge pas, l'erreur pouvant atteindre 90%. Par contre pour des coefficients d'aplatissements compris entre 40 et 48 l'erreur est inférieure à 5% même dans le cas avec bruit de fond modéré, ce qui est appréciable pour la détection de ce type de défaut. Pour les calculs que nous aborderons par suite nous adoptons un coefficient d'aplatissement de $\sigma^2 = 48$. Nous constatons aussi que la capacité du réseau à remonter au défaut s'améliore en présence d'un bruit de fond. Ce qui n'était pas le cas du réseau à retro propagation BP.

II.3.2 Influence de la fréquence d'échantillonnage

L'influence de la fréquence d'échantillonnage ou du nombre de points sur chaque signal échantillonné sur la convergence du réseau n'est autre que l'influence du nombre de neurones de la couche d'entrée. Les calculs ont été menés sans bruit de fond avec 512, 1024 et 4096 points sur chaque signal.

Après convergence du réseau, nous reportons le taux de détection déterminant l'activation des neurones : 2 , 4 et 5 de la couche de sortie correspondant respectivement aux défauts de pignon 1, Roulement et Pignon1+Roulement (cf. Tableau2).




Figure.III.25. Taux de détection en fonction de la fréquence d'échantillonnage

La figure III.25 illustrant le taux de détection en fonction du nombre de neurones sur la couche d'entrée montre clairement que le taux de détection augmente avec l'accroissement de la fréquence d'échantillonnage. Nous constatons aussi qu'il y a une nette amélioration de la détection des défauts en présence d'un bruit de fond ce qui n'était pas le cas du réseau BP. Certes, le bruit de fond n'est pas intense, néanmoins, le

taux global de détection est conséquent même dans le cas d'un défaut combiné : Roulement + Pignon1.

II.3.3 Test du réseau RBF

Pour tester le réseau et évaluer ainsi la capacité du réseau à remonter aux défauts simulés et plus particulièrement en présence de défauts combinés, nous avons utilisé 32 signaux simulés : 26 signaux ont été utilisés pour l'apprentissage du réseau et 6 signaux pour tester le réseau. Les résultats montrés ici ne concernent que les cas sans défauts (Normal), Pignon1 et pignon 1 + Roulement car le cas qui pose le plus de problème est le cas de défauts combinés.

Le nombre d'échantillons traités sur chaque signal est de 2048 points correspondant donc à 2048 neurones sur la couche d'entrées. Pour la convergence du réseau, vingt (20) neurones ont été nécessaires sur la couche cachée pour atteindre la cible avec une erreur de $e = 10^{-4}$. Le coefficient d'aplatissement adopté dans la fonction de transfert de la fonction à Bases radiales est $\sigma^2 = 48$. Nous rappelons que le nombre neurones sur la couche de sortie est de six (06) neurones (cf. Tableau2, p33).

Les résultats obtenus ont été satisfaisants, notamment concernant le cas avec bruit de fond et plus particulièrement pour les défauts combinés.

En effet, nous avons une meilleure classification que dans le cas du réseau BP (Back Propagation), les autres neurones n'étant pas activés. Le tableau 7 montre que le réseau arrive à détecter un défaut de roulement naissant, le neurone 4, correspondant au défaut de roulement est faiblement activé pour le troisième signal du groupe normal. De la même façon est détecté un défaut d'engrenage naissant, le neurone 2, correspondant aux signaux du troisième groupe sont faiblement activés.

En introduisant un bruit de fond intense dans les signaux (cf. Tableau 7), le réseau

arrive à classer les défauts avec une assez bonne approximation, à la différence du réseau BP.

Tableau7. Jeux de test et leurs neurones de sortie avec et sans bruit de fond

Groupe de signaux	Amplitudes	Sorties du réseau sans bruit de fond	Sorties du réseau avec bruit de fond intense
Normal	$B = 0.05$	(1. ; 0 ; 0 ; 0 ; 0 ; 0)	(0.8 ; 0 ; 0 ; 0.2 ; 0. ; 0.)
	$B = 0.10$	(0.9 ; 0 ; 0 ; 0 ; 0 ; 0)	(0.7 ; 0 ; 0 ; 0.3 ; 0. ; 0.)
	$B = 0.25$	(0.7 ; 0 ; 0 ; <u>0.3</u> ; 0 ; 0)	(0.6 ; 0 ; 0 ; <u>0.4</u> ; 0. ; 0.)
Défaut Pignon 1	$A_i = A_i^I + 0.1 ; B = 0.05$	(0 ; 0.9 ; 0 ; 0 ; 0 ; 0)	(0.1 ; 0.8 ; 0 ; 0 ; 0.3 ; 0)
	$A_i = A_i^I + 0.2 ; B = 0.10$	(0 ; 0.9 ; 0 ; 0 ; 0 ; 0)	(0.1 ; 0.8 ; 0 ; 0 ; 0.3 ; 0)
	$A_i = A_i^I + 0.3 ; B = 0.25$	(0 ; 0.8 ; 0 ; 0 ; <u>0.2</u> ; 0)	(0.1 ; 0.7 ; 0 ; 0 ; <u>0.4</u> ; 0)
Pignon1 + roulement	$A_i = A_i^I + 0.1 ; B = 0.35$	(0 ; 0 ; 0 ; 0 ; 1. ; 0)	(0.1 ; 0.5 ; 0 ; 0 ; 0.6 ; 0)
	$A_i = A_i^I + 0.2 ; B = 0.40$	(0 ; 0 ; 0 ; 0 ; 1. ; 0)	(0.1 ; 0.4 ; 0 ; 0 ; 0.7 ; 0)
	$A_i = A_i^I + 0.3 ; B = 0.45$	(0 ; 0 ; 0 ; 0 ; 1. ; 0)	(0.1 ; 0.4 ; 0 ; 0 ; 0.75 ; 0)

La figure III.26. Illustrant le taux de détection pour chaque défaut, montre bien que le réseau remonte au défaut simulé puisqu'à chaque fois le neurone correspondant à ce dernier est nettement activé.




Figure III.26. Taux de détection des défauts simulés

En comparant les réseaux RBF et BP (rétro propagation), comme l'illustre le tableau 8, nous constatons que le réseau RBF est mieux adapté à notre cas et présente une meilleure classification que le réseau BP.

Tableau 8. Comparaison des réseaux RBF et BP en présence d'un bruit de fond.

signaux	Amplitude	Sorties du réseau
BP Normal	B = 0.10	(0.5 ; 0.7 ; 0.3 ; 1.1 ; 1.7 ; 0.6)
RBF		(0.7 ; 0 ; 0 ; 0.3 ; 0. ; 0.)
BP Eng1 + Roul	$A_i = A_i^I + 0.3$; B = 0.45	(1.1 ; 0.4 ; 0.1 ; 1.6 ; 0.5 ; -0.7)
RBF		(0.2 ; 0.3 ; 0 ; 0 ; 0.75 ; 0)

En conclusion, l'étude a montré que le réseau RBF est beaucoup plus adapté aux signaux noyés dans un bruit de fond, ce qui est le cas dans la réalité, et permet surtout de traiter des signaux échantillonnés finement permettant ainsi d'injecter dans le réseau des signaux comportant un nombre important d'échantillons dans la phase d'apprentissage.

Il reste à confirmer ces résultats, en les confrontant à un cas réel. Pour se faire, un banc d'essai a été réalisé permettant de générer des défauts réels.

Chapitre IV. ANALYSE EXPERIMENTALE

IV.1 Introduction

Bien que les résultats obtenus sur des signaux simulés soient assez satisfaisant pour le réseau RBF, cette tendance doit être confirmée expérimentalement afin de déterminer aussi les limites de cette méthode.

Dans un premier temps nous utiliserons les signaux mesurés, avec et sans lubrification, comme entrée du réseau. Ce dernier cas correspond au cas le plus défavorable pour identifier les défauts sur une machine tournante. Par la suite nous utiliserons les spectres des signaux mesurés comme entrée du réseau. Ce cas est intéressant à voir car très souvent l'analyse spectrale est souvent insuffisante pour identifier des défauts et plus particulièrement les défauts de roulement et d'engrenage. En plus la mise en place d'autres méthodes de traitement de signal, telles que l'analyse d'enveloppe ou l'analyse cepstrale, reste assez fastidieuse et complexe.

IV.2 Description du banc d'essai et protocole expérimental

Le banc d'essai est constitué d'une transmission par engrenages à deux étages (cf. Figure IV.27), le tout capoté par une structure constitué de plaques en acier, le couvercle et une des faces sont en plexiglas pour permettre des mesures au vibromètre à laser. Les quatre pignons sont à dentures droites de module 2mm et un nombre de dents respectifs, de $z_1 = 45$, $z_2 = 65$, $z_3 = 50$ et $z_4 = 42$. Sur les six paliers, sont montés des roulements à une rangée de billes du type 6002.

Afin de générer les différents jeux d'apprentissage et ceux permettant de tester le réseau, nous simulons des défauts de dentures sous forme de rayure au niveau d'une dent

sur les pignons 1 et 3 (cf. Tableau 9) . Nous adoptons trois types de dégradations sur la roue 1 : modérée, accentuée et très accentuée ; sur le pignon 3, deux types de dégradations : modéré et accentué. De la même façon, nous simulons sur le roulement du palier P2 des défauts sur la bague intérieure et la bague extérieure sous forme de rayures sur chacune d'elles. Nous adoptons deux types de dégradations sur chacune des bagues : modérée et accentuée.

Avec une vitesse de rotation du moteur $n = 1800$ tr/mn, la combinaison de ces différents défauts nous a permis de générer 60 jeux – y compris le signal correspondant à la machine à l'état neuf - différents sous forme de signaux recueillis avec une fréquence d'échantillonnage $F_e = 48\,000$ Hz avec un temps d'acquisition $T = 10$ s. Cinquante jeux ont été retenus pour l'apprentissage et dix pour tester le réseau. L'accéléromètre permettant l'acquisition est placé sur le palier P2. Les signaux ou les jeux permettant de tester le réseau sont pris entre les limites supérieure et inférieure des jeux retenus pour l'apprentissage, le réseau interpole. Les mesures étant faites avec et sans lubrification afin d'évaluer les limites de la capacité du réseau à remonter aux défauts même dans le cas le plus défavorable correspondant au cas non lubrifié. Le banc d'essai est chargé par un frein magnétique afin que les vibrations soient mesurables.

Le type d'analyseur utilisé est un collecteur de données bi-voies illustrés par la figure 2 (cf. Annexe 1).




Figure IV 27. Banc d'essai (réducteur à deux étages)

Les signaux, utilisés pour l'apprentissage étant à très forte cadence d'échantillonnage, $F_e = 48\,000\text{ Hz}$ sur un temps d'acquisition $t = 10\text{ s}$ (cf. Figure IV 28), le réseau utilisé est du type RBF (radial basis function), de plus ce type de réseau est mieux adapté aux signaux en présence d'un fort bruit de fond, ce qui est le cas dans la réalité, comme nous l'avons vu précédemment.




Figure IV 28. Signal du défaut d'engrenage sur la roue 3 et sur la bague extérieure du roulement à $N = 1800\text{ tr/mn}$.

Pendant l'apprentissage, nous présentons au réseau les amplitudes du signal échantillonné, la sortie est binaire : **1** s'il y a défaut et **0** au contraire. La position du neurone activé est en fonction du type de défaut (cf. Tableau 10.).

Tableau 9. Défauts simulés

Défauts simulés
Pignon1 : 03 dégradations (modéré, accentué, aggravé)
Pignon 3 : 02 dégradations (modéré, accentué)
Roulement : palier P2
Défaut sur bague extérieure : 02 dégradations (modéré, accentué)

Vingt neurones sur la couche cachée ont été nécessaires pour la convergence du réseau, l'aplatissement de la gaussienne de la fonction de transfert de chaque neurone adopté est $\sigma^2=48$, selon l'étude faite précédemment. Le centre de la gaussienne $c_i = w_{ij}$, w_{ij} étant le poids des neurones (cf. Figure.II.10). Ce dernier est déterminé à chaque itération lors de la convergence du réseau.

Tableau 10. Jeux d'apprentissage et leurs sorties correspondantes

	Neurones de la couche de sortie
Normal (sans défauts)	(1 ; 0 ; 0 ; 0 ; 0)
Défaut d'engrenage 1	(0 ; 1 ; 0 ; 0 ; 0)
Défaut d'engrenage 3	(0 ; 0 ; 1 ; 0 ; 0)
Défaut roulement bague extérieure (BE)	(0 ; 0 ; 0 ; 1 ; 0)
Défaut d'engrenage 1 et roulement bague extérieur	(0 ; 0 ; 0 ; 0 ; 1)

IV.3 Détermination des fréquences propres de la structure (capotage)

La figure IV.29 montre le spectre du défaut d'engrenage sur le pignon 1, nous constatons des émergences spectrales autour de 750 Hz, 1100 Hz, 1600 Hz et 3000 Hz. Les mesures ont été effectuées sur le palier P2 (Cf. figure IV 27).





Figure IV.29. Spectres des défauts sur la roue1 à $n = 1800$ tr/mn

Ce spectre montre toute la difficulté du diagnostic en présence de fréquences émergentes liées à la réponse vibratoire de la structure d'accueil ; l'amplitude de ces fréquences augmente avec l'aggravation du défaut qui agit comme une force excitatrice.


Nous avons procédé à une analyse modale expérimentale pour identifier les fréquences et modes propres de la structure enveloppant le réducteur. Ces fréquences correspondent aux fréquences propres de la structure enveloppant le réducteur. La figure IV.30 illustrent les 4 modes propres sollicités lors de nos mesures vibratoires. Ces modes ont été obtenues par analyse modale expérimentale (mesures vibratoires en plusieurs points de l'enveloppe du réducteur). Le point d'excitation est une impulsion sur la plaque

en acier proche du palier P2, elle a été réalisée en utilisant un marteau d'impact (cf. Figure 1, Annexe1)


L'approche neuronale a l'avantage d'intégrer lors de l'apprentissage ces diverses informations liées aux fréquences propres de structures ou bien à un bruit de fond spécifique, pour en tenir compte dans la détection de nouvelles manifestations comme la naissance ou l'aggravation d'un défaut mécanique.




(a) 752 Hz



(b) 1100 Hz



(c) 1600 Hz



(d) 3000 Hz

Figure IV.30. Modes de vibrations de la structure enveloppant le réducteur

Nous présentons dans ce qui suit les résultats dans deux cas : à une vitesse de rotation du moteur $n = 1800$ tr/mn et par la suite à une vitesse de rotation $n = 3000$ tr/mn. La différence entre les deux vitesses est que le bruit de fond devient plus intense dans le deuxième cas. Nous présenterons par la suite le cas non lubrifié ce qui correspond à une présence très intense du bruit de fond. Nous voulons ainsi montrer les limites de la capacité de cette méthode à remonter au défaut en présence d'un bruit de fond. La lubrification est par barbotage.

IV.4 Cas lubrifié

Les figures IV.31, IV.32 et IV.33 montrent clairement l'évolution des indicateurs scalaires, Vitesse globale, RMS et Kurtosis, en fonction de l'aggravation des défauts simulés. Les cinq défauts ont été choisis parmi les défauts simulés pour l'apprentissage et le test du réseau.




Figure IV.31 Vitesse globale correspondant aux différents défauts simulés
à $n = 1800$ tr/mn




Figure IV.32 RMS correspondant aux différents défauts simulés à $n = 1800$ tr/mn

Ces valeurs présentées correspondent au cas où la vitesse de rotation de l'arbre $n = 1800$ tr/mn. Ce cas correspond au cas où le bruit de fond n'est pas intense.




Figure IV.33 Kurtosis correspondant aux différents défauts simulés à $n = 1800$ tr/m.

L'analyse des signaux mesurés, l'analyse d'enveloppe et l'analyse cepstrale (cf figures IV.34 et IV.35), ne permet pas l'identification des défauts simulés justifiant ainsi l'emploi de l'approche neuronale comme une des méthodes parmi d'autres pour remonter au défaut. Cette difficulté est notamment due au bruit de fond.




Figure IV.34. Spectre d'enveloppe dû aux différents défauts simulés à $n = 1800$ tr/mn

Ces deux figures correspondant au cas lubrifié montrent clairement que même l'emploi de l'analyse d'enveloppe pourtant très utilisée pour les défauts sous forme de chocs périodiques n'arrive pas à identifier clairement la nature du défaut. Le problème sera plus accentué dans le cas non lubrifié, comme nous le verrons par la suite.




Figure IV.35 Cepstre dû aux différents défauts simulés à $n = 1800$ tr/mn.

En effet, toute identification par les méthodes classiques de traitement de signal devient rigoureuse et difficile sans investigations supplémentaires tels que l'utilisation des transformées d'ondelettes (waveletts) par exemple. Cette dernière reste néanmoins, une

méthode fastidieuse et assez difficile à mettre en œuvre en pratique dans le cas de la maintenance en général.


Le tableau 11 montre les résultats obtenus en présentant au réseau les signaux de défauts non appris. Pour le cas normal (sans défaut ie état neuf) le neurone 1, lui correspondant, est activé alors que les autres ne le sont pas ce qui montre une bonne identification.

Nous obtenons des résultats identiques pour les autres types de défauts : Pignon1, Pignon3 et défaut de roulement. A chaque fois le neurone correspondant au type de défaut est activé. Néanmoins, en introduisant un défaut de roulement modéré seul, le réseau a tendance à détecter un cas sans défaut (neurone 1 fortement activé neurone 3 et neurone 4 faiblement activé). Par contre lorsque l'on introduit un défaut combiné roulement + Engrenage (ici Pignon1+Roulement), le réseau a tendance à détecter un cas avec défaut d'engrenage pour le deuxième cas et ce est d'autant plus vrai que le défaut de roulement est modéré et que le défaut d'engrenage est accentué (activation du neurone 2 au lieu du neurone 5).

La figure IV.36 représente le taux de détection pour chacun des cas traités. Elle montre clairement la capacité du réseau à remonter au défaut, néanmoins les résultats sont moins bons dans le cas de défauts combinés surtout lorsque le défaut de roulement est naissant que ce soit seul ou combiné. Néanmoins, il y a comme même activation du neurone correspondant au défaut recherché même si elle est faible. Il ya donc orientation du défaut à rechercher.

Tableau 11. Exemples testés et leurs neurones de sortie correspondants (n =1800 tr/mn)

Généralisation	Neurone 1	Neurone 2	Neurone 3	Neurone 4	Neurone 5
Normal	0.9194	0.1054	0.1052	0.1151	0.1109
Engrenage 1	0.1223	0.9017	-0.1117	0.1239	0.1109
Engrenage 3	0.1198	-0.1235	0.9526	0.1287	0.1184
Engrenage 3	-0.0101	0.0238	0.9367	0.0601	0.0001
Roulement BE modéré	0.6627	0.0277	0.0063	0.3016	0.0150
Roulement BE	0.1188	0.2275	0.1191	0.8871	0.1024
Roulement BE	0.1077	0.2254	0.0081	0.8702	0.1877
Engrenage1+ roulement BE	0.0912	<u>0.3912</u>	-0.1046	0.0991	0.6106
Engrenage1+ roulement BE	0.1702	<u>0.4702</u>	0.1113	0.1209	0.5642
Engr1+ roulement BE modéré	0.0208	0.7811	-0.0106	0.0219	0.2030

**Figure IV.36.** Taux de détection des défauts simulés (n = 1800 tr/mn)

L'augmentation de la vitesse de rotation du moteur $n = 3000$ tr/mn, génère ainsi un niveau vibratoire plus important comme le montre les figures 1, 2 et 3 (cf. Annexe 2) représentant les indicateurs scalaires : Vitesse globale, RMS et Kurtosis. L'augmentation de la vitesse de rotation du moteur conduit aussi à l'intensification du bruit de fond.

En effet, l'analyse d'enveloppe et l'analyse cepstrale ne permettent pas comme le montre les figures 4 et 5 (cf. Annexe 3) de faire une lecture rigoureuse et claire des défauts simulés.

La lecture du tableau 12 montre clairement l'activation des neurones 2 et 3 correspondant aux défauts des pignons 1 et 3, montrant ainsi la capacité du réseau (RBF) à remonter à ce type de défauts malgré la présence d'un bruit de fond plus intense par le passage la vitesse de rotation du moteur $n_{MOT} = 1800$ tr/mn à $n_{MOT} = 3000$ tr/mn.

Tableau 12. Exemples testés et leurs neurones de sortie correspondants
($n = 3000$ tr/mn)

Généralisation	Neurone 1	Neurone 2	Neurone 3	Neurone 4	Neurone 5
Normal	0.8512	-0.1054	0.1052	0.1151	0.1109
Engrenage 1	0.1223	0.8421	- 0.1117	0.1239	0.1109
Engrenage 3	0.1198	-0.1235	0.8300	0.1287	0.1184
Engrenage 3	-0.0101	0.0238	0.8013	0.0601	0.0001
Roulement BE modéré	0.5514	0.0277	- 0.0063	0.2154	0.0150
Roulement BE	0.1188	0.2275	- 0.1191	0.7751	0.1024
Roulement BE	0.1077	-0.2254	- 0.0081	0.7045	-0.1877
Engrenage1+ roulement BE	-0.0912	<u>-0.3101</u>	- 0.1046	0.0991	0.5014
Engrenage1+ roulement BE	0.1702	<u>0.4021</u>	0.1113	0.1209	0.0452
Engr1+ roulement BE modéré	-0.0208	0.5112	- 0.0106	0.0219	0.0201

Par contre le neurone 5 correspondant au défaut pignon 1 + roulement n'est pas fortement activé. Le réseau a tendance à identifier un défaut de pignon 1 comme le montre l'activation modéré du neurone 2 correspondant au défaut de pignon 1.

Ce résultat est d'autant plus vrai que le défaut de roulement est modéré (défaut naissant) et que la vitesse de rotation est plus importante (bruit de fond plus intense).

IV.5 Cas non lubrifié

Ce cas est intéressant puisqu'il montre clairement que la présence d'un bruit de fond très intense, dû au fait que la lubrification n'existe pas induisant ainsi des frottements au niveau des dentures (figure IV.37), ne permet pas aux méthodes classiques de traitement de signal de remonter à la nature du défaut.




Figure IV.37 Kurtosis correspondant au cas non lubrifié. $n = 1800$ tr/mn

Par contre les réseaux de neurones permettent dans une certaine mesure, dans le cas non lubrifié et donc le plus défavorable, de remonter au défaut surtout dans le cas des engrenages et ce qui n'est pas du tout le cas des défauts de roulement où toute identification est impossible par les réseaux de neurones




Figure IV.38. Taux de détection des défauts simulés dans les cas lubrifiés et non lubrifiés.

La figure IV.38 résumant l'étude menée sur les trois cas : cas lubrifié avec des vitesses de rotation 1800 tr/mn et 3000 tr/mn et le cas non lubrifié avec $n = 1800$ tr/mn, montre clairement la capacité du réseau à remonter au défauts quand ces derniers ne sont pas combinés même en présence d'un bruit de fond intense (cas non lubrifié) représentant le cas le plus défavorable lors de l'identification de défauts de machines tournantes.

Néanmoins, la détection d'un défaut de roulement combiné avec d'autres défauts tels que les défauts d'engrenage reste assez fastidieuse et parfois même erronée surtout lorsque le bruit de fond est intense (cas du non lubrifié)

Un traitement des signaux est peut être nécessaire avant leur introduction au réseau dans la phase apprentissage et test du réseau.

IV.6 Utilisation des spectres

Dans le souci d'augmenter l'efficacité du réseau RBF à remonter au défaut et notamment dans le cas de défauts combinés (Roulement + Engrenage par exemple), nous faisons subir aux signaux d'autres traitements tels que l'analyse spectrale. En effet, au lieu d'utiliser les signaux comme entrée du réseau, nous utilisons les spectres de ces signaux à très fortes cadences d'échantillonnage puisque les réseaux RBF permettent de traiter un nombre important de neurones sur la couche d'entrée.

De plus l'interprétation des spectres prête souvent à confusion notamment quand il s'agit de défauts combinés en présence de chocs périodiques tels que ceux générés par les défauts de roulement. Cette étude permettra en plus d'apporter un complément d'analyse et d'éviter ainsi l'interprétation du spectre.

Les signaux ont été mesurés avec une fréquence d'échantillonnage $F_e = 48\,000$ Hz sur un temps d'acquisition $T = 10$ secondes, ce qui a donné un nombre de raies spectrales $N_L = 1600$ raies. Par conséquent, le nombre de neurones sur la couche d'entrées est de 1600 neurones. Les paramètres du réseau RBF utilisé étant les mêmes que ceux utilisés précédemment (chapitre IV.2).

Les résultats obtenus montrent la nette amélioration quant à la capacité du réseau à identifier les défauts et plus particulièrement les défauts de roulement combinés avec d'autres défauts.

En effet, le tableau 13 illustrant le cas lubrifié avec une vitesse de rotation $n = 1800$ tr/mn, clairement l'activation des neurones correspondant aux différents défauts à identifier.

Nous notons plus particulièrement l'activation du neurone 5 correspondant au cas du défaut combiné roulement modéré + Pignon1. Cette activation n'est pas tout à fait claire puisque subsiste encore l'activation du neurone correspondant au défaut de Pignon1.

Tableau 13. Exemples testés et leurs neurones de sortie correspondants
(n =1800 tr/mn). Cas lubrifié

Généralisation	Neurone 1	Neurone 2	Neurone 3	Neurone 4	Neurone 5
Normal	0.96	0.01	0.10	0.08	0.1109
Pignon1	0.02	0.97	0.06	0.10	0.002
Pignon 3	0.01	0.09	0.96	0.09	0.10
Roulement BE modéré	0.3 0.0188	0.0277 0.0275	0.0063 0.0191	0.69 0.90	0.0150 0.1024
Roulement BE accentué					
Pignon1+ roulement BE	0.0912	<u>0.22</u>	0.0646	0.0991	0.81
Pignon1+ roulement BE modéré	0.0208	0.35	0.0106	0.0219	0.65

De plus nous notons la nette convergence du réseau (cf. Figure.IV.39). En effet, la convergence a été atteinte au bout de la treizième itération.




Figure.IV.39. Convergence du réseau dans le cas d'utilisation des spectres avec lubrification.

Le cas non lubrifié à une vitesse de rotation $n = 1800$ tr/mn correspondant au cas de bruit de fond intense a été aussi traité. Il montre des résultats intéressants. En effet, la figure IV.40 et IV.41 illustrant la comparaison entre l'utilisation des signaux et l'utilisation des spectres comme entrées du réseau, montre clairement cette amélioration. Les taux de détection ayant nettement augmenté.




Figure.IV.40 Comparaison des taux de détection dans le cas lubrifié à $n = 1800$ tr/ mn.

La détection de défauts non combinés via le réseau RBF en utilisant les spectres comme entrée du réseau est très satisfaisante. En effet, des taux de détection qui avoisinent les 80% et donc des neurones de sortie fortement activés sont des résultats très encourageants quant à l'utilisation des spectres comme base d'apprentissage. Certes, il ya un traitement à faire avant l'apprentissage mais l'obtention des spectres est une étape très simple, c'est plutôt son interprétation qui parfois assez difficile et rigoureuse.




Figure.IV.41 Comparaison des taux de détection dans le cas non lubrifié à $n = 1800$ tr/ mn.

Il reste néanmoins, des efforts à faire concernant la détection des défauts combinés (Roulement+Engrenage). Des taux de détection autour de 60% sont des taux assez satisfaisant en termes d'approche neurale. En effet, la plupart des documents et références dans le domaine des réseaux de neurones [48], [49] considèrent que la convergence de ces derniers est atteinte dès qu'un neurone est activé à partir de 0.6 (60%). Cette dernière étude nous a permis surtout de montrer qu'un traitement préalable des signaux permet une meilleure détection et classification des défauts.

Conclusion Générale

Ce travail nous a permis de mettre en œuvre une méthode de diagnostic des défauts de machines tournantes par approche neuronale afin d'éviter les techniques classiques de détection de défauts reposant sur le traitement de signal. Ces dernières sont très souvent assez fastidieuses et complexes à mettre en place. En plus, lorsqu'il s'agit de défauts combinés tels que les défauts d'engrenage combinés avec des défauts de roulement l'interprétation est souvent ardue et sujette à des erreurs. Nous avons donc proposé une méthode utilisant les réseaux de neurones.

Deux types de réseau ont été étudiés : le réseau à rétro propagation de l'erreur BP (Back Propagation) et le réseau à fonction à base radiale RBF (Radial Basis Function). Nous avons évalué pour chacun de ces réseaux leur capacité de remonter aux défauts ainsi que leurs limites. Une étude paramétrée a été faite pour optimiser ces réseaux afin que la convergence de ces derniers soit efficace et rapide. Cette étude nous a permis aussi de comparer ces deux types de réseau quant à leur aptitude à identifier les défauts.

Pour ce faire, la démarche adoptée a été dans un premier temps de tester ces réseaux en utilisant des signaux simulés numériquement et par la suite confirmer les résultats obtenus, par voie expérimentale. Les signaux utilisés, dans ce dernier cas, ont été mesurés sur un banc d'essai que nous avons réalisé au Laboratoire de Vibrations Acoustique de l'INSA de Lyon. Ce banc est un réducteur à deux étages avec des engrenages à dentures droites.

L'étude numérique et paramétrée menée sur le réseau BP a montré des résultats assez mitigés. En effet, bien que ce réseau soit très utilisé en mécanique, il a montré ces limites dans notre cas d'application. En effet, si ce réseau arrive à remonter et à classer

les défauts en utilisant des signaux sains (sans bruit de fond c'est à dire sans chahutage), ce n'est pas le cas pour des signaux avec bruit de fond même modéré, le réseau ne converge pas et n'arrive pas à identifier les différents défauts simulés surtout lorsqu'il s'agit sur la couche cachée a montré qu'un nombre important de neurones est nécessaire, ce qui conduit bien sûr à un temps de calcul significatif pour la convergence du réseau.

Une des limites les plus contraignantes est le nombre de neurones sur la couche d'entrée. Ce dernier est directement lié à la fréquence d'échantillonnage des signaux présentés au réseau lors de l'apprentissage. En effet l'étude menée a montré qu'une très forte cadence d'échantillonnage et donc un nombre élevé d'échantillons et par conséquent un nombre important de neurones sur la couche d'entrée ne permet pas au réseau de converger et donc de remonter aux différents défauts simulés. Ce phénomène s'explique, d'après les différents documents consultés, par le sur-apprentissage que ce type de réseau engendre.

Pour améliorer les résultats de la détection et contenu des travaux réalisés dans ce domaine par plusieurs auteurs des références bibliographiques consultées, nous avons proposés comme entrée non pas les signaux mais les moments statistiques d'ordre 1, 2, 3 et 4 (M_1 , M_2 , M_3 et M_4) pour diminuer l'effet du bruit de fond. Par conséquent la couche d'entrée est constituée de quatre neurones. Les résultats ont montré qu'il faut une base d'apprentissage très importante. Cette initiative a été abandonnée car en pratique il est toujours difficile de constituer une base de données pour l'apprentissage. Pour toutes les limites invoquées ci-dessus, nous proposons le deuxième réseau, le réseau RBF.

L'analyse menée sur le nombre de neurones nous a permis, dans un premier temps, de montrer que le réseau à base radiale (Radial Basis Function – RBF-) est plus

adapté que le réseau à rétro propagation de l'erreur, tant que du point de vue bruit de fond que du point de vue cadence d'échantillonnage des signaux ainsi que rapidité de convergence. La mise en œuvre de ce réseau nous a permis de remonter à chaque fois à la nature du défaut même en présence d'un bruit de fond intense.

Par rapport au réseau BP (Rétro-Propagation de l'erreur), le résultat le plus important obtenu en utilisant le réseau RBF (Radial Basis Function) est l'amélioration nette de la détection des défauts combinés. Cependant, une étude minutieuse doit être faite concernant l'aplatissement de la gaussienne de la fonction de transfert utilisée pour chaque neurone pour atteindre une convergence optimale du réseau. Néanmoins, des efforts restent à faire pour la détection des défauts combinés en présence d'un bruit de fond intense comme nous le verrons dans la partie expérimentale.

Un résultat tout aussi intéressant pour le réseau RBF est que ce dernier converge malgré le nombre élevé de neurones dans la couche d'entrée. Ce résultat est intéressant car en pratique cela permettra d'utiliser des signaux à très forte cadences d'échantillonnage ($F_e = 44 \text{ kHz}$).

L'analyse expérimentale réalisée sur un réducteur à deux étages a permis de généraliser les études menées auparavant sur des réducteurs à un étage et de généraliser aussi sur des défauts combinés (roulement–Engrenages). Cette étude expérimentale a été menée bien sur en présence de bruit de fond émanant de l'environnement du laboratoire et de la machine.

L'étude nous a permis aussi de corroborer et de confirmer les résultats obtenus sur des signaux numériques dans le cas du réseau RBF, puisque c'est ce dernier qui a été retenu pour l'étude expérimentale et ce pour son efficacité prouvée ultérieurement par rapport au réseau BP. Cependant, comparée avec celle correspondant au défaut d'engrenage seul, l'identification devient plus ardue dans le cas d'un défaut de

roulement combiné à un défaut d'engrenage. En effet, le réseau a tendance, à un degré moindre par rapport au réseau BP, à identifier un défaut de roulement associé à un défaut d'engrenage comme étant un défaut d'engrenage ; ceci est d'autant plus vrai lorsque le défaut de roulement est naissant. Néanmoins, nous notons la nette amélioration par rapport à la détection du défaut Roulement + Engrenages où nous un taux de détection qui avoisine les 60 % (dans le cas lubrifié), ce qui es assez raisonnable dans les réseaux de neurones.

Dans le souci d'améliorer la détection des défauts combinés et plus ceux correspondant au défaut combiné Roulement + Engrenages, nous avons injectés comme entrée du réseau les spectres issus de ces signaux mesurés au lieu de ces derniers. Certes, les signaux subissent un traitement mais les résultats obtenus ont été très intéressants.

En effet, le taux de détection du défaut combiné Roulement + Engrenage dans le cas non lubrifié (chahutage important des signaux) avoisine les 60 %, ce qui n'est pas le cas en utilisant les signaux comme entrée du réseau car la présence d'un bruit de fond complique l'identification par approche neuronale et encore plus par les méthodes classiques de traitement de signal.

En perspective, et concernant les défauts combinés, il serait intéressant de tester d'autres approches telles que celles associant la logique floue et les réseaux de neurones appelées Neuro-Floue, l'utilisation des algorithmes génétiques peut aussi apporter des améliorations. Comme nous l'avons montré, l'utilisation des spectres comme entrée du réseau a apporté une nette amélioration quant à la capacité du réseau à remonter aux différents défauts et donc des traitements supplémentaires sur les signaux peuvent être envisagés dans le souci d'améliorer la détection et plus particulièrement la détection des

défauts combinés. Parmi ces traitements nous pensons à l'analyse d'enveloppe ou la transformée d'ondelettes.

Références bibliographiques

- [1] Randall, R.B “ Developments in Digital Analysis Techniques for Diagnostics of Bearings and Gears.” *Fifth International Congress on Sound and Vibration, December 15-18, (1997) Adelaide, South Australia.*
- [2] M. SID AHMED “ Traitement du signal pour détecter de manière précoce les défaillances des machines ” *Forum FIST 91, Orléans 1991.*
- [3] J. MAX “ Méthodes et techniques de traitement du signal et applications physiques ” *tome I, Masson 3^{ème} édition 1981.*
- [4] R.F. Burchill 1973, Resonant structure techniques for bearing fault analysis. *Proceeding of the Meeting of Mechanical Failures prevention Group, National Bureau Standard NBSIR, 73-252, pages 21-29*
- [5] R.F. Burchill, J.L. Frarey and D.S. Wilson 1973, New machinery health diagnostic techniques using high frequency vibration.
- [6] M.S. Darlow and R.H. Badgley 1975, Early detection of defects in rolling element bearings. *Society of Automotive Engineers paper 75 0209*
- [7] M.S. Darlow and R.H. Badgley 1975, Applications for early detection of rolling element bearings failures using the high frequency resonance technique. *American Society of Mechanical Engineers paper 75 – DET – 46*
- [8] K. Nishio, S. Hoshiya, T. Miyashi and M. Matsuki 1979, An investigation of the early detection of defects in ball bearings by the vibration monitoring. *American Society of Mechanical Engineers paper 79 – DET – 45*
- [9] P.D Mc Fadden and J.D Smith, Model for the vibration produced by a single point defect in a rolling element bearing. *Journal sound and vibration 96 (1984) N°1, pages 69-82*
- [10] P.D Mc Fadden and J.D Smith, The vibration produced by multiple point defects in a rolling element bearing. *Journal sound and vibration 98 (1985) N°2, pages 263-273*
- [11] David Brie, Modelling of the spalled rolling element bearing vibration analysis: an overview and some new results. *Mechanical Systems and Signal Processing, Volume 14, Issue 3, May 2000, Pages 353-369*
- [12] V. Purushotham, S. Narayanan and Suryanarayana A.N. Prasod, Multi-faults diagnosis of rolling bearing element using wavelet analysis and hidden Markov model based fault recognition. *NDT&E International, Volume 38, Issue 8, December 2005, Pages 654-664.*

- [13] Kahane J. P., Gilles P. & Rieusset L, Séries de Fourier et Ondelettes. *Editions Nouvelle bibliothèque mathématique, Cassini. 1998*
- [14] C. James, Li and J. Ma, Wavelet decomposition of vibrations for detection of bearing-localised defects. *NDT&E International, Volume 30, Issue 3, 1997, Pages 143-149.*
- [15] Jing Lin and Liangsheng Qu, Feature extraction based on Morlet wavelet and its application for mechanical fault diagnosis. *Journal sound and vibration 234 (2000) N°1, pages 135-148*
- [16] Chen Jun sheng, Yu Dejie and Yang Yu 2005, Application of impulse response wavelet to fault diagnosis of rolling bearings. *Mechanical Systems and Signal Processing.*
- [17] Hong Yu Yang, Joseph Matew and Liu Ma, Fault diagnosis of rolling element bearing using basis pursuit. *Mechanical Systems and Signal Processing, Volume 19, issue 2, March 2005, pages 341-356.*
- [18] S. Chen and D. Donoho, Signals, Systems and computers, 1994. *Conference Record of the 28 th asimolan Conference, Volume 1, Vo, 1994, Pages 41 - 44.*
- [19] S. Chen, D. Donoho and M.A. Saunders, Atomic decomposition by Basis pursuit. *SIAM review 43 1 (2001), Pages 129 - 159.*
- [20] T. I. Liu and N. R. Iyer, Diagnosis of rolling bearing defects using neural networks. *The International Journal of Advanced Manufacturing Technology, Volume 8, N° 4, July 1993, Pages 210 – 215.*
- [21] Alguindigue, I .E. Loskiewicz-Buczak and A. Uhrig, Monitoring and diagnosis of rolling element bearings using artificial neural networks. *IEEE transactions on Industrial electronics, Volume 40, Issue 2, April 1993, Pages 209-217.*
- [22] Wenlung Li, Y.P. Tsai and C.L. Chiu, The experimental study of the expert system for diagnosing unbalances by ANN and acoustic signals. *Journal of Sound and Vibration, Volume 272, Issue 1+2, April 2004, Pages 69-83.*
- [23] B. Samanta and K. R. Al-Balushi, Artificial neural network based fault diagnosis of rolling element bearings using time – domain features. *Mechanical Systems and Signal Processing, Volume 17, Issue 2, March 2003, Pages 317 – 328.*
- [24] D. M. Yang, A. F. Stronach, P. Mac Connelland and J. Penman, Third-order spectral techniques for the diagnosis of motor bearing condition using artificial neural network. *Mechanical Systems and Signal Processing, Vol 16, Issues 2-3, March 2002, Pages 391 –411.*

- [25] Czeslaw T. Kowalski and Teresa Orlowska-Kowalska, Neural networks application for induction motor faults diagnosis. *Mathematical and Computers in Simulation*, Vol 63, Issues 3-5, 17 Nov 2003, Pages 435-448 .
- [26] Kohonen T., Self-Organisation and Associative Memory. *Springer-Verlag*, 2nd Edition 1989.
- [27] Kohonen T., An Introduction to Neural Computing. *Neural Networks*, Volume 1, 1998, Pages 3-16.
- [28] RB. Randall, Detection and diagnosis of incipient bearing failure in helicopter gearbox. *Engineering Failure Analysis*, Volume 11, Issue 2, April 2004, Pages 177-190.
- [29] D. Ho and R.B. Randall, Optimisation of bearing diagnostic techniques using simulated and actual bearing fault signals. *Mechanical Systems and Signal Processing* Volume14, Issue 5, 2000, Pages 763–788.
- [30] Antoni J, Randall RB., Unsupervised noise cancellation for vibration signals—part two—a novel algorithm. *Mechanical Systems and Signal Processing* Volume 18, Issue 1, January 2004, Pages 103-117.
- [31] Lai Wuxing, Peter W. Tse, Zhang Guicai and Shi Tielin, Classification of gear fault using cumulants and the radial basis function network. *Mechanical Systems and Signal Processing* Volume18, Issue 2, Mars 2008, Pages 381–389.
- [32] C.M. Bishop, Neural Networks for Pattern Recognition. *Clarendon Press, Oxford*, 1995, pp. 164–191.
- [33] Xu Bingzheng, Zhang Beilin, Wei Gang, The Theory and Application of Neural Network, *Huanan University of Science and Technology Press, Guangzhou*, 1994, pp. 304–322.
- [34] H. Demuth and M. Beale, Neural Network Toolbox for use with Matlab. *User's guide, Version3.0*, 1998.
- [35] Zhang Xianda, Advanced Signal Processing. *Shinghua University Press, Beijing*, 1995, pp. 373–380.
- [36] W. Li, S.S. Chang, An artificial neural network system for machinery diagnoses using statistical moments as auxiliary inputs. *Proceedings ICTM98,Hsinchu, Taiwan 1998*, Pages 513-518.
- [37] A. Nadi and al., Classification of condition of rotating machines using higher-order statistics. *IEEE Colloquium on Higher Order Statistics in Signal Processing*, 1995, Pages 3/1-3/6.
- [38] H. Xing, Fuzzy Control and Modelling. *IEEE Press, New York* 2000.

- [39] F.L. Lewis, J. Campos and R. Selmic, Neuro- Fuzzy Control of Industrial Systems with Actuator Nonlinearities. *Edition Siam; Frontiers in Applied Mathematics. London 2002*
- [40] David. E. Goldberg, Algorithmes génétiques: Exploration, Optimisation et Apprentissage. *Edition Addison-Wesley 1996.*
- [41] William. B. Laugdon and Riccardo. Poli, Fundation of Génétique Programming. *Edition Springer London 2002.*
- [42] N. K. Bose and P. Liang, Neural Networks Fundamentals. *Edition Mc Graw-Hill, New York 1996.*
- [43] Gerard Dreyfus, Neural Network Methodology and Application. *Edition Springer, Paris 200.*
- [44] A. Cichoki and R. Unbehauen, Neural Network for Optimisation and Signal Processing. *Edition John Wiley and Sons. 1993*
- [45] E. Aarts and J. Korst, Simulated Annealing and Boltzmann Machines – a Stochastic Approach to Combinatorial Optimization and Neural Computing. *Edition John Wiley and Sons. 1989.*
- [46] Yee and Haykin, Regularized Radial Basis Functions Networks: Theory and Application. *Edition John Wiley 2001.*
- [47] Martin. D. Buhmann, Radial Basis Functions: Theory and Implementations. *Cambridge University 2003.*
- [48] Barto.A.G, Sutton.R and Watkins.C, Sequential dcision problems and Neural Networks. *In D. Touretsky Edition. Advances in Neural Information Processing II. 1990.*
- [49] Hartman, Keeler and Kowalski, Layered Neural Networks with Gaussian Hidden Units as Universal Approximations. *Neural Computation 2 (2), Page 210-215. 1990.*

Annexe 1.

La figure ci-dessous représente le marteau d'impact utilisé lors de l'analyse modale permettant de déterminer les modes propres de la structure (réducteur de vitesse à deux étages) et les fréquences propres. Ces dernières nous permettent bien sur d'interpréter les différents spectres issus des différentes mesures effectués sur le banc d'essai.

Les différents impacts étant effectués sur les centres des différentes mailles de la structure maillée.



Figure1. Marteau d'impact avec capteur de force

La figure ci-dessous représente l'analyseur ou plus explicitement le collecteur de données à deux voies avec une carte du type "National Instrument". Il nous a permis d'effectuer les différentes mesures vibratoires permettant de générer les jeux d'apprentissage ainsi que les jeux permettant de tester les deux réseaux utilisés (RBF et BP). Le logiciel permettant de piloter la mesure et d'effectuer les différents traitements (Spectre et analyse d'enveloppe) est "StudioVib".



Figure2. Analyseur (collecteur de données) utilisé pour la mesure et traitement des signaux

Annexe 2.




Figure1. Vitesse globale correspondant aux différents défauts simulés à $n = 3000$ tr/mn




Figure2. RMS correspondant aux différents défauts simulés à $n = 3000$ tr/mn




Figure3. Kurtosis correspondant aux différents défauts simulés à $n = 3000$ tr/mn




Figure 4. Spectre d'enveloppe dû aux différents défauts simulés à $n = 3000$ tr/mn




Figure 5. Cepstre dû aux différents défauts simulés à $n = 3000$ tr/m

