

Université Mohamed Boudiaf - M'sila

FACULTE DE TECHNOLOGIE

DEPARTEMENT



Numéro de série.....

Numéro d'inscription.....

Thèse

Présentée pour l'obtention du diplôme de

DOCTORAT LMD

Filière : Electromécanique

Spécialité : Maintenance industrielle

THEME

Diagnostic des défauts mécaniques basé sur l'apprentissage automatique

Présentée Par

DAHMANE Saida

Soutenue le : 17/ 10 / 2024

Devant le jury composé de :

| <u>Nom & Prénom</u> | <u>Grade</u> | <u>Etablissement</u> | <u>Qualité</u> |
|----------------------------|--------------|----------------------|----------------|
| GHEMARI Zine | Professeur | Univ. de M'sila | Président |
| BERRABAH Fouad | Professeur | Univ. de M'sila | Encadrant |
| CHERIF Bilal Djamal Eddine | MCA | Univ. de M'sila | Co-Encadrant |
| KESSAL Abdelhalim | Professeur | Univ. de Bordj.B | Examineur |
| TALHAOUI Hicham | Professeur | Univ. de Bordj.B | Examineur |
| BELKHIRI Salah | MCA | Univ. de M'sila | Examineur |
| ZEMMIT Abderrahim | MCA | Univ. de M'sila | Invité |

Année Universitaire : 2023/2024

A mon père que Allah lui accorde le paradis
A ma mère mon amour éternelle sans elle je ne serais plus là où je suis
A mes chers frères et sœurs, mes petits chers neveux et nièces
A mon cher Redouane...

Remerciements

Je remercie en premier lieu Allah le tout puissant pour m'avoir accordé la patience, la volonté, la santé et le courage pour finaliser ce travail.

Je souhaite remercier mon encadrant de thèse, M. BERRABAH Fouad, Professeur à l'Université Mohamed Boudiaf de M'sila, pour avoir dirigé ce travail tout au long de ces années de recherches.

Je tiens à remercier mon Co-encadrant de thèse, M. CHERIF Bilal Djamel Eddine, Maître de conférences à l'Université Mohamed Boudiaf de M'sila, pour son attention de tout instant sur mes travaux. Je lui suis également reconnaissante pour le temps conséquent qu'il m'a accordé, ses qualités pédagogiques et scientifiques, sa franchise et sa sympathie. J'ai beaucoup appris à ses côtés, et je lui adresse toute ma gratitude pour cela.

J'adresse de chaleureux remerciements à M. CHOUDER Aissa, Professeur à l'Université Mohamed Boudiaf de M'sila, pour ces conseils avisés et son écoute qui ont été prépondérants pour la réussite de cette recherche.

Un grand merci à M. LAIB Abderrzak pour ces conseils, son énergie et sa confiance qui ont été des éléments moteurs pour moi. J'ai pris un grand plaisir à travailler avec lui.

J'associe à ces sincères remerciements aux membres de jury pour avoir accepté d'examiner ma thèse.

Je désire également remercier tous les membres de laboratoire de génie électrique pour m'avoir accueilli au sein de leur équipe.

Je souhaite remercier spécialement ma mère, mon épaule Mme. DAHMANE FATMA pour ses DOUAA, son amour, et son soutien tout au long de ces années de recherche.

Travaux scientifiques

Publications

1. **Saida DAHMANE, Fouad BERRABAH, Mabrouk DEFDAF, SAAD Salah**, Diagnosis and monitoring method for detecting and localizing bearing faults, **Indonesian Journal of Electrical Engineering and Informatics (IJEEI)**, Janvier 2024, Doi: 10.52549/ijeei.v12i1.4612.

Proceedings

1. **Saida DAHMANE, Fouad BERRABAH, Mabrouk DEFDAF**, An automatic diagnosis of bearing faults of an induction motor based on FFT-ANN, **2022 International Conference of Advanced Technology in Electronic and Electrical Engineering (ICATEEE)**, 26-27 November 2022, M'sila, Algeria, Added to IEEE Xplore.

Communications internationales

1. **Saida DAHMANE, Fouad BERRABAH, Mabrouk DEFDAF**, Experimental study of bearing fault diagnosis using vibration signal – Kurtogram, **ISIEAM 2022, International Seminar in Industrial Engineering and Applied Mathematics**, 23-24 October 2022, Skikda, Algeria.
2. **Saida DAHMANE, Fouad BERRABAH, Mohamed Razi MORAKCHI**, A rolling bearing fault identification based on vibration signals analysis using DWT-DFT technique, **4th International Conference on Applied Engineering and Natural Sciences (ICAENS 2022)**, 10-13 November 2022, Konya, Turkey.

Communications nationales

- I. **Saida DAHMANE, Fouad BERRABAH, Bilal Djamal Eddine CHERIF, Mohamed Razi MORAKCHI**, Discrete Wavelet Transform (DWT) for Detection of a Rolling Element Bearing Based on Kurtosis-Energy Selection, **The First National Conference on Materials Science and Engineering (NCMSE'1_2022)**, 27-28 November, 2022, Khemis Miliana, Algeria.

Table des matières

| | |
|------------------------------------|------|
| <i>Remerciement</i> | |
| Travaux scientifiques | |
| Liste des figures | vi |
| Liste des tableaux | x |
| Liste des abréviations..... | xi |
| Liste des symboles | xiii |
| <i>Introduction générale</i> | 1 |

Chapitre I : Généralité sur la maintenance et la surveillance des organes mécaniques par l'analyse vibratoire

| | |
|--|----|
| I.1. Introduction | 5 |
| I.2. Exploration des concepts fondamentaux de défaillance et de maintenance | 5 |
| I.2.1. Défaillance, défaut et panne | 5 |
| I.2.1.1. Définition de la défaillance | 5 |
| I.2.1.4. Causes de défaillance | 6 |
| I.2.2. Notions générales sur la maintenance | 6 |
| I.2.2.1. Définition de la maintenance | 7 |
| I.2.2.2. Objectifs de la maintenance | 7 |
| I.2.3. Types de la maintenance | 7 |
| I.2.3.1. Maintenance préventive | 8 |
| I.2.3.2. Maintenance corrective | 9 |
| I.3. Niveaux de Maintenance | 9 |
| I.4. Définitions des termes liées à la surveillance | 10 |
| I.4.1. Surveillance | 10 |
| I.4.1.1. Détection | 11 |
| I.4.1.2. Diagnostic | 11 |
| I.5. Techniques de surveillance et d'analyse | 11 |
| I.5.1. Analyse d'huile | 12 |
| I.5.2. Thermographie IR | 12 |
| I.5.3. Analyse acoustique | 13 |
| I.5.4. Analyse vibratoire | 13 |
| I.6. Surveillance par analyse vibratoire | 14 |

| | |
|---|----|
| I.6.1. Définition d'une vibration | 15 |
| I.6.2. Caractéristique d'une vibration | 15 |
| I.6.3. Type des signaux vibratoires | 15 |
| I.6.3.1. Signaux déterministes | 16 |
| I.6.3.1.1. Signaux périodiques | 16 |
| I.6.3.1.2. Signaux non périodiques | 17 |
| I.6.3.2. Signaux aléatoires | 17 |
| I.6.4. Nature des vibrations générées par les machines tournantes | 18 |
| I.6.5. Chaîne de collecte des vibrations dans les machines | 19 |
| I.6.5.1. Choix de capteurs de la prise de mesure | 19 |
| I.6.5.1.1. Capteur de déplacement (proximètre) | 19 |
| I.6.5.1.2. Capteur de vitesse (vélocimètre) | 19 |
| I.6.5.1.3. Accéléromètre | 20 |
| I.6.5.2. Choix de l'emplacement de capteurs | 21 |
| I.6.5.3. Conditionnement de signal mesuré | 21 |
| I.6.6. Outils de surveillance vibratoire | 22 |
| I.7. Technologie des roulements | 22 |
| I.7.1. Constitution des roulements | 23 |
| I.7.2. Principaux types de roulements | 24 |
| I.7.2.1. Roulements à billes | 25 |
| I.7.2.1.1. Roulements à billes à contact radial à une seule rangée | 25 |
| I.7.2.1.2. Roulements à billes à contact oblique | 26 |
| I.7.2.1.3. Roulements à rotule sur double rangée de billes | 27 |
| I.7.2.1.4. Butées à billes | 27 |
| I.7.2.1.5. Paliers des roulements à billes | 28 |
| I.7.2.2. Roulements à rouleaux | 29 |
| I.7.2.2.1. Roulement à rouleaux cylindriques | 29 |
| I.7.2.2.2. Roulements à aiguilles | 29 |
| I.7.2.2.3. Roulements à rouleaux coniques | 30 |
| I.7.2.2.4. Roulements à rotule sur rouleaux | 31 |
| I.7.2.2.5. Butées à rouleaux | 31 |
| I.8. Conclusion | 32 |

Chapitre II : Etat de l'art sur les méthodes de diagnostic utilisées dans l'analyse vibratoire de roulements

| | |
|---|----|
| II.1. Introduction | 33 |
| II.2. Techniques de traitement des signaux vibratoires | 33 |

| | |
|---|----|
| II.2.1. Analyse temporelle | 34 |
| II.2.1.1. Valeur efficace (RMS) | 34 |
| II.2.1.2. Valeur crête | 34 |
| II.2.1.3. Facteur crête | 35 |
| II.2.1.4. Facteur crête-à-crête | 35 |
| II.2.1.5. Facteur d'impulsion | 35 |
| II.2.1.6. Moments statistiques | 35 |
| II.2.1.7. THIKAT | 37 |
| II.2.1.8. TALAF | 37 |
| II.2.2. Analyse fréquentielle | 37 |
| II.2.2.1. Analyse spectrale | 37 |
| II.2.2.2. Analyse cepstrale | 38 |
| II.2.2.3. Analyse d'enveloppe | 39 |
| II.2.2.4. Kurtosis spectral | 40 |
| II.2.2.5. Kurtogram | 41 |
| II.2.3. Analyse temps-fréquence | 42 |
| II.2.3.1. Transformée de Fourier à court terme (TFCT ou STFT) | 43 |
| II.2.3.2. Transformation de Wigner-Ville (TWV) | 44 |
| II.2.3.3. Transformée de Hilbert Huang | 45 |
| II.2.4. Analyse Temps-Echelle (les ondelettes) | 46 |
| II.3. Techniques de diagnostic de défauts par l'intelligence artificielle (IA) | 47 |
| II.3.1. Apprentissage Automatique (ML) | 48 |
| II.3.2. Apprentissage Approfondi (DL) | 48 |
| II.4. Conclusion | 49 |

*Chapitre III : Simulation de la signature vibratoire Liée aux défauts du roulement :
modélisation et applications*

| | |
|--|----|
| III.1. Introduction | 50 |
| III.2. Signatures de défaut et fréquences caractéristiques | 50 |
| III.2.1. Défaut de la bague extérieure | 51 |
| III.2.2. Défaut de l'élément roulant (billes) | 52 |
| III.2.3. Défaut de cage | 53 |
| III.2.4. Défaut de bague intérieure | 53 |
| III.3. Modélisation du roulement | 54 |
| III.3.1. Modélisation du roulement par traitement de signal | 54 |
| III.3.2. Modèle de Sheen pour la simulation des signaux vibratoires | 55 |
| III.3.2.1. Filtre complexe pour la transformée de Hilbert | 55 |

| | |
|--|----|
| III.3.3. Résultats de simulation analytique des signaux vibratoires du roulement..... | 57 |
| III.3.3.1. Représentation temporelle et fréquentielle avec défaut et sans bruit | 58 |
| III.3.3.2. Représentation temporelle et fréquentielle avec défaut et avec différents niveaux de bruit | 59 |
| III.3.4. Description de banc d'essai de CWRU | 61 |
| III.3.4.1. Représentation du modèle réel sans défaut | 63 |
| III.3.4.2. Représentation des signaux réels avec défaut | 63 |
| III.5. Conclusion | 65 |

*Chapitre IV : Détection des défauts de roulement par l'application des méthodes de
traitement du signal*

| | |
|--|----|
| IV.1. Introduction | 66 |
| IV.2. Théorie des ondelettes | 66 |
| IV.2.1. Définition d'une ondelette..... | 66 |
| IV.2.2. Types de transformées en ondelettes..... | 68 |
| IV.2.2.1. Transformée en Ondelette Continue (TOC)..... | 68 |
| IV.2.2.2. Transformée en Ondelette Discrète (TOD)..... | 68 |
| IV.2.3. Différentes familles d'ondelettes | 69 |
| IV.2.4. Analyse par Paquets d'Ondelettes..... | 72 |
| IV.2.5. Analyse Multi-Résolution en Ondelettes (AMRO) | 72 |
| IV.2.6. Application de l'Analyse Multi-Résolution en Ondelettes sur les signaux simulés..... | 73 |
| IV.2.6.1. Nombre de niveaux optimal de la décomposition par ondelettes | 74 |
| IV.2.6.2. Ondelette mère optimale pour la décomposition en ondelettes | 74 |
| IV.2.6.3. Processus de l'analyse du signal simulé par la méthode de l'AMRO | 75 |
| IV.2.7. Application de la méthode de l'AMRO sur les signaux réels | 80 |
| IV.3. Décomposition en mode empirique (EMD)..... | 84 |
| IV.3.1. Application de l'EMD sur les signaux simulés | 85 |
| IV.3.2. Application de l'EMD sur les signaux réels..... | 89 |
| IV.4. Synthèse des résultats des deux méthodes : AMRO et EMD..... | 93 |
| IV.5. Conclusion | 94 |

*Chapitre V : Diagnostic des défauts du roulement par l'apprentissage automatique :
validation expérimentale*

| | |
|---|----|
| V.1. Introduction..... | 96 |
| V.2. Description des algorithmes de la Random Forest et le Perceptron Multicouches (MLP)... | 96 |
| V.2.1. Définition du classifieur Random Forest | 96 |

| | |
|---|-----|
| V.2.2. Définition du classifieur du Perceptron Multicouches (MLP) | 98 |
| V.3. Critère d'évaluation de la classification des défauts | 99 |
| V.4. Extraction des indicateurs de défauts du roulement..... | 101 |
| V.5. Localisation de défauts du roulement par l'application de RF et de MLP | 103 |
| V.5.1. Application de l'algorithme de Random Forest | 103 |
| V.5.2. Application de l'algorithme de MLP | 105 |
| V.6. Etude comparative entre les deux algorithmes de classification..... | 110 |
| V.7. Conclusion | 111 |
| <i>Conclusion générale</i> | 112 |
| Références bibliographiques..... | 114 |

Liste des figures

| | |
|--|----|
| Figure I.1 : Différents types de la maintenance..... | 8 |
| Figure I.2 : Fonctions de la surveillance industrielle. | 11 |
| Figure I.3 : Statistiques sur les diverses techniques de surveillance des équipements tournants. | 14 |
| Figure I.4 : Différentes catégories des signaux de vibrations. | 16 |
| Figure I.5 : Allure d'une onde de type périodique harmonique..... | 16 |
| Figure I.6 : Allure d'un signal de type périodique non harmonique. | 17 |
| Figure I.7 : Représentation d'un signal non périodique. | 17 |
| Figure I.8 : Représentation d'un signal aléatoire..... | 18 |
| Figure I.9 : Type d'une chaîne de mesures des signaux vibratoire. | 20 |
| Figure I.10 : Distribution du taux de pannes rencontrées dans les machines asynchrones. | 23 |
| Figure I.11 : Structure générale d'un roulement..... | 23 |
| Figure I.12 : Synthèse des différents types de roulements. | 25 |
| Figure I.13 : Roulement à contact radial à une seule rangée..... | 26 |
| Figures I.14 : Roulements à billes à contact oblique. (a) : Roulement à contact oblique à une rangée de billes. (b) : Roulement à contact oblique à double rangée de billes | 26 |
| Figure I.15 : Roulement à rotule sur deux rangées de billes. | 27 |
| Figure I.16 : Butées à billes. (a) : à simple effet. (b) : à double effet..... | 28 |
| Figure I.17 : Palier de roulements à billes..... | 28 |
| Figure I.18 : Roulement à rouleaux cylindriques à une seule rangée..... | 29 |
| Figure I.19 : Roulement à aiguilles | 30 |
| Figure I.20 : Roulements à rouleaux coniques. (a) : Roulement à une seule rangée. (b) : Roulement à quatre rangées..... | 30 |
| Figure I.21 : Roulement à rotule sur rouleaux à deux rangées | 31 |
| Figure I.22 : Butée à rouleaux cylindrique..... | 31 |
| Figure II.1 : (a) : Filtrage par la décomposition élémentaire. (b) : Calcul du Kurtogram par une cascade de filtres en banc..... | 42 |
| Figure II.2 : Cordonnées en 3D illustrant le temps, la fréquence et l'intensité d'un signal | 43 |
| Figure II.3 : Principaux sous -ensemble et leurs classificateurs de l'intelligence artificielle. | 47 |
| Figure III.1 : Géométrie d'un roulement..... | 51 |
| Figure III.2 : Caractéristiques vibratoires d'une anomalie sur une bague externe. | 52 |
| Figure III.3 : Signature vibratoire d'un défaut de bille | 53 |
| Figure III.4 : signature vibratoire d'un défaut de bague intérieure | 54 |
| Figure III.5 : Signal simulé de défaut de la bague intérieure de 0,007". (a) : représentation temporelle. (b) : représentation fréquentielle. | 58 |

| | |
|---|----|
| Figure III.6 : Signal simulé de défaut de la bague intérieure de 0,014". (a) : représentation temporelle. (b) : représentation fréquentielle. | 58 |
| Figure III.7 : Signal simulé de défaut de la bague intérieure de 0,021". (a) : représentation temporelle. (b) : représentation fréquentielle. | 58 |
| Figure III.8 : Signal simulé de défaut de la bague intérieure de 0,028". (a) : représentation temporelle. (b) : représentation fréquentielle. | 59 |
| Figure III.9 : Représentation temporelle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 1,5..... | 59 |
| Figure III.10 : Représentation fréquentielle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 1,5..... | 59 |
| Figure III.11 : Représentation temporelle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 8..... | 60 |
| Figure III.12 : Représentation fréquentielle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 8..... | 60 |
| Figure III.13 : Représentation de la variation du Kurtosis en fonction du SNR. | 61 |
| Figure III.14 : Représentation de la variation de RMS en fonction du SNR. | 61 |
| Figure III.15 : Banc d'essai expérimental de la CWRU..... | 62 |
| Figure III.16 : Représentation temporelle d'un signal réel sans défaut. | 63 |
| Figure III.17 : Représentation fréquentielle d'un signal réel sans défaut. | 63 |
| Figure III.18 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,007"..... | 63 |
| Figure III.19 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,007"..... | 63 |
| Figure III.20 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,014"..... | 64 |
| Figure III.21 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,014"..... | 64 |
| Figure III.22 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,021"..... | 64 |
| Figure III.23 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,021"..... | 64 |
| Figure III.24 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,028"..... | 64 |
| Figure III.25 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,028"..... | 64 |
| Figure IV.1 : (a) : Changement de position des ondelettes par la translation. (b) : Changement d'échelle des ondelettes [13]..... | 67 |
| Figure IV.2 : Forme de l'ondelette de Morlet..... | 69 |
| Figure IV.3 : Forme de l'ondelette chapeau mexicain [100]. | 70 |
| Figure IV.4 : Forme de l'ondelette de Haar [101]. | 70 |
| Figure IV.5 : Forme de l'ondelette de Daubechies. | 71 |
| Figure IV.6 : la forme de l'ondelette de Meyer..... | 71 |

| | |
|---|----|
| Figure IV.7 : Arbre de la décomposition en paquets d'ondelettes. | 72 |
| Figure IV.8 : Décomposition d'un signal en cascade en trois niveaux [107]. | 73 |
| Figure IV.9 : Signal simulé présentant un défaut de la bague extérieure de 104,3 Hz avec deux niveaux de bruit..... | 75 |
| Figure IV.10 : Kurtosis calculé de chaque détail reconstruit de la décomposition utilisant différents types d'ondelettes mères pour signal avec bruit. (a) : SNR=5 dB. (b) : SNR=-3 dB. | 75 |
| Figure IV.11 : Processus de l'application de la méthode de l'AMRO..... | 76 |
| Figure IV.12 : Signal simulé d'un état sain avec bruit de -1 dB..... | 77 |
| Figure IV.13 : Kurtosis calculé pour les sept détails reconstruits..... | 77 |
| Figure IV.14 : Spectre d'enveloppe du détail reconstruit 1 de l'état sain du roulement..... | 77 |
| Figure IV.15 : Signal simulé de défaut de la bague extérieure avec un bruit de 5 dB..... | 78 |
| Figure IV.16 : Kurtosis calculé pour les sept détails reconstruits..... | 78 |
| Figure IV.17 : Spectre d'enveloppe du détail reconstruit 4 de la décomposition par l'AMRO de signal simulé de défaut de la bague extérieure. | 78 |
| Figure IV.18 : Signal simulé de défaut de la bague intérieure d'un bruit de 5 dB. | 79 |
| Figure IV.19 : Kurtosis calculé pour les sept détails reconstruits..... | 79 |
| Figure IV.20 : Spectre d'enveloppe de détail reconstruit 3. | 79 |
| Figure IV.21 : Signal simulé de défaut de la bille avec un bruit de -3 dB..... | 80 |
| Figure IV.22 : Kurtosis calculé pour les sept détails reconstruit. | 80 |
| Figure IV.23 : Spectre d'enveloppe de détail reconstruit 4 de défaut de la bille..... | 80 |
| Figure IV.24 : Signal temporel d'un état sain du roulement réel..... | 81 |
| Figure IV.25 : Kurtosis calculé pour les sept détails reconstruits d'un cas sain du roulement..... | 81 |
| Figure IV.26 : Spectre d'enveloppe du détail reconstruit 1 représentant un cas sain du roulement. | 81 |
| Figure IV.27 : Signal temporel de défaut de la bague extérieure du roulement. | 81 |
| Figure IV.28 : Kurtosis calculé pour les sept détails reconstruits de défaut de la bague extérieure. | 81 |
| Figure IV.29 : Spectre d'enveloppe du détail reconstruit 2 de défaut de la bague extérieure. | 82 |
| Figure IV.30 : Signal temporel de défaut de la bague intérieure du roulement. | 82 |
| Figure IV.31 : Kurtosis calculé pour les sept détails reconstruit de défaut de la bague intérieure. | 82 |
| Figure IV.32 : Spectre d'enveloppe de détail reconstruit 1 de défaut de la bague intérieure. | 83 |
| Figure IV.33 : Spectre d'enveloppe de détail reconstruit 7 de défaut de la bague intérieure. | 83 |
| Figure IV.34 : Signal temporel de défaut de la bille du roulement..... | 83 |
| Figure IV.35 : Kurtosis calculé pour les sept détails reconstruit de défaut la bille..... | 83 |
| Figure IV.36 : Spectre d'enveloppe du détail reconstruit 1 de défaut de la bille..... | 83 |
| Figure IV.37 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le cas sain du roulement. (a) : Kurtosis. (b) : Coefficient de corrélation. | 86 |
| Figure IV.38 : Spectre d'enveloppe de l' <i>IMF1</i> de l'état sain du roulement..... | 87 |
| Figure IV.39 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le défaut de la bague extérieure. (a) : Kurtosis. (b) : Coefficient de corrélation..... | 87 |
| Figure IV.40 : Spectre d'enveloppe de l' <i>IMF1</i> de défaut de la bague extérieure. | 87 |

| | |
|---|-----|
| Figure IV.41 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le défaut de la bille. (a) : Kurtosis. (b) : Coefficient de corrélation. | 88 |
| Figure IV.42 : Spectre d’enveloppe de l’ <i>IMF1</i> de défaut de la bille..... | 88 |
| Figure IV.43 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le défaut de la bague intérieure. (a) : Kurtosis. (b) : Coefficient de corrélation..... | 89 |
| Figure IV.44 : Spectre d’enveloppe de l’ <i>IMF3</i> de défaut de la bague intérieure. | 89 |
| Figure IV.45 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le cas sain. (a) : Kurtosis. (b) : Coefficient de corrélation. | 90 |
| Figure IV.46 Spectre d’enveloppe de l’ <i>IMF1</i> d’un cas sain du roulement. | 90 |
| Figure IV.47 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le cas de défaut de la bague extérieure. (a) : Kurtosis. (b) : Coefficient de corrélation. | 91 |
| Figure IV.48 : Spectre d’enveloppe de l’ <i>IMF1</i> de défaut de la bague extérieure. | 91 |
| Figure IV.49 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le cas de défaut de la bille. (a) : Kurtosis. (b) : Coefficient de corrélation. | 92 |
| Figure IV.50 : Spectre d’enveloppe de l’ <i>IMF1</i> de défaut de la bille..... | 92 |
| Figure IV.51 : Facteurs calculés pour les 10 <i>IMFs</i> représentant le cas de défaut de défaut de la bague intérieure. (a) : Kurtosis. (b) : Coefficient de corrélation..... | 93 |
| Figure IV.52 : Spectre d’enveloppe de l’ <i>IMF1</i> de défaut de défaut de la bague intérieure. | 93 |
| Figure V.1 : L’architecture du classifieur de la RF..... | 98 |
| Figure V.2 : Exemple de la structure du réseau de Perceptron Multicouche (MLP). | 99 |
| Figure V.3 : Diamètre variable et charge fixe à 0 Nm avec une position centrale de l’accéléromètre. | 101 |
| Figure V.4 : Charge variable et diamètre fixe à 0.5534 mm avec une position centrale de l’accéléromètre. | 102 |
| Figure V.5 : Charge variable et diamètre fixe à 0.5534 mm avec une position orthogonale de l’accéléromètre. | 102 |
| Figure V.6 : Charge variable et diamètre fixe à 0.5534 mm avec une position opposite de l’accéléromètre. | 102 |
| Figure V.7 : Diagramme schématique du modèle de Random Forest proposé. | 104 |
| Figure V.8 : Taux d’exactitude en fonction du nombre d’arbres de RF. | 105 |
| Figure V.9 : Diagramme schématique du modèle MLP proposé. | 106 |
| Figure V.10 : Matrice de confusion d’une structure de : (a) : (55, 1) neurones. (b) : (45,1) neurones. | 108 |
| Figure V.11 : Matrice de confusion d’une structure de : (a) : (55, 25, 1) neurones. (b) : (65, 25, 1).. | 108 |

Liste des tableaux

| | |
|---|-----|
| Tableau I.1 : les cinq niveaux de la maintenance..... | 10 |
| Tableau I.2 : La nature des vibrations générées par les organes mécaniques. | 18 |
| Tableau II.1 : les diverses techniques d'analyse du signal..... | 33 |
| Tableau III.1 : Paramètres géométriques. | 51 |
| Tableau III.2 : Paramètres des mesures réelles. | 57 |
| Tableau III.3 : Variation des facteurs de kurtosis et de RMS en fonction du SNR..... | 60 |
| Tableau III.4 : Paramètres du roulement 6205-2 RSJEM SKF..... | 62 |
| Tableau III.5 : Comparaison entre les signaux simulés et les signaux réels. | 65 |
| Tableau IV. 1 : Fréquences théoriques calculées des défauts du roulement. | 76 |
| Tableau V.1 : Critères d'évaluation du modèle RF..... | 104 |
| Tableau V.2 : Critères d'évaluation du modèle MLP..... | 106 |

Liste des abréviations

| | |
|---------|--|
| ANN : | Artificial Neural Network (Réseau Neuronal Artificiel) |
| MLP : | Multi-Layer Perceptron (Perceptron Multicouche) |
| NBC : | Naïf-Bays Classifier |
| K-NN : | K-Nearest Neighbor (k- plus Proches Voisins) |
| RF : | Random Forest (Forêts Aléatoires) |
| ML : | Machine Learning (Apprentissage Automatique) |
| CWRU : | Case Western Reserve Université |
| AFNOR : | Association Française de Normalisation |
| ISO : | Organisation Internationale de Standardisation |
| IR : | Infrarouge |
| HHT : | Transformée de Hilbert Huang |
| FC : | Facteur de Crête |
| FCC : | Facteur de Crête à Crête |
| RMS : | Valeur Efficace |
| FI : | Facteur d'Impulsion |
| CC : | Coefficient de Corrélation |
| FFT : | Transformée de Fourier Rapide |
| ENV : | Analyse d'Enveloppe Spectrale |
| TFCT : | Transformée de Fourier à Court Terme |
| WVD : | Distribution de Wigner-Ville |
| TOD : | Transformée en Ondelettes Discrète |
| TOC : | Transformée en Ondelette Continue |
| AMRO : | Analyse Multi-Résolution en Ondelettes |
| EMD : | Transformée en Mode Empirique |
| IMF : | Fonction Modale Intrinsèque |
| RPM : | Révolution Par Minute |
| EDM : | Usinage par Electroérosion |

| | |
|--------|---|
| SNR : | Rapport Signal sur Bruit |
| KS : | Kurtosis Spectral |
| VMD : | Décomposition en Mode Variationnel |
| IA : | Intelligence Artificielle |
| SVM : | Machine à Vecteur de Support |
| CNN : | Conventional Neural Network (Réseau Neuronal Conventionnel) |
| DT : | Decision Tree (Arbre de Décision) |
| DL : | Deep Learning (Apprentissage Approfondi) |
| DA-E : | Auto-Encodeurs de Débruitage |
| RCP : | Réseaux de Croyance Profonde |

Liste des symboles

| | |
|--------------------------|--|
| t : | Temps |
| A : | Amplitude |
| f : | Fréquence |
| Hz : | Hertz unité de fréquence |
| N : | Nombre de point du signal |
| x_i : | Valeur instantanée du signal |
| V_{peak} : | Valeur crête du signal |
| F_C : | Facteur crête |
| F_{CC} : | Facteur crête à crête |
| F_I : | Facteur d'impulsion |
| M_r : | Moment d'ordre r |
| \bar{x} : | Moyenne (moment d'ordre 1) |
| σ^2 : | Variance (moment d'ordre 2) |
| σ : | Ecart type |
| <i>Skewness</i> : | Moment d'ordre 3 |
| Ku : | Kurtosis (moment d'ordre 4) |
| $x(f)$: | Transformée de Fourier |
| $x(t)$: | Signal temporel |
| $X(k)$: | Transformée de Fourier discrète |
| $\mathcal{C}(\tau)$: | Cepstre |
| $H[x(t)]$: | Transformée de Hilbert |
| K_x : | Kurtosis spectral |
| $H(i, f)$: | Enveloppe complexe de $x(i)$ |
| $\langle F(i) \rangle$: | Moyenne temporelle d'une fonction $F(i)$ |
| $\rho(f)$: | Rapport signal bruit en fonction de la fréquence |

| | |
|-------------------|---|
| $\eta(i)$: | Bruit stationnaire additif |
| $h_0(i)$: | Filtre passe-bas |
| $h_1(i)$: | Filtre passe-haut |
| $h(n)$: | Filtre prototype passe-bas |
| f_c : | Fréquence de coupure |
| K_k^i : | Kurtogram |
| $C_k^i(n)$: | Séquence de coefficients des $i^{\text{ème}}$ filtre et $k^{\text{ème}}$ niveau de l'arbre de décomposition |
| $X(\tau, f)$: | Transformée de Fourier à court terme d'un signal |
| $W_x(t, f)$: | Transformation de Wigner-Ville |
| $\psi(t)$: | Ondelette |
| $\psi(f)$: | Transformée de Fourier de l'ondelette $\psi(t)$ |
| n_b : | Nombre de billes |
| α : | Angle de contact |
| D : | Diamètre du cercle primitif |
| d : | Diamètre de l'élément roulant (billes) |
| D_o : | Diamètre de la bague externe |
| D_i : | Diamètre de la bague interne |
| f_r : | Fréquence de rotation |
| F_{BPFO} : | Fréquence de passage des billes de défaut de la bague extérieure |
| F_{BSF} : | Fréquence de défaut de rotation de la bille |
| F_{FTF} : | Fréquence fondamentale de défaut de la cage |
| F_{BPFI} : | Fréquence de passage des billes de défaut de la bague intérieure |
| h_{a,f_c,f_w} : | Filtre complexe pour la transformée de Hilbert |
| a : | Facteur d'échelle |
| f_c : | Fréquence centrale |
| f_w : | Largeur de la bande passante |
| T_s : | Temps d'échantillonnage |
| f_s : | Fréquence d'échantillonnage |
| cA_1 : | Coefficient d'approximations |
| cD_1 : | Coefficient des détails |
| F_{max} : | Fréquence maximale du signal. |
| $E_{max}(t)$: | Enveloppe supérieure |

| | |
|------------------|------------------------------------|
| $E_{min}(t)$: | Enveloppe inférieure |
| y_k : | $k^{ième}$ sortie du réseau |
| x_j : | $j^{ième}$ entrée du réseau |
| $w_{ij}^{(1)}$: | Poids de la première couche cachée |
| $w_{ij}^{(2)}$: | Poids de la deuxième couche cachée |

Introduction générale

Les processus industriels peuvent impliquer des procédures chimiques, physiques, électriques ou mécaniques qui contribuent à la fabrication d'un ou de plusieurs produits, généralement à très grande échelle. Dans ces processus industriels, les moteurs à induction sont les composants clés de l'industrie lourde [1], en raison de leurs innombrables avantages, en particulier ceux qui découlent de leur grande fiabilité, de leur faible coût, de la réduction du temps de maintenance et de leurs performances dynamiques. Malgré cela, en raison d'un environnement opérationnel défavorable, tel que l'abrasion, les charges déséquilibrées ou la surcharge, ces moteurs sont susceptibles d'être endommagés, ce qui peut perturber les composants du stator, du rotor et des éléments du roulement. En effet, les roulements sont généralement incapables de supporter de lourdes charges et représentent, selon les statistiques, environ 41 % à 69% de tous les cas d'autres défaillances [2, 3 et 4]. Ces défaillances peuvent conduire à des interruptions brutales de la production, ce qui entraîne également une augmentation des coûts de maintenance. Cela démontre l'intérêt de diagnostiquer les défaillances des roulements dans le cadre de la surveillance et la prédiction de l'état de fonctionnement des moteurs à induction.

Eventuellement, pour un diagnostic efficace des défauts, trois approches de base sont considérées : la maintenance préventive, la maintenance prédictive et la maintenance corrective. Si un défaut s'est déjà produit, des procédures correctives sont mises en œuvre, ce qui entraîne des coûts élevés de remplacement des composants, des temps d'arrêt soudains et, évidemment, un coût substantiel lié à l'arrêt de la production. Les procédures préventives visent à planifier et à gérer les interventions périodiques de maintenance industrielle avant qu'un dysfonctionnement ou une panne ne survienne. Toutefois, cette approche mobilise de nombreuses ressources, alors que les résultats sont peu efficaces. En revanche, la procédure prédictive est développée sur la base d'une surveillance précise qui peut diminuer considérablement les défaillances des machines et les coûts de maintenance [5].

Pour surveiller les symptômes de défaillance, diverses grandeurs physiques peuvent être mesurées, telles que le courant du stator, l'analyse de la température, le niveau du bruit, la lubrification, la pression, la vitesse et l'analyse des vibrations [6, 7 et 8]. Parmi ces mesures,

l'analyse des vibrations est la technique la plus souvent considérée pour diagnostiquer les défaillances des roulements [9]. Elle se déroule selon trois niveaux principaux : la supervision, le diagnostic et la surveillance. La supervision consiste à utiliser des indicateurs globaux qui reflètent les changements dans le comportement du roulement. Ensuite, le diagnostic s'appuie sur des techniques de traitement du signal pour localiser et identifier les défauts. Enfin, la surveillance sert à observer l'état de dégradation de chaque élément défectueux [10].

En outre, pour la prédiction des défaillances du roulement à un stade précoce, l'extraction des signatures vibratoires est un sujet de recherche très intéressant et délicat, en raison de la non linéarité et la non stationnarité des signaux vibratoires. De plus, les données temporelles brutes seules ne peuvent révéler aucune information sur l'état de l'élément du roulement, ce qui rend son identification ou sa détection impossible. Le traitement du signal devient donc un outil essentiel pour déterminer l'état de fonctionnement du système. Dans le domaine du traitement des signaux, la littérature scientifique a connu plusieurs efforts de recherche qui soutiennent de nombreuses techniques et approches. Parmi les différentes approches traditionnelles du traitement des signaux, on a l'analyse temporelle (RMS, Kurtosis, Facteur de forme...), l'analyse fréquentielle (Transformée de Fourier Rapide (FFT), analyse d'enveloppe spectrale), l'analyse temps-fréquence (Transformée de Fourier à Court Terme (TFCT), la Distribution de Wigner-Ville (WVD)). Plus récemment, d'autres techniques ont été apparues pour mieux détecter les défauts du roulement, à savoir la Transformée en Ondelettes Discrète (TOD), la Transformée en Mode Empirique (EMD)... etc.). La transformée en ondelettes discrète (TOD) et l'analyse d'enveloppe spectrale (ENV) sont bien connues et utilisées pour identifier les défauts, en particulier dans les signaux non stationnaires [8]. La TOD sert à décomposer le signal original, fournissant des approximations et des détails riches en informations sur les défauts, tandis que l'analyse d'enveloppe spectrale permet d'obtenir uniquement les informations nécessaires correspondant à l'existence du défaut en termes de séries de fréquences.

En réalité, l'application de l'une de ces techniques de traitement des signaux comprenant des symptômes de défaillance des éléments, nécessite l'analyse et l'évaluation des résultats atteints. Ce qui nécessite également des connaissances spécialisées pour utiliser ces symptômes dans le processus de diagnostic, pour interpréter les résultats, pour fixer les seuils appropriés et pour effectuer un suivi régulier de ces analyses. Ce type d'approche introduit un facteur humain qui réduit la tolérance aux pannes du système dans son ensemble. C'est pourquoi des méthodes d'intelligence artificielle sont recherchées pour éliminer ce facteur humain et automatiser le

processus de détection. Dans la littérature spécialisée, de nombreux chercheurs ont concentré leurs études sur le développement d'approches et de méthodes visant à améliorer l'automatisation du diagnostic des défauts de roulements. Les algorithmes d'apprentissage automatique permettent de classer les différents défauts tout en assurant une meilleure localisation des défauts. Parmi les outils d'apprentissage automatique, les algorithmes suivants sont les plus utilisés : Réseau Neuronal Artificiel (ANN), Perceptron Multicouche (MLP), Naïf-Bays, K-Voisins les plus Proches (K-NN) et Forêts Aléatoires (RF). La mise en œuvre d'une combinaison entre l'apprentissage automatique (ML) et le traitement des signaux permet de surveiller automatiquement les défauts. Ainsi, une identification pertinente des défauts permet une meilleure extraction des caractéristiques, ce qui améliore finalement la performance et la fiabilité de la classification du système [105].

Pour cette raison, l'objectif fondamental de ce travail sert à élaborer une nouvelle stratégie qui combine deux approches pour renforcer la détection précoce des défauts et la surveillance des machines tournantes, en mettant l'accent spécifique sur les roulements. Notre stratégie consiste à associer l'identification des défauts sur la base des signaux de vibration des composants du roulement par le leur traitement via la transformée en ondelettes discrète (TOD) et l'analyse d'enveloppe spectrale, avec deux techniques d'apprentissage automatique faisant appel au perceptron multicouche (MLP) et la forêt aléatoire (RF). La TOD décompose le signal vibratoire en un ensemble de détails et d'approximation qui seront reconstruits à nouveau pour conserver les informations nécessaires sur le défaut. L'analyse d'enveloppe (ENV) est effectuée sur les détails reconstruits pour fournir les fréquences caractéristiques de défaut. L'idée centrale ici est d'encercler uniquement la zone de bande des composants du défaut et de réduire la dimensionnalité de la matrice de caractéristiques. Enfin, les classificateurs de la forêt aléatoire et du MLP sont entraînés à l'aide des caractéristiques de fréquence obtenues afin d'évaluer les performances et d'obtenir un modèle automatique robuste pour diagnostiquer les défauts des composants du roulement. Il convient de mentionner que le processus proposé est validé par un test expérimental au laboratoire de la CWRU qui comprend des signaux vibratoires de quatre conditions du roulement : roulement en état sain, roulement défectueux comprenant un défaut de la bague extérieure, roulement défectueux avec défaut de la bille et roulement défectueux avec défaut de la bague intérieure.

Suite à ces considérations, nous présentons notre thèse en cinq chapitres, que nous résumons comme suit :

- **Le premier chapitre** est dédié à la présentation des généralités sur la maintenance et la surveillance des organes mécaniques par l'analyse vibratoire, ainsi qu'à l'exposition des différents types de roulements existants dans l'industrie.
- **Dans le deuxième chapitre**, nous exposons un état de l'art sur les différentes techniques utilisées dans le domaine du diagnostic des défauts de roulements, en mettant en avant leurs avantages et limitations dans ce domaine.
- **Le troisième chapitre** a pour but développer et simuler les signatures vibratoires des défauts du roulement à partir des équations décrivant le mouvement de ce système.
- **Le quatrième chapitre** repose sur la détection et l'identification des défauts du roulement par l'application des techniques de traitement du signal, notamment la TOD, l'EMD et l'analyse d'enveloppe spectrale, tout en comparant les résultats obtenus pour les considérer dans la classification des défauts.
- **Dans le cinquième et dernier chapitre**, nous finalisons notre thèse en illustrant les résultats obtenus par la stratégie suivie lors du diagnostic des différents défauts du roulement, tout en montrant la pertinence et l'efficacité des caractéristiques extraites, ainsi que la performance et la robustesse des classificateurs choisis pour ce diagnostic.

Chapitre I

Généralité sur la maintenance et la surveillance des organes mécaniques par l'analyse vibratoire

I.1. Introduction

L'objectif principal de ce chapitre sert à fournir une introduction aux différentes notions de base liées à la défaillance, à la maintenance et à la surveillance. Ensuite, une partie importante du chapitre est réservée pour présenter la surveillance des roulements par l'analyse vibratoire et de ses différentes phases. Enfin, nous exposons un aperçu global sur les différents types de roulements pouvant existés dans l'industrie, tels que les roulements à billes, les roulements à rouleaux, les roulements coniques, etc. Ainsi que leurs applications spécifiques dans divers domaines industriels.

I.2. Exploration des concepts fondamentaux de défaillance et de maintenance

Dans cette section, on présente des concepts clés employés dans le domaine de la maintenance, ainsi que dans le cadre de cette thèse, en fournissant leurs définitions.

I.2.1. Défaillance, défaut et panne

I.2.1.1. Définition de la défaillance

La norme AFNOR X 60-319 définit la défaillance comme étant l'altération ou la cessation de l'aptitude d'une entité à accomplir une fonction requise avec les performances définis dans les spécifications techniques [11]. Généralement la défaillance induit un écart entre une caractéristique mesurée sur le bien et une caractéristique de référence ce qui conduit en conséquence à un défaut.

I.2.1.2. Définition de défaut

Selon la norme AFNOR [11], un défaut représente l'écart entre une caractéristique réelle d'une entité et la caractéristique de référence lorsque celui-ci est en dehors des spécifications. Les défauts peuvent être classés selon leur sévérité en plusieurs types différents [12]:

- ✓ **Défaut naissant** : ce type de défaut se manifeste de manière progressive, avec une amplitude croissante. Il résulte généralement de l'usure ou du vieillissement, entraînant des déviations.
- ✓ **Défaut fugitif** : qui est également connu sous le nom de défaut ponctuel ou passager, se distingue par sa durée courte et par l'écart significatif entre la sortie du système et la référence.
- ✓ **Défaut permanent** : ce défaut s'installe dès son apparition et persiste de manière continue dans le système, tant qu'aucune intervention de maintenance ne soit pas entreprise.
- ✓ **Défaut catastrophique** : est un type de défaut qui provoque l'arrêt complet ou la panne du système.

I.2.1.3. Définition de la panne

Une panne est définie selon AFNOR [11], comme étant l'inaptitude d'un dispositif à accomplir une fonction requise. Ainsi, une panne est généralement le résultat d'une défaillance. Lorsqu'un dispositif cesse de remplir sa fonction prévue, il subit une défaillance, ce qui entraîne alors la panne du dispositif.

I.2.1.4. Causes de défaillance

Les causes de défaillance sont décrites suite à la norme AFNOR NF X60-010 [11], par : « les circonstances liées à la conception, la fabrication ou l'emploi, qui ont entraîné la défaillance ». Effectivement, une connaissance approfondie de ces mécanismes, permet de mettre en place des stratégies de maintenance adaptées, incluant des actions préventives et prédictives, afin de maximiser la durée de vie utile des matériels et réduire les risques de défaillance [13]. Toutes les notions fondamentales de la maintenance vont être bien détailler dans la section suivante.

I.2.2. Notions générales sur la maintenance

Avec l'avènement de l'industrie et des technologies, la maintenance des machines dans les usines est devenue essentielle pour garantir un fonctionnement fiable, efficace et sécurisé des équipements et également accroître le rendement de ces dernières.

I.2.2.1. Définition de la maintenance

La norme AFNOR NF-X60-010 [11], définit la maintenance comme un ensemble d'activités destinées à maintenir ou rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé, pour accomplir une fonction requise.

I.2.2.2. Objectifs de la maintenance

Les activités de la maintenance ont plusieurs objectifs qui peuvent être groupés en deux catégories principaux :

Objectifs opérationnels

Les objectifs opérationnels de la maintenance sont étroitement liés et se renforcent mutuellement pour assurer un fonctionnement optimal des équipements, parmi lesquels on a :

- A. Assurer une disponibilité accrue des équipements, cela permet de diminuer au minimum le temps d'arrêt imprévus ;
- B. Garantir une durée de vie prolongée des équipements ;
- C. Améliorer les performances globales des équipements ou des processus ;
- D. Renforcer la sécurité des travailleurs et des employés.

Objectifs financiers

Les objectifs financiers sont généralement interconnectés avec ceux des objectifs opérationnels et se soutiennent mutuellement pour :

- a. Réduire les coûts liés aux activités de la maintenance ;
- b. Optimiser la productivité du processus tout en réduisant les temps d'arrêt et en exploitant efficacement les ressources ce qui garantit une augmentation des résultats financiers.

I.2.3. Types de la maintenance

En fonction de la défaillance, les types de maintenance sont regroupés en deux grandes familles : la maintenance préventive (avant la défaillance) et la maintenance corrective (après la défaillance), comme illustre la figure I.1.

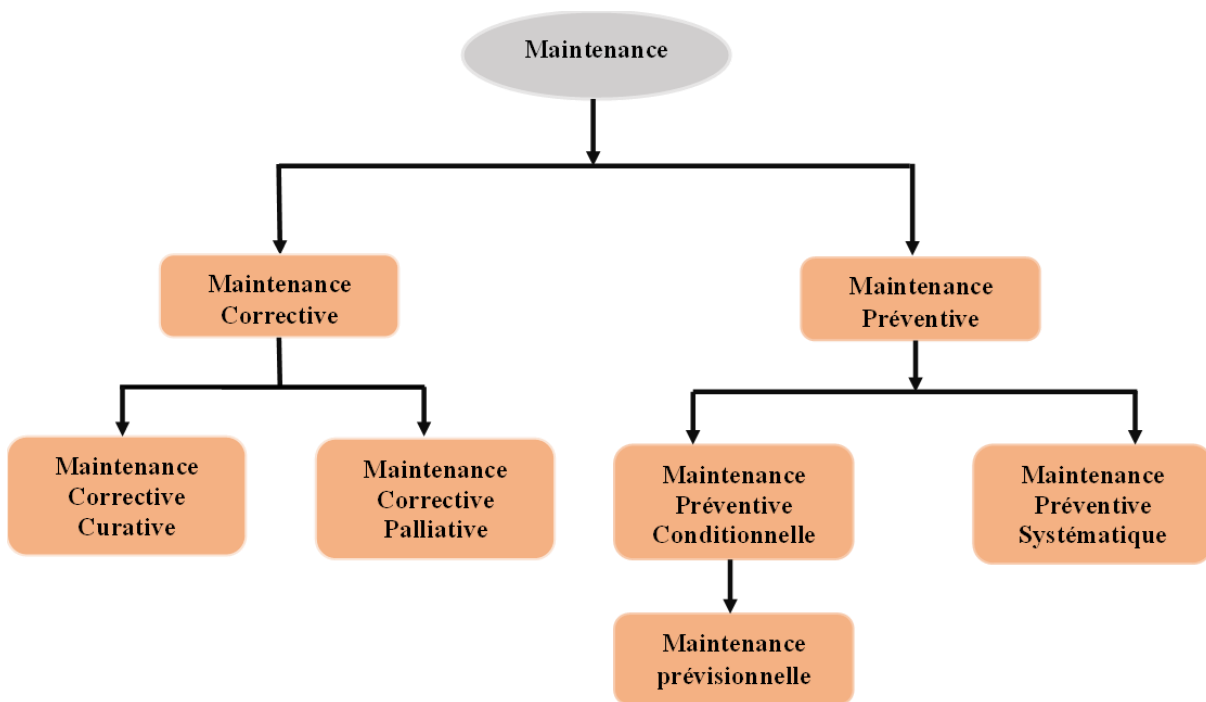


Figure I.1 : Différents types de la maintenance [14, 15].

I.2.3.1. Maintenance préventive

On fait toujours référence à la norme AFNOR [11], la maintenance préventive : « c'est une maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinés à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien ».

Les opérations essentielles pouvant être effectuées dans le cadre de la maintenance préventive comprennent : les inspections visuelles régulières, les visites sur terrain, les contrôles, les tests de performance et la formation du personnel et sensibilisation. A partir de ces opérations on peut distinguer deux types de la maintenance préventive : systématique, conditionnelle ou prévisionnelle.

a) Maintenance préventive systématique

Selon la norme AFNOR [11], la maintenance systématique : « C'est une 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 ».

b) Maintenance préventive conditionnelle

D'après la norme AFNOR [11], la maintenance conditionnelle : « C'est une maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent ».

La maintenance prévisionnelle, également nommée par la maintenance prédictive, est un concept spécifique de la maintenance conditionnelle, selon l'AFNOR. Elle se base sur les informations obtenues à travers la surveillance de l'état de l'équipement et de l'analyse périodique des données, dans le but d'identifier la détérioration des équipements et de déterminer le moment approprié d'intervention.

I.2.3.2. Maintenance corrective

La maintenance corrective est définie suite à la norme AFNOR [11], comme étant : « la maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise ».

Les opérations de la maintenance corrective sont réalisées pour les remplacements des pièces défectueuses et la réparation des équipements ou les installations après une panne ou un dysfonctionnement. Les opérations précitées permettent de différencier deux grandes catégories de maintenance corrective : la maintenance curative et la maintenance palliative.

a) Maintenance corrective palliative

Dans le cadre de ce type de maintenance, également connue sous le nom de dépannage, des actions de réparation sont entreprises pour permettre au système de reprendre provisoirement ou partiellement la fonction requise.

b) Maintenance corrective curative

A la différence des mesures palliatives, la maintenance curative vise à éliminer de manière définitive la ou les défaillances pour objectif de rétablir d'une façon permanente la fonction requise d'un bien.

Il est couramment constaté que la maintenance corrective s'avère à la fois coûteuse et potentiellement dangereuse. Une maintenance optimale est donc le résultat d'une combinaison harmonieuse entre l'entretien correctif et l'entretien préventif conditionnel qui est lié à la surveillance et au diagnostic du système.

I.3. Niveaux de Maintenance

Selon la norme AFNOR NF X60-010 et la norme NF X60-000 (2016) [11, 16], les niveaux de maintenance sont classés en cinq catégories distinctes, allant des activités les plus élémentaires aux plus complexes. Également, des actions de maintenance corrective et

préventive vont correspondre à chaque niveau. Ces niveaux de maintenance sont bien listés dans le tableau I.1 ci-dessous.

Tableau I.1 : les cinq niveaux de la maintenance.

| | Niveau I | Niveau II | Niveau III | Niveau IV | Niveau V |
|------------------|--|--|--|--|---|
| Travaux | - Interventions simples - Pas de démontage ni ouverture | - Interventions peu complexes | - Interventions considérées comme complexes - Diagnostic et identification des pannes | - Opérations importantes de grande importance | - Actions complexes |
| Lieu | Sur site | Sur site | L'emplacement des travaux peut être sur site ou dans un atelier de maintenance. | Atelier bien équipé et spécialisé | Chez le constructeur |
| Personnel | Opérateur non spécialisé | Technicien de qualification moyenne | Techniciens spécialisés | Equipe de techniciens spécialisés ayant un responsable superviseur | Constructeur |
| Exemple | - Graissages - Test de voyant | Changement de pièce de rechange (Rouleaux, fusible...) | Changement de pièce de rechange standard (moteur, roulements, engrenages...) | La mise en œuvre des techniques de surveillance, telles que l'analyse des vibrations et l'analyse d'huile. | - La mise en conformité d'un équipement - Reconstruction et réparation d'un équipement |

I.4. Définitions des termes liées à la surveillance

Cette partie est consacrée à la présentation des définitions liées à la surveillance et au diagnostic dans le domaine industriel.

I.4.1. Surveillance

La surveillance est un dispositif informationnel passif qui analyse l'état d'un système et fournit des indicateurs. Elle se concentre sur la détection et la classification des défaillances en observant l'évolution du système, ainsi que sur leur diagnostic en identifiant les éléments défaillants et les causes sous-jacentes. La figure I.2 résume les niveaux de la surveillance en deux fonctions principales [17,18]:

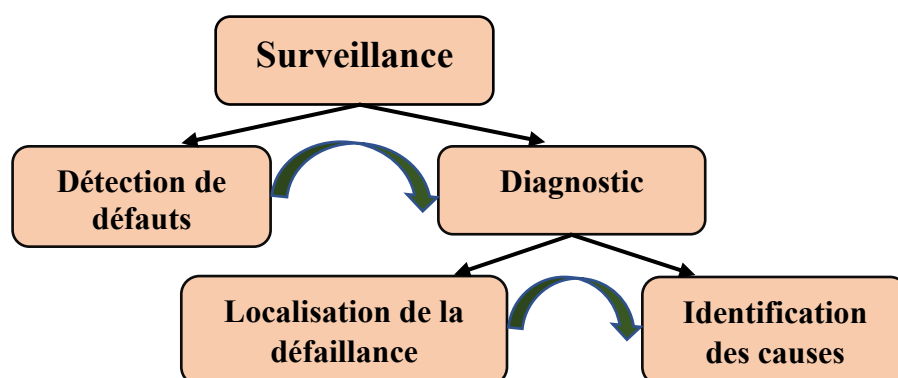


Figure I.2 : Fonctions de la surveillance industrielle [18] .

I.4.1.1. Détection

L'observation de l'évolution du système permet de détecter les éventuelles défaillances ou anomalies. La détection se fait donc par l'analyse des signaux et indicateurs afin de repérer tout comportement anormal qui pourrait indiquer un dysfonctionnement [19].

I.4.1.2. Diagnostic

Le diagnostic consiste à isoler le défaut, le localiser, le caractériser, ainsi qu'identifier sa nature. Il se divise en deux aspects : la localisation et l'identification des causes. Localiser signifie trouver la partie en panne, tandis qu'identifier les causes signifie trouver les raisons derrière la situation anormale [20].

I.5. Techniques de surveillance et d'analyse

La surveillance des défauts et leur diagnostic impliquent l'obtention des symptômes caractéristiques du fonctionnement du dispositif surveillé et les analyser pour déterminer l'état du système. Souvent, les symptômes sont identifiés en se basant sur la compréhension du comportement sain préalablement acquise [21]. Les divers défauts entraînent des couples de pulsations, des variations de vitesse, une modification de la signature de courant, une élévation de température et des changements dans les paramètres électriques, ainsi qu'une augmentation du bruit et des vibrations.

C'est pourquoi la détection des problèmes des machines asynchrones repose fréquemment sur la surveillance de ces indicateurs [22]. Étant donné que de nombreux travaux ont été réalisés sur cet aspect depuis longtemps, il existe ainsi plusieurs méthodes et technologies pour diagnostiquer les défauts, notamment ceux des roulements. Nous pouvons mentionner, entre autres, le contrôle de la température par thermographie, le contrôle des débris dans les huiles, l'analyse acoustique et le contrôle du signal vibratoire par l'analyse vibratoire.

La section suivante présente brièvement chacune de ces techniques d'analyse, ainsi que leurs nombreux avantages et différents domaines d'application.

I.5.1. Analyse d'huile

L'analyse d'huile est une technique d'inspection et de surveillance qui implique l'analyse chimique et physique de l'huile de lubrification pour détecter les signes de dégradation, de contamination ou de problèmes potentiels dans les équipements. Les avantages de cette technique sont nombreux parmi lesquels, elle permet de :

- Surveiller la présence de particules solides, d'eau, de carburant ou d'autres contaminants dans l'huile, qui peuvent réduire son efficacité lubrifiante et endommager les équipements ;
- Optimiser les intervalles des vidanges d'huile en se basant sur les données réelles plutôt que sur des intervalles prédéfinis, ce qui conduit à des économies sur les frais d'entretien.

Cependant, il est essentiel de souligner que cette méthode ne permet pas une localisation précise de la défaillance, mais qu'elle est seulement utile pour contrôler les caractéristiques physico-chimiques du lubrifiant utilisé [23].

I.5.2. Thermographie IR

La thermographie infrarouge se fait par l'utilisation de l'imagerie thermique qui permet de détecter et localiser le défaut provoqué par l'augmentation de la température. Elle offre également la possibilité de voir de manière spatiale comment la chaleur se propage dans les régions sous surveillance. Cette technique est largement utilisée et elle permet de :

- Détecter les variations de température anormales qui peuvent indiquer des problèmes tels que les surchauffes, les points chauds ou les zones de refroidissement inefficace ;
- Détecter les imperfections dissimulées ou les variations de température invisibles à l'œil nu, telles que les pertes de chaleur et les dysfonctionnements électriques.

La spectroscopie infrarouge est un outil puissant pour observer et comprendre les changements de température des appareils, mais elle n'est pas aussi précise qu'une analyse approfondie et détecte les défauts plus tard que la vibration.

I.5.3. Analyse acoustique

L'utilisation de l'analyse acoustique est une méthode en développement pour contrôler la condition du roulement en permettant de détecter les anomalies en se basant sur l'interprétation des sons émis par les machines, les bruits anormaux, les vibrations indésirables et les problèmes potentiels. Cette méthode offre également la possibilité de :

- Identifier les signes précurseurs de défaillances ou dysfonctionnements des équipements des frottements excessifs ou des vibrations anormales ;
- Localiser les sources des problèmes en identifiant les zones spécifiques des équipements qui génèrent des sons anormaux ;
- Réaliser des inspections non intrusives, sans avoir besoin de démonter les équipements, ce qui permet de minimiser les périodes d'arrêt et les dépenses de maintenance.

Comme toutes les autres techniques, l'analyse acoustique présente de nombreux avantages. Cependant, il est important de noter qu'elle peut être limitée dans certaines situations où elle peut être sensible aux bruits ambiants. En cas d'un bruit anormal, la détection peut ensuite être soumise à une analyse vibratoire pour une évaluation plus approfondie [23].

I.5.4. Analyse vibratoire

La surveillance par l'analyse vibratoire implique de mesurer et d'analyser les vibrations générées par les machines. Elle permet de repérer les éventuels problèmes mécaniques comme : les déséquilibres, les défauts élémentaires du roulement et les défauts des composants des engrenages. L'intérêt de cette technique est inestimable car elle permet de :

- Détecter précocement les signes de défaillance mécanique en identifiant les vibrations anormales et les changements dans les caractéristiques vibratoires des équipements ;
- Localiser les sources de vibrations en identifiant les composants spécifiques qui génèrent les vibrations indésirables ;
- Prévenir les pannes coûteuses en prenant des mesures préventives basées sur les données de vibration ;
- Réaliser des inspections non intrusives, sans avoir à démonter, permet de diminuer périodes d'immobilisation et les dépenses liées à la maintenance.

En conclusion, l'analyse vibratoire est une méthode précieuse pour surveiller l'état des équipements et détecter les problèmes mécaniques, ce qui permet de la sélectionner parmi les meilleures techniques de surveillance adoptées dans le secteur industriel, comme le montre la figure I.3.

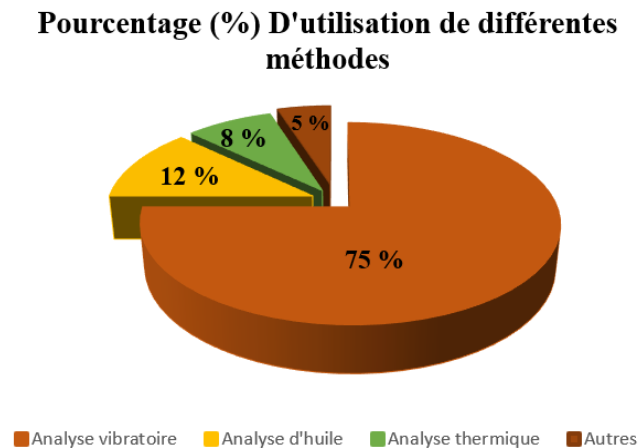


Figure I.3 : Statistiques sur les diverses techniques de surveillance des équipements tournants [19].

De cet effet, la prochaine section se concentrera sur une présentation détaillée de la surveillance par analyse vibratoire.

I.6. Surveillance par analyse vibratoire

L'évaluation de l'état de fonctionnement des machines est effectuée à l'aide de la surveillance par analyse vibratoire en mesurant et en analysant les vibrations qu'ils génèrent pendant leur état de marche.

I.6.1. Définition d'une vibration

Selon la norme ISO 2041, Une vibration se décrit comme le changement temporel de l'intensité d'une caractéristique du mouvement ou de la position d'un système mécanique, lorsque cette intensité varie alternativement autour d'une certaine valeur de référence [24].

En pratique, un objet oscille lorsqu'il effectue un mouvement de va-et-vient autour d'une position neutre ou initiale. Ce phénomène peut être provoqué par une force mécanique

indésirable ou une perturbation externe. Un système mécanique vibre en effectuant des oscillations régulières autour de sa position de repos, entraînant des vibrations excessives, des bruits et même des déformations au système [25].

I.6.2. Caractéristique d'une vibration

Une vibration est représentée sous forme un signal vibratoire qui est définie par son amplitude, sa période et sa fréquence.

- **L'amplitude** : se note par A , correspond à l'écart de la valeur par rapport au point d'équilibre et peut être :
 - Le point de crête maximale par rapport au point de repos ;
 - La double amplitude, également connue sous le nom de crête à crête ;
 - L'amplitude efficace notée par RMS (Root Mean Square).
- **La période** : notée par T , et est mesurée en seconde (s) en représentant la durée correspondant à l'intervalle de temps nécessaire pour effectuer un cycle complet.
- **La fréquence** : désignée par f , et représente le nombre de cycles par seconde. Elle se formule en fonction de la période selon la relation suivante : $f = \frac{1}{T}$ et s'exprime en Hertz (Hz) sachant que ($1 \text{ Hz} = 1 \text{ s}^{-1}$).

I.6.3. Type des signaux vibratoires

Les différents types des signaux de vibrations produits par les machines tournantes sont multiples et peuvent être regroupés en diverses catégories en se basant de leurs caractéristiques. La figure I.4 ci-dessous montre en détail ses différents types.

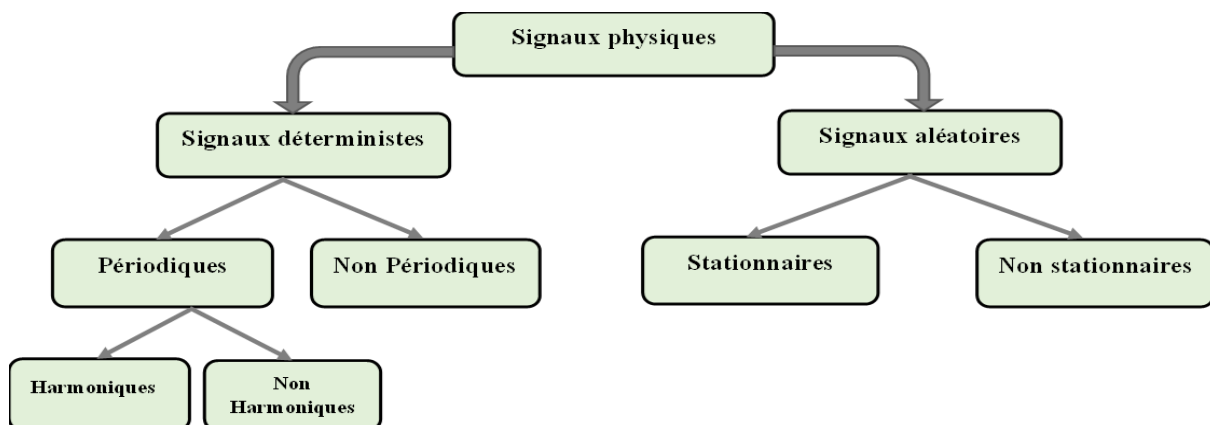


Figure I.4 : Différentes catégories des signaux de vibrations.

I.6.3.1. Signaux déterministes

Un signal quelconque est considéré comme déterministe lorsqu'il est éventuel de déterminer à chaque instant « t » donné son amplitude [26]. Ce type de signal est entièrement déterminé par une fonction mathématique ainsi présenté par un graphique. Il peut avoir des variations périodiques comme celles non périodiques.

I.6.3.1.1. Signaux périodiques

De sa dénomination un signal périodique présente une forme qui se répète à un intervalle régulier, appelée période. Son allure est décrite par la fonction suivante : $x(t) = x(t + nT)$ pour toute valeur de n , « n » étant un entier. Les signaux périodiques également peuvent être harmoniques ou non harmoniques.

- **Signaux périodiques harmoniques**

Le signal sinusoïdal est l'exemple le plus courant qui représente un signal harmonique et qui est décrit par la formule suivante : $x(t) = A \sin(2\pi ft + \vartheta)$. La figure I.5 montre la fameuse allure d'un signal de type périodique harmonique.




Figure I.5 : Allure d'une onde de type périodique harmonique [19].

- **Signaux périodiques non harmoniques**

Également appelées signaux complexes, représentent une composante des signaux de type harmoniques avec des amplitudes maximales variées, dont les fréquences sont des multiples d'une fréquence fondamentale, comme illustré dans la figure I.6.




Figure I.6 : Allure d'un signal de type périodique non harmonique [19].

I.6.3.1.2. Signaux non périodiques

Un signal non périodique est un signal qui existe à tout instant « t », mais ne se répète pas régulièrement dans le temps, comme on peut le voir dans la figure I.7.




Figure I.7 : Représentation d'un signal non périodique [19].

Les signaux déterministes sont généralement utilisés dans les domaines où il est important de réaliser un contrôle précis sur les caractéristiques du signal. Cependant, on peut remarquer que dans de nombreuses situations réelles, les signaux peuvent être soumis à des influences aléatoires ou imprévisibles, ce qui les rend non déterministes (aléatoires).

I.6.3.2. Signaux aléatoires

À la différence des signaux déterministes, les signaux de type aléatoires sont caractérisés par leur incapacité de trouver leurs amplitudes à tout moment donné. Ils sont également classifiés en deux catégories : les signaux stationnaires et les signaux non stationnaires. Un exemple de signaux aléatoires est représenté dans la figure I.8.




Figure I.8 : Représentation d'un signal aléatoire [19].

- **Signaux aléatoires stationnaires**

Les signaux stationnaires sont des signaux dans le contenu fréquentiel reste invariable dans le temps.

- **Signaux aléatoires non stationnaires**

Les signaux non stationnaires sont des signaux dont le contenu fréquentiel varie dans le temps.

La section qui suit sert à une présentation plus explicative des types des signaux de vibrations générés par les équipements tournants et spécifiquement par les composants mécaniques abordés dans le cadre de cette thèse.

I.6.4. Nature des vibrations générées par les machines tournantes

Les signaux de vibrations entraînés par les équipements tournants sans généralement de type déterministe qu'aléatoire ou stationnaire [27]. Le Tableau I.2 ci-dessous résume les différents types des vibrations générées par les composants mécaniques des machines tournantes.

Tableau I.2 : La nature des vibrations générées par les organes mécaniques.

| Nature de vibration | Organes générateurs de vibration |
|--|--|
| Périodique de type sinusoïdal simple | Ce type de vibration est causé par le balourd des arbres et de rotor d'un système mécanique. |
| Périodique de type sinusoïdal complexe | Un tel type de vibration représente les engrenements causés par les engrenages des machines tournantes. |
| Périodique de type impulsif | Ce type de vibration est causé par les écaillages des roulements des machines tournantes dans le cas du fonctionnement anormal. |
| Aléatoire de type impulsif | Ce type de vibration peut être généré par un manque de lubrification d'un roulement ou par la cavitation dans une pompe. |

I.6.5. Chaîne de collecte des vibrations dans les machines

Une bonne connaissance de la chaîne de mesure des vibrations est essentielle pour garantir une haute qualité de détection et de diagnostic de défauts dans les machines tournantes par analyse vibratoire, ce qui inclut les étapes suivantes en particulier :

- Choix de capteurs convenables pour la prise de mesure ;
- Choix de l'emplacement de capteurs ;
- Conditionnement du signal mesuré ;
- Enregistrement du signal pour son traitement.

La figure I.9 représente un organigramme bien détaillé du processus de la prise de mesure des vibrations générées par les machines tournantes tout en incluant les principales étapes.

I.6.5.1. Choix de capteurs de la prise de mesure

Le premier maillon de la chaîne de mesure est le capteur de vibrations, qui convertit les vibrations mécaniques en un signal électrique exploitable. Le capteur est choisi en fonction de la vitesse de la machine en rotation et on distingue :

- Capteur de déplacement (proximètre) ;
- Capteur de vitesse (vélocimètre) ;
- Capteur d'accélération (accéléromètre).

I.6.5.1.1. Capteur de déplacement (proximètre)

Le capteur de déplacement est conçu pour détecter et quantifier les variations de position entre deux éléments d'un système mécanique. Généralement, ce type est utilisé dans les machines tournantes pour mesurer le mouvement relatif entre l'arbre et le palier, causés par des vibrations dues aux défauts de balourd ou désalignement. La grandeur de déplacement revient aux phénomènes à basse fréquence $f \leq 100$ Hz.

I.6.5.1.2. Capteur de vitesse (vélocimètre)

Les vélocimètres ou également capteurs électrodynamiques sont utilisés principalement pour les machines à faible vitesse de rotation telle que les aéroréfrigérants, permettant de mesurer la vitesse de rotation magnétique. Ce type de capteur fournit une grandeur de vitesse qui concerne les phénomènes à une large gamme de fréquence allant jusqu'à $f \leq 1000$ Hz.

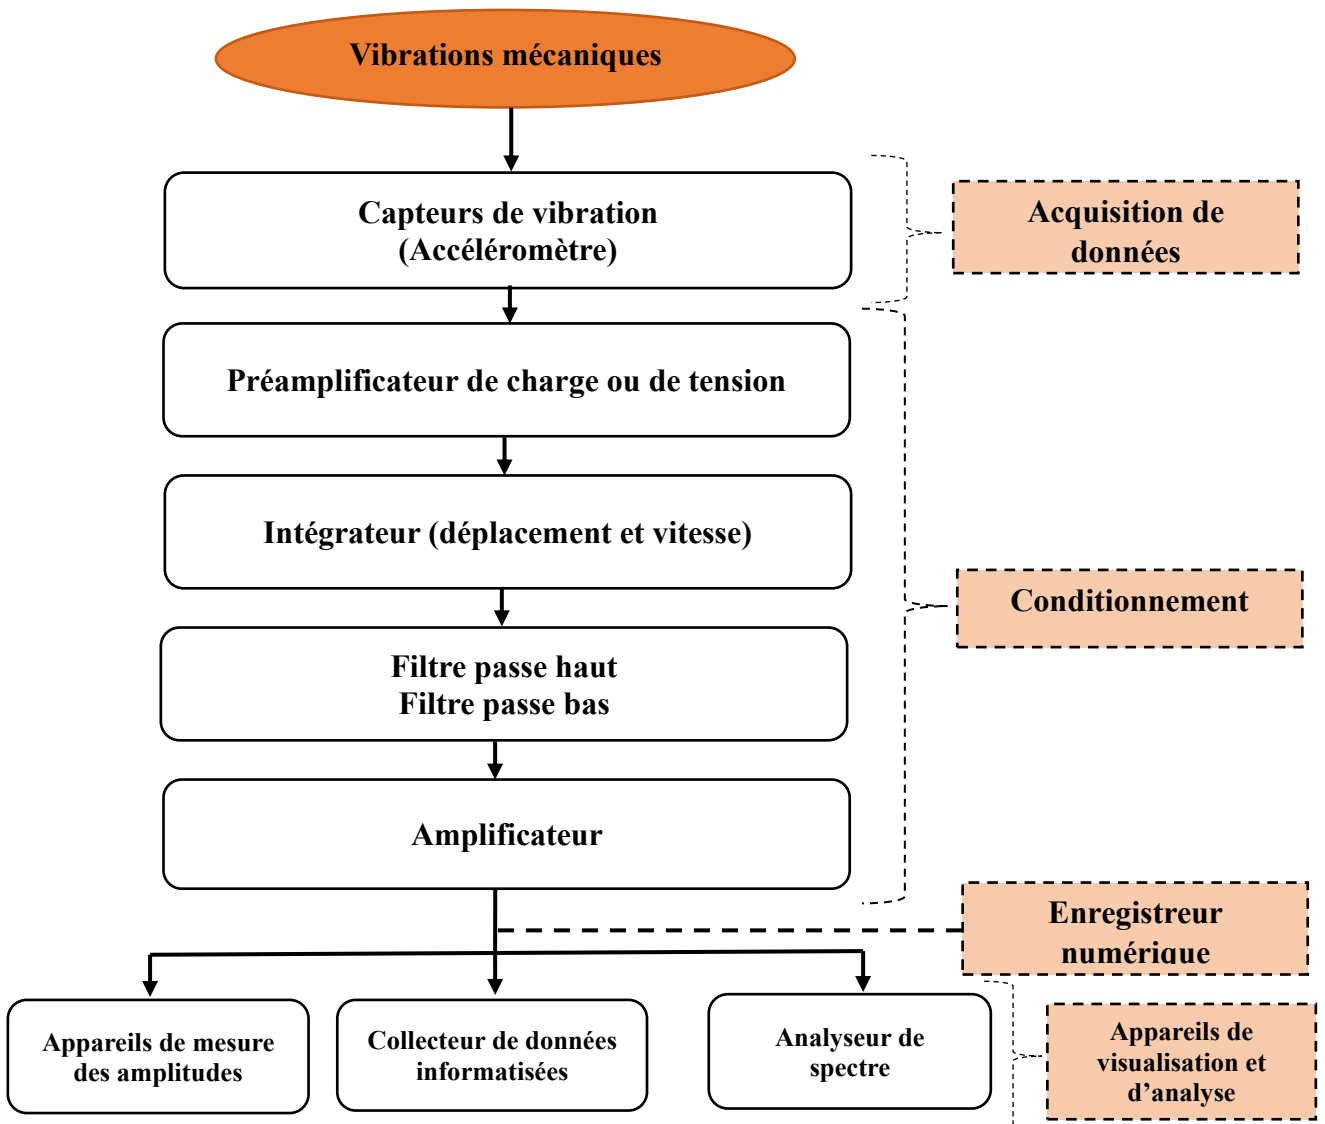


Figure I.9 : Type d'une chaîne de mesures des signaux vibratoire [13].

I.6.5.1.3. Accéléromètre

Les accéléromètres de type piézo-électrique sont les capteurs les plus utilisés dans l'analyse vibratoire. Ils offrent plus d'avantages tout en générant un signal électrique correspondant à l'accélération du signal vibratoire de la machine tournante et plus précisément de ses composants qui délivrent de hautes fréquences de vibration tels que les roulements et les engrenages. L'accéléromètre est constitué des disques en cristal piézo-électrique qui sont mis entre deux masses importantes par le biais d'un ressort de tarage important. Lorsque la machine produit des vibrations, le capteur détecte ces vibrations par les masses qui exercent une pression sur les disques qui également, grâce à leur effet piézo-électrique, créent en sortie une charge électrique proportionnelle aux oscillations mécaniques appliquées et également à l'accélération

générée de ces deux masses. Le capteur piézo-électrique peut détecter une haute gamme de fréquence $f \leq 20000$ Hz, ce qui favorise leur utilisation dans l'analyse vibratoire des machines tournantes de haute puissance.

I.6.5.2. Choix de l'emplacement de capteurs

Le choix adéquat de l'emplacement du capteur est une étape primordiale pour la réussite de l'analyse vibratoire. Pour un emplacement optimal il faut :

- Choisir les points les plus sûrs, où il y a un bon chemin de transmission mécanique jusqu'au support (l'élément mobile) ;
- Éviter les points qui vibrent et qui ne représentent pas les forces directes sur l'élément mobile car ils ne donnent pas les vraies mesures de la vibration et ça risque d'impacter la répétabilité ;
- Vérifier qu'il ne y'a ni l'air ni de joints entre l'élément mobile et le capteur mis en place, car dans le cas contraire les mesures de vibrations ne seront pas fiables ;
- Une bonne sélection de la direction de l'implémentation de capteur, donc il est nécessaire d'avoir des mesures verticales, horizontales et axiales, pour détecter et distinguer les conditions de défaut ;
- La surface de l'emplacement du capteur doit être lisse et plane.

I.6.5.3. Conditionnement de signal mesuré

La phase de conditionnement comprend le préamplificateur, l'intégrateur, le filtre et l'amplificateur, et elle joue un rôle essentiel dans le processus de mesure de vibrations.

- Le préamplificateur, est situé à proximité du capteur, ou peut parfois être intégré à celui-ci. Son rôle est d'amplifier initialement le signal et de convertir les ondes élastiques en un signal électrique ;
- L'intégrateur sert à convertir le signal d'accélération en un signal de vitesse ou de déplacement ;
- Le filtre (passe-haut et passe-bas) sert à limiter le signal sur une certaine plage de fréquence. Le filtre passe-haut permet d'éliminer les bruits provenant du fonctionnement de l'installation sur lesquels une mesure en service est achevée ;
- L'amplificateur permet la préparation du signal et puis sa transmission à l'appareillage d'analyse pour qu'il soit traité par la suite.

Une fois la phase de la prise de mesure des vibrations est achevée, les signaux vibratoires vont être traités et analysés par l'utilisation des différents outils qui représentent le pilier de la surveillance vibratoire. Ces outils seront présentés dans le paragraphe qui suit.

I.6.6. Outils de surveillance vibratoire

Les outils couramment utilisés pour la surveillance vibratoire peuvent être regroupés en deux grandes catégories [28] :

- Les outils de l'analyse temporelle basée sur des indicateurs destinés proprement à la surveillance et permettent de détecter la présence d'un défaut dès que les valeurs de ces indicateurs dépassent un seuil d'alerte préalablement bien déterminé. Parmi les indicateurs communément utilisés on a (valeur efficace ou RMS, facteur de crête, kurtosis et l'énergie).
- Les outils de l'analyse spectrale proprement destinés au diagnostic en permettant d'identifier avec précision la nature de chaque défaut et d'évaluer sa gravité, parmi lesquels on a (FFT, spectre d'enveloppe, cepstre, ondelette et HHT).

Ces outils vont être présentés avec plus de détails dans le chapitre II.

I.7. Technologie des roulements

Dans la littérature, plusieurs recherches approfondies ont été menées sur des moteurs asynchrones portant des caractéristiques variées, dans le but d'analyser la répartition des pannes qui se produisent dans ces systèmes [29,30, 31]. A l'issue de ces différentes recherches, les résultats obtenus ont révélé que les pannes liées aux roulements représentent environ 41% à 69% de l'ensemble total des pannes du moteur asynchrone, comme il est illustré dans la figure 1.10 en regroupant les défauts en quatre catégories : roulements, stator, rotor et autres.

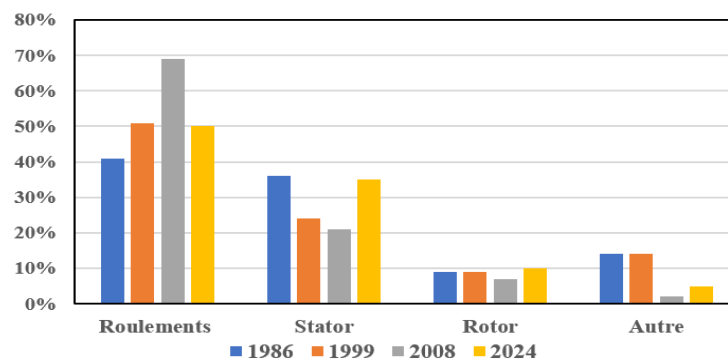


Figure I.10 : Distribution du taux de pannes rencontrées dans les machines asynchrones[3,4].

En connaissant la gravité des défauts se produisant par les roulements dans les machines asynchrones, il est logique d'orienter notre étude vers la détection et le diagnostic de ces derniers. Le roulement est un organe mécanique assurant la rotation d'un élément mobile, appelée également arbre ou palier, par rapport à un élément fixe selon un axe de rotation défini, dans le but de réduire le frottement lors de la transmission des charges (efforts) entre ces deux éléments [32]. Les roulements sont largement employés dans la construction mécanique, en particulier dans le secteur des machines tournantes et l'industrie automobile.

I.7.1. Constitution des roulements

Les roulements sont composés essentiellement de quatre organes : bague extérieure, bague intérieure, entre les deux se trouve un organe de lubrification (cage) et les éléments roulants, comme illustre la figure I.11.




Figure I.11 : Structure générale d'un roulement [13].

- a) **Bague extérieure** : elle est le plus souvent en acier et elle se positionne dans un logement fixe ou un moyeu tournant, comportant le chemin de roulement (piste) sur sa surface intérieure.
- b) **Bague intérieure** : elle est en acier et elle se positionne sur un arbre fixe ou mobile, comportant le chemin de roulement sur sa surface extérieure.
- c) **Cage** : c'est l'organe qui maintient et sépare les éléments roulants en position les unes par rapport aux autres et à des distances spécifiques, elle peut être sous différentes formes (en polyamide, tôle, acier, laiton ou résine). La cage peut être parfois accompagnée par un joint de protection qui retient le lubrifiant et empêche l'entrée de poussières.

- d) **Eléments roulants** : ils sont habituellement en acier et ils peuvent être des billes, des rouleaux ou des aiguilles, assurant la rotation relative des deux bagues l'une par rapport à l'autre avec un frottement minimal.

I.7.2. Principaux types de roulements

Il est clair que les types de roulements diffèrent en fonction des éléments roulants (billes, rouleaux) qui sont en contact avec les pistes des bagues de roulements de manière différente, et pour assurer un bon fonctionnement tout en minimisant les coûts, il est nécessaire de choisir le type de roulements adéquat. Pour un choix optimal de type de roulements, plusieurs facteurs importants sont pris en compte tels que :

- La capacité de la charge du roulement qu'il peut supporter, sachant que chaque type de roulement est spécifiquement conçu pour supporter soit une charge axiale, soit une charge radiale, ou peut même supporter les deux charges lorsqu'on parle de charge combinée ;
- La vitesse de rotation de roulement, notant que certains types de roulements ne sont pas capables de supporter une des vitesses élevées ;
- Les conditions d'utilisation à les quelles le roulement va fonctionner, tels que la température, les chocs, les vibrations ;
- La durée de vie de roulement ;
- Le choix de dispositif d'étanchéité qui dépend également du type de lubrifiant.

D'après ces nombreux facteurs, on peut lister les différents types de roulements qu'il peut exister, en les regroupant en deux grandes catégories : les roulements à billes et les roulements à rouleaux. Ainsi pour faciliter la différenciation entre ses types, la figure I.12 sert à les détailler.

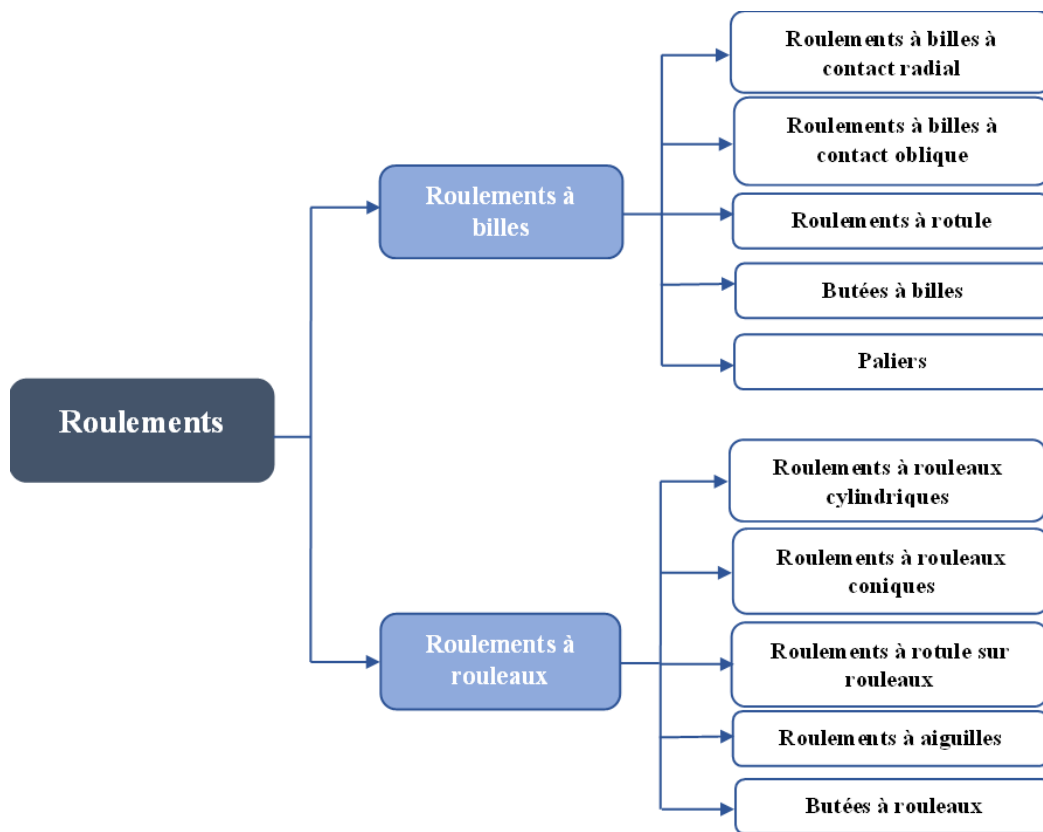


Figure I.12 : Synthèse des différents types de roulements.

I.7.2.1. Roulements à billes

Les roulements à billes sont généralement caractérisés par la forme des pistes des bagues qui les conduisent. Les billes sont en contact ponctuel avec ces pistes, cependant avec l'augmentation des charges agissant sur le roulement, le point de contact devient une zone elliptique. Cela entraîne un faible frottement, en permettant aux roulements à billes de supporter des vitesses élevées mais, en revanche, d'être limités à certaine capacité de charge. A cet effet, les roulements à billes se subdivisent selon la direction des charges qu'ils supportent. Les roulements à billes radiaux supportent des charges radiales, tandis que les roulements à billes axiaux ou également appelés « butées » supportent des charges axiales. Les différents types que peuvent avoir les roulements à billes sont cités dans la section suivante :

I.7.2.1.1. Roulements à billes à contact radial à une seule rangée

Ce type de roulements est le plus souvent utilisé dans de nombreux domaines, grâce à sa conception spécifique qui est caractérisée par une gorge sur les deux bagues de roulement, permettant aux billes de s'intégrer plus profondément dans le roulement. Ce qui permet au

roulement de supporter une capacité des charges élevées avec une meilleure répartition de ces charges dans la direction radial ou dans une direction combinée en deux sens. Un exemple type de roulement à contact radial est illustré dans la figure I.13.



Figure I.13 : Roulement à contact radial à une seule rangée [13].

I.7.2.1.2. Roulements à billes à contact oblique

Les roulements à contact oblique sont caractérisés par des chemins de roulements (pistes) inclinés sur la bague intérieure et la bague extérieure, ce qui produit un contact oblique entre les billes et les pistes de roulements. Cela permet à ce type de roulements de supporter une capacité importante des charges axiales mais dans un seul sens. En revanche, les roulements à contact oblique à deux rangées de billes ont deux chemins de roulements pour chacune des bagues de roulements, ce qui les rend capables de supporter des charges élevées dans les deux sens. La figure I.14 montre bien le roulement à billes à contact oblique avec les deux types, à une seule rangée et à double rangée de billes.



Figures I.14 : Roulements à billes à contact oblique. (a) : Roulement à contact oblique à une rangée de billes. (b) : Roulement à contact oblique à double rangée de billes [13].

I.7.2.1.3. Roulements à rotule sur double rangée de billes

La construction des roulements à rotule sur double rangée de billes est caractérisée par un basculement des axes des bagues intérieure et extérieure par rapport à l'axe central du roulement. Sachant que la bague extérieure comporte deux chemins de roulements (pistes) à contact ponctuel des billes sur la bague, tandis que la bague intérieure comporte une seule piste de forme sphérique. Cette conception permet de compenser les défauts d'alignement que peuvent être produits par l'arbre, ce qui rend les contraintes et les charges sur le roulement très réduites. Les roulements à rotule sur double rangée de billes sont principalement utilisés pour les applications où les mouvements oscillatoires ou d'inclinaison ont lieu, tels que les transmissions automobiles et les applications d'agricoles. Un exemple de roulement à rotule sur deux rangées de billes est montré sur la figure I.15.



Figure I.15 : Roulement à rotule sur deux rangées de billes [13].

I.7.2.1.4. Butées à billes

Butées ou roulements axiaux, de leur nomination, ce type de roulements supportent des charges axiales exercées principalement dans l'axe de l'arbre. Ces butées sont conçues à partir de deux composants, un boîtier qui est fixe et attaché à la machine et un roulement qui tourne avec l'arbre. Les billes leur permettent de supporter des vitesses plus élevées, bien qu'elles ne supportent pas des charges axiales importantes. Les butées à billes peuvent être à simple ou double effet.

- ✚ **Butées à simple effet :** sont composées d'une rondelle-arbre fixée sur l'arbre, d'une rondelle-logement et une cage comportant les billes. Ces butées supportent purement

les charges axiales dans un seul sens, elles peuvent être utilisées dans les pompes et les moteurs électriques.

- ✚ **Butées à double effet** : supportent principalement les charges axiales qui changent fréquemment de direction, donc elles tournent dans deux sens de rotation, ce qui nécessite une composition d'une rondelle-arbre, de deux rondelles-logement et deux cages à billes. Elles peuvent être utilisées dans les machines à outils et les grues. La figure I.16 montre des modèles des butées à billes à simple et double effet.



Figure I.16 : Butées à billes. (a) : à simple effet. (b) : à double effet [13].

I.7.2.1.5. Paliers des roulements à billes

Un palier est un organe mécanique qui sert à guider et supporter en rotation des arbres de transmission. Le palier est fixé sur une machine et composé d'un roulement à billes dont sa bague intérieure est attachée sur un arbre par des vis de blocage, comme il est illustré dans la figure I.17. Ces paliers peuvent être, paliers auto-aligneur ou paliers à deux parties.

- **Paliers auto-aligneur** : qui répondent à des charges importantes où ils peuvent corriger les défauts d'alignements, ils peuvent ainsi supporter des grandes vitesses et des vibrations.
- **Paliers à deux parties** : qui sont conçus pour assurer une excellente stabilité tout en supportant des charges importantes.



Figure I.17 : Palier de roulements à billes [13].

I.7.2.2. Roulements à rouleaux

Les roulements à rouleaux sont appropriés pour supporter des charges plus lourdes comparant aux roulements à billes. La diversité de ces roulements dépend de la forme de rouleaux qui peut être cylindrique, conique, ou aiguille en formant les différents types de roulements et qui sont cités et décrits brièvement dans la section suivante.

I.7.2.2.1. Roulement à rouleaux cylindriques

Les roulements à rouleaux cylindriques sont caractérisés par des rouleaux sous forme de cylindre, ce qui permet d'avoir un contact linéaire avec les deux bagues de roulements. Par conséquence, cela favorise à ce type de roulements de supporter une capacité des charges radiales importante mais des vitesses de rotation plus faibles que les roulements à billes qui supportent des charges légères et des vitesses très élevées. L'avantage de ce type de roulements est qu'ils permettent une distribution uniforme des charges radiales exercées, ce qui augmente la durée de vie du roulement. Un exemple type d'un roulement à rouleaux cylindriques à une seule rangée est illustré dans la figure I.18



Figure I.18 : Roulement à rouleaux cylindriques à une seule rangée [13].

I.7.2.2.2. Roulements à aiguilles

Les roulements à aiguilles sont des dérivés des roulements à rouleaux cylindriques au diamètre très réduit par rapport à leur longueur. Leur conception spécifique des rouleaux sur les chemins de roulement leur permet de supporter des charges radiales plus élevées, également d'empêcher les contraintes de bord aux extrémités des aiguilles, ce qui permet de prolonger la durée de vie de ce type de roulements. La figure I.19 montre un modèle d'un roulement à aiguilles.



Figure I.19 : Roulement à aiguilles [13].

I.7.2.2.3. Roulements à rouleaux coniques

Les roulements à rouleaux coniques sont principalement conçus pour supporter des charges combinées entre les charges radiales et axiales agissant en même temps. La capacité des charges axiales des roulements à rouleaux coniques augmente avec l'angle de contact. En effet, plus l'angle de contact est grand plus la capacité de charges appliquées est importante. Comparant aux autres types de roulements, les roulements à rouleaux coniques sont composés du cône qui correspond à la cage intérieure comportant les rouleaux, et de la cuvette qui correspond à la cage extérieure. Cette conception spécifique permet à la bague intérieure et la cage avec les rouleaux d'être montés indépendamment de la bague extérieure, ce qui facilite le montage, le démontage et la maintenance de ces roulements. Un exemple de roulements à rouleaux coniques est montré dans la figure I.20.



Figure I.20 : Roulements à rouleaux coniques. (a) : Roulement à une seule rangée. (b) : Roulement à quatre rangées [13].

I.7.2.2.4. Roulements à rotule sur rouleaux

Un roulement à rotule sur rouleaux comporte une bague intérieure, deux rangées de rouleaux, une cage qui les maintient et une bague extérieure. Deux chemins de roulement sont tracés dans les gorges continues de la bague intérieure et une piste sphérique sur la bague extérieure, ce qui rend la construction meilleure aussi bien avec des rouleaux cylindriques que coniques. Cette conception également est parfaite pour compenser les défauts de désalignement de l'arbre par l'auto-aligneur qui corrige le positionnement de l'arbre, diminue les frottements tout en supportant une capacité de charge radiale importante à des vitesses très élevées. Un modèle de roulement à rotule sur rouleaux à deux rangées est montré sur la figure I.21.



Figure I.21 : Roulement à rotule sur rouleaux à deux rangées [13].

I.7.2.2.5. Butées à rouleaux

Une butée à rouleaux est appelée ainsi en raison de sa structure contenant principalement de rouleaux. Ces butées sont utilisées dans le cas où les butées à billes ne supportent pas certaine capacité de charges. Les butées à rouleaux sont destinées à supporter de très fortes charges, uniquement axiales et dans un seul sens et sont généralement composées d'une rondelle-arbre, une rondelle-logement et la cage à rouleaux. La rondelle-arbre et la cage à rouleaux sont montées séparément à la rondelle-logement. Le chemin de roulement sur la rondelle-logement est de forme sphérique, ce qui permet de supporter des oscillations optimales. Un exemple d'une butée à rouleaux cylindrique est illustré dans la figure I.22.



Figure I.22 : Butée à rouleaux cylindrique [13].

L'utilisation de chacun de ces types de roulements dépend de l'application dont il va intervenir. Il existe donc d'autres types de roulements spéciaux d'une fabrication spéciale pour

répondre à des exigences des applications particulières, tels que les roulements aéronautiques, les roulements des boîtes d'essieu et les roulements utilisés pour des guidages linéaires (guidage linéaire à billes, à rouleaux ou aux patins).

I.8. Conclusion

Due aux conditions anormales de fonctionnement, les roulements sont les organes les plus sollicités aux défaillances dans les machines tournantes. Les défauts de roulements peuvent produire des pertes financières lourdes et provoquer la sécurité humaine et matérielle. Pour parvenir à résoudre ces problèmes, la surveillance par l'analyse vibratoire semble être la technique la plus puissante pour un diagnostic efficace des défauts de roulements, tout en limitant les pertes causées par les arrêts inattendus des machines.

Dans ce chapitre, nous avons présenté toutes notions liées au domaine de la maintenance et la surveillance. Ainsi, nous avons illustré les différentes étapes de la surveillance par l'analyse vibratoire des défauts de roulements. A la fin, nous avons donné un aperçu global sur les différents types de roulements, tout en montrant le domaine d'utilisation de chacun d'eux, cela permet de bien maîtriser les caractéristiques de chaque type de roulement étudié.

Le prochain chapitre sera dédié à l'illustration d'un état de l'art sur les différentes techniques de diagnostic utilisées dans l'analyse vibratoire de roulements.

Chapitre II

Etat de l'art sur les méthodes de diagnostic utilisées dans l'analyse vibratoire de roulements

II.1. Introduction

Nous présentons dans ce chapitre un aperçu général sur les diverses techniques de traitement du signal qui sont largement considérées dans l'analyse vibratoire et qui permettent la caractérisation de l'état du système. Nous avons effectué également une revue bibliographique synthétique sur l'application de chaque outil de traitement des signaux dans la détection des défauts des roulements. Dans la deuxième partie du chapitre présent, nous présentons ainsi les différentes méthodes de diagnostic par l'intelligence artificielle tout en montrant les avantages et les inconvénients de chacune d'entre elles.

II.2. Techniques de traitement des signaux vibratoires

Selon la littérature, on peut observer quatre catégories de représentation. Le récapitulatif présenté dans le Tableau II.1, les méthodes les plus couramment utilisées, qui seront examinées dans cette thèse.

Tableau II.1 : les diverses techniques d'analyse du signal.

| Domaine | Techniques | | |
|-----------------|-------------------------------------|--------------------------------|---------------------------------|
| Temporel | Analyse statistique | | |
| Fréquentiel | Analyse spectrale | Analyse d'enveloppe | Analyse Cepstrale |
| Temps-fréquence | Transformée de Fourier courte terme | Wigner Ville | Transformé de Hilbert Huang |
| Temps-échelle | Transformée en ondelettes | Analyse en Ondelettes Discrète | Analyse en Paquets d'Ondelettes |

II.2.1. Analyse temporelle

Les méthodes temporelles consistent à analyser statistiquement les signaux recueillis à l'aide d'indicateurs globaux et s'appliquent sur des machines simples. Evaluer ces indicateurs implique qu'un défaut est en train de progresser [33]. Cette méthode permet d'identifier les défauts sans pouvoir les localiser précisément, ce qui en fait des outils efficaces pour la surveillance. La première utilisation d'une maintenance conditionnelle reposant sur deux indicateurs statistiques tels que le Kurtosis et la valeur RMS, a été proposé par J. P. Dron [34]. D'autres travaux réalisés par Y. Zhang [35] ont proposé le Skewness et l'écart type comme indicateurs temporels. M.S. Safizadeh [36] et P. Stepanic [37] ont proposé d'autres indicateurs basés sur la combinaison de plusieurs indicateurs utilisés dans la catégorie temporelle, tels que la valeur crête, le facteur crête et le facteur d'impulsion.

Parmi les nombreux indicateurs disponibles, nous avons décidé de présenter quelques-uns mentionnés ci-dessous.

II.2.1.1. Valeur efficace (RMS)

La valeur efficace, dite aussi la valeur RMS, est une mesure caractéristique utilisée pour évaluer l'énergie moyenne du signal. Elle sert à contrôler l'état de la machine lié à l'énergie vibratoire et au risque de détérioration des vibrations [38]. Cependant, il n'arrive pas à repérer les imperfections à fréquence élevée, habituellement dues à la première phase de l'usure des roulements.

$$RMS = \sqrt{\frac{\sum_{i=1}^N (x_i)^2}{N}} \quad (II.1)$$

Avec : x_i la valeur instantanée du signal à i et N le nombre de point du signal.

II.2.1.2. Valeur crête

Il s'agit de la plus grande valeur du signal temporel enregistré [35]. Elle reflète efficacement l'état du roulement, la gravité des défauts amplifie l'impact et la réponse correspondante augmente en conséquence.

$$V_{peak} = \max |(x_i)| \quad i = 1, \dots, N \quad (II.2)$$

Avec : N est le nombre de points du signal.

II.2.1.3. Facteur crête

Le facteur crête (FC) est défini comme le rapport entre la valeur maximale du signal et la valeur efficace du signal.

$$F_C = \frac{V_{Peak}}{RMS} \quad (II.3)$$

Son aspect avantageux réside dans le fait qu'il permet de repérer les imperfections avant la valeur RMS. En réalité, dans un roulement en bon état, le rapport reste à peu près le même et augmente en cas de défaut, tandis que la valeur crête augmente alors que la valeur efficace reste plus ou moins constante [15].

II.2.1.4. Facteur crête-à-crête

Le facteur crête-à-crête correspond à la variation entre les valeurs maximale et minimale du signal. C'est une mesure importante pour évaluer le mouvement des pièces, la distance pouvant être cruciale pour des raisons de contrainte maximale ou de jeu mécanique [39].

$$F_{CC} = \max(x_i) - \min(x_i) \quad (II.4)$$

II.2.1.5. Facteur d'impulsion

Le facteur d'impulsion sert surtout à repérer un défaut dès son apparition, tandis que ses valeurs diminuent progressivement une fois que le défaut est à son apogée. Ce critère permet de mettre en évidence les particularités résultant du contact entre un défaut et les éléments en rotation dans les roulements [39].

$$F_I = \frac{\max(|x_i|)}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (II.5)$$

II.2.1.6. Moments statistiques

L'analyse par les indicateurs statistiques repose sur les moments statistiques initiaux de la variable aléatoire de densité de probabilité. L'équation suivante définit le moment d'ordre r [13].

$$M_r = \int_{-\infty}^{+\infty} (x_i - \bar{x})^r p(x) dx \quad (II.6)$$

❖ Moment d'ordre 1 (la moyenne)

Le premier moment d'ordre définit la moyenne \bar{x} et correspond à l'équation qui suit.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (\text{II.7})$$

❖ **Moment d'ordre 2 (la variance)**

Le deuxième moment donne la variance σ^2 qui montre la dispersion des variables autour de la moyenne. L'écart type σ permet de détecter les défauts de roulement en mesurant la variabilité par rapport à la moyenne, tel qu'indiqué dans l'équation suivante [13].

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (\text{II.8})$$

❖ **Moment d'ordre 3 (Skewness)**

Le coefficient de dissymétrie (Skewness) est représenté par le moment d'ordre 3 et mesure l'asymétrie de la densité de probabilité d'une variable aléatoire. La dissymétrie est une mesure statistique fréquemment employée pour détecter les défauts des roulements des éléments roulants. Cet indicateur est calculé par l'équation suivante [13].

$$Skewness = \frac{1}{N} \sum_{i=1}^N \left(\frac{(x_i - \bar{x})^3}{(N-1)\sigma^3} \right) \quad (\text{II.9})$$

❖ **Moment d'ordre 4 (Kurtosis)**

Le Kurtosis est fréquemment employé pour identifier les dysfonctionnements des machines en rotation. C'est un indicateur qui montre la caractéristique impulsive d'un signal et aide à repérer rapidement un défaut de roulement. Selon les études [40], une valeur de 3 indique un équipement en bon état de fonctionnement, tandis qu'une valeur supérieure à 3 signifie qu'il est défectueux. Il est important d'utiliser le kurtosis avec prudence car il réagit fortement aux valeurs aberrantes, ce qui nécessite de l'appliquer dans un contexte peu compliqué pour éviter les erreurs d'interprétation. La formule qui suit donne cet indicateur [40].

$$Kurtosis = \frac{1}{N} \sum_{i=1}^N \left(\frac{(x_i - \bar{x})^4}{\sigma^4} \right) \quad (\text{II.10})$$

D'autres indicateurs temporels basés sur la combinaison des indicateurs statistiques cités au-dessus sont proposés par S. Sassi et sont nommés par THIKAT et TALAF. Ces deux indicateurs sont définis dans le paragraphe qui suit [13].

II.2.1.7. THIKAT

THIKAT est déterminé en se basant sur diverses mesures statistiques telles que le RMS, le facteur crête-à-crête, le facteur crête et le Kurtosis. Comparé au Kurtosis, le THIKAT est un indicateur moins réactif, mais il présente l'inconvénient de retarder l'alerte concernant la dégradation. Quand la dégradation augmente fortement, le THIKAT deviendra nul et il deviendra impératif d'arrêter la machine [42].

$$THIKAT = \log \left[(Ku)^{F_C} + \left(\frac{RMS}{RMS_0} \right)^{V_{peak}} \right] \quad (II.11)$$

Avec : le RMS_0 est la valeur efficace de signal vibratoire d'un roulement sain.

II.2.1.8. TALAF

Contrairement aux indicateurs classiques (RMS , Kurtosis), TALAF est un outil qui montre comment la détérioration progresse d'un point à un autre. Sa valeur reste constante malgré la présence de multiples défauts [42].

$$TALAF = \log \left[Ku + \frac{RMS}{RMS_0} \right] \quad (II.12)$$

II.2.2. Analyse fréquentielle

La méthode d'analyse fréquentielle utilise la transformée de Fourier pour convertir les données du temps en données de fréquence. La fréquence d'analyse est une approche utile dans le traitement des signaux vibratoires [43]. La détection de certains signaux fréquents aide à repérer et à caractériser les anomalies dans les machines en rotation.

II.2.2.1. Analyse spectrale

La méthode d'analyse spectrale s'appuie sur la transformation de Fourier du signal de vibration, ce qui permet de décomposer tout signal $x(t)$ en signaux sinusoïdaux de base. L'analyse spectrale consiste à identifier la fréquence et l'amplitude de ces sinus, ce qui permet par la suite de tracer la représentation amplitude/ fréquence de $x(t)$ [44]. Analyser le spectre revient à déterminer la fréquence et l'amplitude des sinusoïdes, afin ensuite de représenter l'amplitude en fonction de la fréquence de $x(t)$ [44]. Donc, l'équation suivante définit la transformée de Fourier.

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (\text{II.13})$$

$X(f)$ est la transformée de Fourier, f est la variable de fréquence, t est la variable de temps.

Cette approche est fréquemment employée sur les machines sophistiquées avec de nombreux éléments mécaniques pour détecter la présence éventuelle des défauts, en donnant un tas d'information dans un stade précoce. La transformation de Fourier est discrétisée en utilisant la formule qui suit.

$$X(k) = \sum_{i=1}^N x(i)e^{-j2\pi k \frac{i}{N}} \quad (\text{II.14})$$

Où : $X(k)$ représente la transformée de Fourier discrète pour le numéro d'échantillon i , avec k indiquant la ligne fréquentielle et N étant le nombre total d'échantillons.

II.2.2.2. Analyse cepstrale

La méthode de Fourier part du principe que les signaux manipulés sont stationnaires. Cependant, dans les machines en rotation, les signaux générés ne sont pas constants dans le temps, donc l'analyse spectrale est utilisée pour la détection de défauts et pour surmonter les limites de cette méthode. La méthode de l'analyse cepstrale permet d'identifier les défauts à partir d'un spectre de fréquences. Le cepstre est employé pour décrire les structures périodiques ou les échos cachés dans les spectres. $C(\tau)$ est défini comme l'inverse de la transformée de Fourier du logarithme décimal du spectre du signal ($|X(f)|$), et il est donné par l'équation qui suit [45].

$$C(\tau) = C[x(t)] = TF^{-1} \left[\log \{ TF(x(t)) \} \right] \quad (\text{II.15})$$

La variable τ , appelée fréquence, représentent la dimension d'un temps et correspond aux moments où les dysfonctionnements de la machine surveillée se répètent. Le premier développement de l'approche cepstrale pour les équipements tournants et précisément pour les engrenages était réalisé par Randall [46,47], où le cepstre a largement simplifié l'interprétation des familles de bandes latérales associées aux défauts locaux dans les engrenages. R.H. Lyon et A. Ordubadi ont appliqué l'analyse cepstrale pour l'extraction des signaux de pression des cylindres de moteurs diesel à partir des mesures de réponse acoustique [48]. En outre,

l'utilisation de l'analyse cepstrale est répandue pour repérer les problèmes de dents d'engrenage et, dans une moindre mesure, les problèmes de roulement [49,50].

II.2.2.3. Analyse d'enveloppe

Certains problèmes dans les systèmes mécaniques, comme les roulements, entraînent des variations de fréquence et d'amplitude. Néanmoins, ces variations engendrent des fréquences secondaires dans le spectre du système. Il y a une méthode qui permet de détecter plus tôt les défauts de type choc, c'est l'analyse d'enveloppe qui consiste à démêler les fréquences modulantes en effectuant une opération de démodulation de phase. Cette technique repose principalement sur la transformée de Hilbert (TH) qui est une méthode très importante dans le domaine de traitement du signal et également pour le diagnostic des machines en rotation. La transformée de Hilbert d'un signal $x(t)$ est représenté par $H[x(t)]$ ou $\hat{x}(t)$ et elle est donnée par :

$$H[x(t)] = \hat{x}(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (\text{II.16})$$

Avec : $\hat{x}(t)$ représente la composante imaginaire du signal analytique $Z(t)$ qui est également défini comme :

$$Z(t) = x(t) + i\hat{x}(t) = A(t)e^{-i\varphi(t)} \quad (\text{II.17})$$

Tels que, le signal analytique $A(t) = |x(t)|$ décrit l'enveloppe du signal $A(t)$. Les équations suivantes donnent la phase et la fréquence instantanée du signal :

$$\varphi(t) = \arctg \left[\frac{\hat{x}(t)}{x(t)} \right] \quad (\text{II.18})$$

$$w(t) = \frac{d\varphi(t)}{dt} \quad (\text{II.19})$$

Pratiquement, L'analyse du signal en utilisant la méthode d'enveloppe se fait par trois étapes distinctes :

- ❖ La première étape utilise un filtre passe-bande dans le domaine temporel pour filtrer le signal en se concentrant sur la zone de haute fréquence, afin de supprimer les éléments non désirés ;

- ❖ L'étape suivante du processus implique l'application de la transformée de Hilbert au signal filtré afin de séparer l'enveloppe du signal modulé en amplitude ;
- ❖ Enfin, les défauts et les harmoniques de cette fréquence sont évalués en se basant sur la transformée de Fourier de l'enveloppe.

II.2.2.4. Kurtosis spectral

Comme présenté dans la section précédente, Avant de réaliser une analyse d'enveloppe, il est nécessaire de filtrer par bande-passante et de démoduler le signal. Cependant, le choix d'un filtre passe-bande est déterminé par deux aspects : la fréquence centrale et la plage optimale. Le défaut ne sera repéré que si ces deux éléments sont correctement sélectionnés. Pour y parvenir à cela, le Kurtosis spectral a été suggéré comme approche en utilisant le Kurtosis dans le domaine des fréquences.

Le Kurtosis spectral est donc un descripteur fréquentiel largement utilisé pour caractériser les signaux non stationnaires, il est appliqué pour la première fois dans le but de caractériser et détecter les événements transitoires dans un signal [51,52]. Ce facteur est particulièrement utilisé pour diagnostiquer les machines électriques, cela revient à la simplicité de l'algorithme, ainsi sa capacité qui lui permet de détecter des événements non stationnaires. Le principe de cette technique réside principalement dans le calcul du kurtosis du signal traité pour chaque fréquence, pour précisément distinguer les événements non stationnaires et de bien montrer les bandes de fréquences dont ceux-ci se réalisent. D'après [53], on calcule le kurtosis spectral (KS) d'un processus non stationnaire $x(i)$ en utilisant la formule suivante :

$$K_x = \frac{|H(i, f)|^4}{\langle |H(i, f)|^2 \rangle^2} - 2 \quad (\text{II. 20})$$

Avec : $H(i, f)$ représente l'enveloppe complexe de $x(i)$ à la fréquence f .

Le symbole $\langle F(i) \rangle$ est défini par la formule suivante : $\langle F(i) \rangle = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_N F(i)$ qui signifie la moyenne temporelle d'une fonction $F(i)$. Il y a plusieurs propriétés qui se distinguent, notamment les plus importantes que l'on rappelle brièvement [54].

- Kurtosis spectral des processus stationnaires réguliers ne varie pas en fonction de la fréquence ;
- Pour les processus stationnaires gaussiens, le Kurtosis spectral est toujours égal à zéro ;

- En présence du bruit stationnaire supplémentaire $\eta(i)$, le Kurtosis spectral d'un processus non stationnaire $X(i)$ est défini comme :

$$K_{(x+\eta)}(f) = \frac{K_x(f)}{[1+\rho(f)]} \quad (\text{II.21})$$

Où : f est la fréquence et $\rho(f)$ est le rapport signal-bruit.

Ces caractéristiques permettent de saisir la capacité du K_S à détecter, décrire et situer en termes de fréquence les signaux non stationnaires.

II.2.2.5. Kurtogram

Antoni et Randall sont les premiers qui ont défini le Kurtogram pour généraliser l'aspect du Kurtosis spectral à l'identification des composantes non stationnaires sans nécessiter la connaissance des paramètres du signal, faisant ce qu'on appelle la détection aveugle [53][55]. L'élément fondamental de l'algorithme de calcul du Kurtogram repose sur une configuration de banque de filtres en arbre courante, qui dépend des caractéristiques spécifiques des filtres quasi-analytiques. Soit $h_0(i)$ et $h_1(i)$ deux filtres quasi-analytiques, passe-bas et passe-haut, fonctionnant dans les bandes de fréquences suivantes $\left[0, \frac{1}{4}\right]$ et $\left[\frac{1}{4}, \frac{1}{2}\right]$ [52] :

$$h_0(n) = h(n)e^{j\pi n/4} \quad (\text{II.22})$$

$$h_1(n) = h(n)e^{j3\pi n/4} \quad (\text{II.23})$$

Ces deux filtres sont formés à partir du filtre $h(n)$ qui représente un filtre prototype passe-bas, avec une fréquence de coupure $f_c = \frac{1}{8} + \varepsilon$, $\varepsilon \geq 0$, tout en servant à la construction du banc de filtres arborescent par la réalisation des opérations élémentaires itérées en cascade comme montre la figure II.1 (a), de sorte d'avoir l'arbre de décomposition illustrée dans la figure II.1 (b), dont chaque niveau k représente un banc de filtres uniforme à 2^k bandes. De tel que, $C_k^i(n)$ représente la séquence des coefficients issue du $i^{\text{ème}}$ filtre, $i=0, \dots, 2^k - 1$, au $k^{\text{ème}}$ niveau de l'arbre de décomposition. Le Kurtogram est donc obtenu tout en calculant le facteur du kurtosis sur toutes les séquences de coefficients $C_k^i(n)$:

$$K_k^i = \frac{|C_k^i(n)|^4}{\langle |C_k^i(n)|^2 \rangle^2} - 2 \quad (\text{II.24})$$

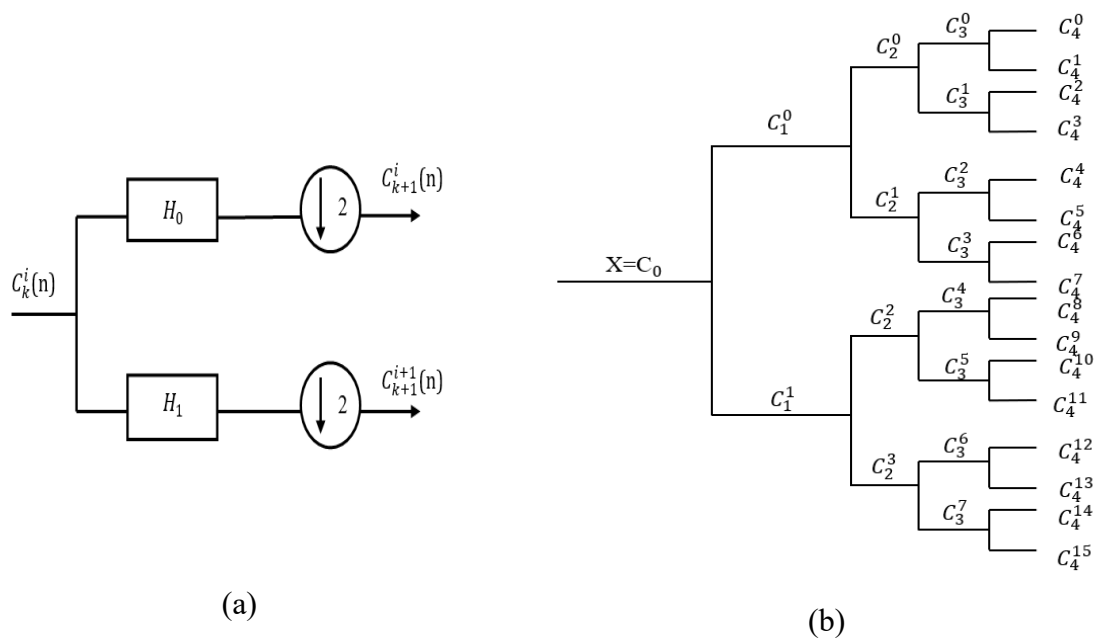


Figure II.1 : (a) : Filtrage par la décomposition élémentaire. (b) : Calcul du Kurtogram par une cascade de filtres en banc.

Le kurtogram a été appliqué dans plusieurs travaux de recherches pour le diagnostic de défaut. Dans [56], Antoni a développé le kurtogram pour la détection des défauts transitoires, ce dernier a bien montré l'efficacité de l'algorithme du kurtogram. Le kurtogram a été utilisé dans de nombreuses études récentes pour détecter les défauts des roulements. Dans [57] S.K. Mirsha a amélioré une technique de résonance en comparant avec le kurtogram pour diagnostiquer les défauts du roulement. [58] et [59] ont développé le kurtogram pour la détection et la classification de défaut de roulement tout en montrant l'efficacité et la convenance de la technique du kurtogram pour extraire parfaitement la bande passante et la fréquence centrale tout en éliminant les informations invalides.

II.2.3. Analyse temps-fréquence

Généralement, les défauts de roulements provoquent l'apparition de chocs, ce qui crée également un signal vibratoire non régulier, limitant ainsi l'utilisation de l'analyse spectrale via la transformée de Fourier. Cela requiert des méthodes pour analyser les caractéristiques spectrales en fonction du temps, d'où l'introduction de l'analyse temps-fréquence pour étudier les signaux non stationnaires et décrire leur évolution temporelle en fréquence. Pendant les deux dernières décennies, l'étude temps-fréquence a suscité un grand intérêt le secteur du diagnostic des défauts des machines industrielles. En réalité, cette analyse concilie les avantages des deux analyses spectrale et temporelle, en décrivant le signal vibratoire à travers le temps, la fréquence

et l'amplitude, permettant ainsi la détection des variations inhabituelles dans la répartition des fréquences d'une signature vibratoire à un moment très spécifique.

Les méthodes d'analyse temps-fréquence vise à [60] :

- ✚ Fournir une illustration du signal en trois dimensions (amplitude-temps-fréquence) comme il est indiqué dans la figure II.2 ci-dessous ;
- ✚ Identifier et surveiller l'évolution des imperfections entraînant une faible puissance de vibration ;
- ✚ Surveiller des machines qui génèrent des chocs périodiques de grande amplitude lors de leur fonctionnement normal.

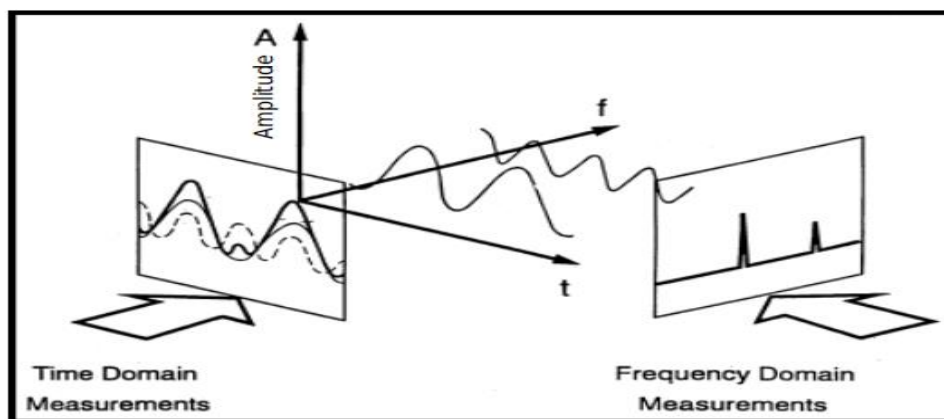


Figure II.2: Cordonnées en 3D illustrant le temps, la fréquence et l'intensité d'un signal [60].

Il y a deux types d'analyse temps-fréquence à considérer dans cette section : la transformée de Fourier à court terme, la transformée de Wigner-Ville et la transformée de Hilbert Huang.

II.2.3.1. Transformée de Fourier à court terme (TFCT ou STFT)

Pour pallier les limites de la transformation de Fourier, Gabor a introduit en 1946 la transformée de Fourier à court terme, également appelée transformée de Fourier sur une fenêtre glissante, qui implique l'application de la transformée de Fourier sur une fenêtre mobile du signal $x(t)$. Cela veut dire que cette technique sert à déviser le signal initial, qui est supposé être non stationnaire, en plusieurs segments localement stationnaire, où la transformée de Fourier est appliquée sur chaque segment de signal, et ainsi de suite sur les autres segments [61].

La technique de Fourier fenêtrée est la plus ancienne parmi les techniques temps-fréquence. Cependant, dans la réalité, il est à noter qu'il n'existe pas de méthode ou d'analyses parfaites car chacune comporte des inconvénients et des avantages. En effet, tandis qu'une

certaine répartition est optimale pour un type de signal, d'autres distributions temps-fréquence conviennent mieux à d'autres types de signaux. La dégradation d'un défaut de roulement provoque non seulement une augmentation de l'amplitude des fréquences de vibration, mais aussi la production d'harmoniques de ces fréquences en raison de la modulation d'amplitude.

La transformée de Fourier à court terme continue d'un signal $x(t)$ est donné par l'équation suivante :

$$X(\tau, f) = \int_{-\infty}^{+\infty} x(t).h(t-\tau)e^{-j2\pi ft} dt \quad (\text{II.25})$$

Le signal $x(t)$ est segmenté en utilisant une fenêtre $h(t)$ avec l'indice τ représentant le positionnement temporel de la fenêtre, et donc le décalage de ce spectre.

Dans la littérature, la transformée de Fourier à court terme a été utilisée dans plusieurs travaux pour le diagnostic de défauts. Dans [62], une méthode combinée entre la STFT et le classifieur de Support Vecteur Machine (SVM) pour la classification des anomalies d'un moteur à induction dont les résultats achevés ont bien validé la réussite de la méthodologie proposée. En 2012, M. Cocconceli a appliqué la STFT pour détecter les défauts du roulement tout en montrant de bons résultats sur l'efficacité de cette technique [63]. Plus récemment, dans [64], une nouvelle méthode combinée entre la STFT et le réseau de neurones conventionnel (CNN) a été proposé à fin de détecter et classifier les défauts des différents composants de roulement d'un moteur à induction. Les fins de ces travaux ont bien confirmé la validité et l'efficacité de cette technique dans la détection et l'identification de défauts des machines en rotation.

II.2.3.2. Transformation de Wigner-Ville (TWV)

La méthode d'analyse temps-fréquence de Wigner-Ville est efficace en raison de sa haute résolution temporelle et fréquentielle. La Wigner-Ville offre une description précise des variations spectrales liées aux modifications soudaines de la vibration des roulements [65]. Elle présente des avantages notables par rapport à d'autres techniques d'analyse temps-fréquence car elle n'utilise pas des méthodes basées sur l'hypothèse de stationnarité, telle que la TFCT [66]. La fonction $W_x(t, f)$ est une transformation de Wigner-Ville, liée à un signal temporel $x(t)$ d'énergie finie, qui dépend des variables temps t et fréquence f , définie par l'équation suivante :

$$W_x(t, f) = \int_{-\infty}^{+\infty} x(t + \tau/2)x^*(t - \tau/2)e^{-j2\pi f \tau} d\tau \quad (\text{II.26})$$

En résumé, la transformée de Fourier à court terme et la transformation de Wigner-Ville ont un inconvénient majeur. Néanmoins, la contrainte de la transformée de Fourier à court terme est que la dimension de la fenêtre de résolution reste constante, ce qui peut entraîner un compromis optimal entre le temps et la résolution de la fréquence pour certaines fréquences, mais pas pour d'autres [67]. Lorsqu'un signal contient plusieurs composantes, la TWV peut devenir difficile à interpréter en raison des inconvénients de la transformation de Wigner-Ville.

L'analyse en ondelettes (ou analyse temps-échelle) peut remédier à ce problème en offrant un outil qui s'ajuste efficacement à la taille de l'objet ou du détail examiné. Cela sera clairement détaillé dans la prochaine section.

II.2.3.3. Transformée de Hilbert Huang

La méthode de Hilbert Huang a été mise au point en 1998, par H. Huang et al [68]. Le concept de cette méthode réside dans la décomposition du signal original en différentes composantes, ce qui donne lieu à ce processus appelé décomposition en mode empirique (EMD). L'EMD est ainsi une méthode de décomposition adaptative, non paramétrique et locale des signaux non stationnaires. Elle est utilisée pour diviser un signal complexe en une série de composantes oscillantes extraites directement de manière adaptative, avec une fréquence unique pour chaque échantillon. Ces composantes représentent une série d'IMF (IMF : Fonction Modale Intrinsèque) comme on les nomme les approximations et les détails, et qui sont interprétées comme des formes d'ondes non stationnaires modulées en amplitude et en fréquence instantanée en utilisant la transformée de Hilbert lors de leurs calculs.

L'algorithme EMD est résumé par des étapes bien détaillées dans le chapitre IV [68]. Néanmoins, La méthode de l'EMD a reconnu certaines limites, telles que la sensibilité au bruit et la fusion des modes. Pour surmonter aux problèmes de mélange des modes, la méthode de VMD a été développée [69, 70 et 71].

II.2.4. Analyse Temps-Echelle (les ondelettes)

La technique temps-échelle, également connue sous le nom d'analyse par ondelettes, est une approche de traitement de signaux récente qui a été développée pour surmonter les limites des méthodes traditionnelles d'analyse de signaux et qui est largement utilisée pour la détection des défauts. Le plus souvent, Les ondelettes sont employées pour effectuer un diagnostic en analyse vibratoire en décomposant le signal en sous-composantes [72] ou pour éliminer le bruit du signal [73]. La transformée en ondelettes a été inventée pour la première fois par Alfred Haar

en 1909. La technique consiste à décomposer le signal en ondes dilatées ou non et localisées temporellement, offrant ainsi des informations temporelles et en échelle grâce à des opérations de convolution entre le signal et une ondelette mère pour différents facteurs d'échelle. Les ondelettes permettent aussi de récupérer des indicateurs évolutifs dans le temps en plus de donner une information sur l'échelle temporelle d'un signal. En général, la fonction d'ondelette $\psi(t)$ est continue, nulle en dehors d'un intervalle de R et est définie par :

$$\int_{-\infty}^{+\infty} \frac{|\psi(f)|^2}{f} df < \infty \quad (\text{II.41})$$

Avec : $\psi(f)$: représente la transformée de Fourier de l'ondelette $\psi(t)$.

Il est essentiel de sélectionner l'ondelette mère, sa fonction et ses paramètres (décroissance et fréquence) pour utiliser cette méthode. Après, il faut ajuster le paramètre dans une gamme de valeurs définie de manière aléatoire. Il y a deux types de transformation en ondelettes : la transformée en ondelettes continue et la transformée en ondelettes discrètes [74]. Les détails de cette méthode seront clairement expliqués dans le chapitre IV.

En réalité, l'utilisation de l'une des méthodes de traitement des signaux susmentionnées pour les signaux présentant des symptômes de défaillance des composants, nécessite l'analyse et l'évaluation des résultats obtenus. Ce qui nécessite également des connaissances spécialisées pour utiliser ces symptômes dans le processus de diagnostic, et pour interpréter les résultats. Ce type d'approche introduit un facteur humain qui réduit la tolérance aux pannes de l'ensemble du système. Ainsi, ce processus semble difficile pour les défaillances redondantes et les grandes données collectées, avec lesquelles un diagnostic automatique basé sur l'intelligence artificielle est nécessaire [18]. Les sections qui suivent seront réservées pour éclaircir l'intérêt de chacune de ces méthodes dans l'automatisation de diagnostic de défauts.

II.3. Techniques de diagnostic de défauts par l'intelligence artificielle (IA)

Au cours des dernières décennies, pour automatiser le diagnostic des défauts des machines tournantes, la plupart des recherches sont basées sur les techniques de l'intelligence artificielle. Celles-ci peuvent agir en tant que détecteurs et classificateurs des défauts, en minimisant ainsi la participation humaine dans le processus de diagnostic [75]. Le domaine de l'intelligence artificielle est vaste et les techniques utilisées sont incomptables [76]. Les réseaux de neurones artificiels (ANN) sont la base de l'IA, ils se sont appuyés sur des modèles mathématiques assez simples pour améliorer les techniques d'analyse des données. Dans [77],

la recherche était basée à la fois sur l'EMD et l'ANN pour diagnostiquer et classifier les défauts de roulements dans les machines asynchrones. Ainsi, dans [78], l'étude s'appuie sur la combinaison entre l'ondelette de Morlet et les deux classificateurs l'ANN et le SVM (machine à vecteur de support), tout en remarquons que l'algorithme de SVM est plus adapté pour la classification et le diagnostic des défauts de roulements. En résumé, deux sous-ensembles dans le domaine de l'IA sont largement utilisés dans le diagnostic et la classification des défauts de roulements, qui sont : l'apprentissage automatique (connu sous l'acronyme ML pour Machine Learning) et l'apprentissage profond (connu par DL pour Deep Learning). La figure II.12 illustre la relation entre l'IA, le ML et le DL et ces principales méthodes (classifieurs) fréquemment utilisés dans le processus de diagnostic des défauts des machines tournantes.

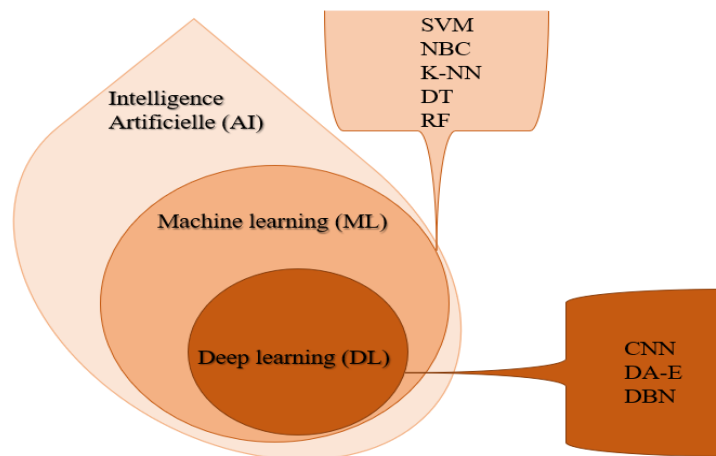


Figure II.3 : Principaux sous -ensemble et leurs classificateurs de l'intelligence artificielle.

II.3.1. Apprentissage Automatique (ML)

Les principaux algorithmes de ML sont classés en algorithmes supervisés et non supervisés. Les algorithmes supervisés se composent de variables cibles à prédire à partir d'un ensemble donné de variables indépendantes. Ces variables sont utilisées pour générer la fonction et les cartes de l'entrée afin d'obtenir la sortie souhaitée et d'atteindre l'objectif. Les données sont entraînées afin d'obtenir un meilleur taux de précision. Le processus de l'entraînement se poursuit jusqu'à ce que le modèle atteigne le niveau de précision souhaité. Cependant, pour les algorithmes non supervisés, il n'y a pas de variable cible et la technique de regroupement est adoptée. Les techniques peuvent segmenter le groupe et certains niveaux de diagnostic peuvent être atteints. Le rôle est d'identifier l'état actuel du roulement et, d'après la littérature, on sait que l'algorithme d'apprentissage automatique supervisé est adapté. Les

algorithmes fréquemment utilisés sont SVM (Machine à Vecteur de Support), NBC (Naïf-Bays Classificateur), k-NN (K-Plus Proche Voisins), DT (Arbre de Décision) et RF (Forêt Aléatoire). Ces algorithmes sont caractérisés par un grand nombre de couches de neurones, dont la sortie supporte de multiple classe, contrairement aux réseaux de neurones qui sont connus par leur simplicité de structure et de computation [79].

II.3.2. Apprentissage Approfondi (DL)

L'apprentissage approfondi est également considéré comme une forme de ML mais, en détail, il est un sous-ensemble de l'IA [79]. Le réseau peut être utilisé à la fois pour des applications supervisées et non supervisées. En d'autres termes, le réseau est formé de plusieurs couches contenant des couches cachées qui sont utilisées pour former l'entrée. Les Auto-Encodeurs de Débruitage (DA-E : Denoising Auto-Encoder), les Réseaux de Croyance Profonde (DBN : Deep Belief Network) et les Réseaux Neuronaux Convolutifs (CNN : Réseau Neural Convolution) sont les modèles standard de DL. En raison d'avantages tels que la variance de décalage, le partage des poids, le taux de précision élevé et l'encodage des données, parmi les différentes architectures, le CNN est le plus utilisé pour l'entraînement de l'entrée.

Le DL est largement utilisé dans le domaine médical, mais rarement dans le domaine de diagnostic des machines électriques [80,81]. Ces dernières années, un saut important a été observé vers l'utilisation du Deep Learning dans le domaine de diagnostic des défauts des machines tournantes et de leurs différents composants. Dans [82], le DL et un ensemble des algorithmes de ML a été appliqués pour le diagnostic des défauts de diagnostic des défauts de roulements, les résultats de la comparaison démontrent en outre que la fusion par apprentissage signaux de vibration peut améliorer le diagnostic des défauts des roulements. Un diagnostic des défauts de roulements basé sur la transformée de l'ondelette et le classifieur CNN a été appliqué dans [83], cette méthode présente une capacité de diagnostic des défauts supérieure comparant à celle des autres méthodes basées sur l'apprentissage automatique.

II.4. Conclusion

Dans ce chapitre, nous avons exposé un état de l'art sur les différentes techniques utilisées dans la détection et le diagnostic des défauts de roulements. Nous avons cité les techniques de traitement de signal qui servent à identifier et localiser le défaut existant dans la machine tournante elle-même ou dans l'un de ces composants. En outre, chaque méthode

présente ses propres limites, lesquelles ont été surmontées grâce au développement de la recherche et des études avancées. Ces techniques sont regroupées en quatre domaines d'analyse : l'analyse temporelle, l'analyse fréquentielle, l'analyse temps-fréquence et l'analyse temps-échelle. Ainsi, nous avons cité les techniques de l'intelligence artificielle qui servent à automatiser le diagnostic par la classification et la localisation des éventuels types de défauts existants dans le système. L'AI s'appuie sur les réseaux de neurones artificielles (ANN), mais ces derniers offrent moins de précision lorsqu'il s'agit de diagnostic multi-classes. L'apprentissage automatique (ML) et l'apprentissage profondi (DL) sont deux sous-ensembles de l'AI, caractérisés par une haute précision attribuée à leur structure relativement simple. De plus, le ML ne dépend pas d'un volume de données considérable, contrairement au DL qui est particulièrement adapté au traitement du big data. D'après les études, pour améliorer l'efficacité de précision de diagnostic et de classification, une combinaison entre les techniques de traitement de signal et les techniques de l'AI doit être présente.

Dans les prochains chapitres nous concentrerons sur l'application de certaines techniques, en mettant en évidence leur efficacité et leur précision dans le domaine du diagnostic des défauts de roulements.

Chapitre III

Simulation de la signature vibratoire Liée aux défauts du roulement : modélisation et applications




III.1. Introduction

Dans ce chapitre, nous exposons la modélisation et la simulation du comportement vibratoire d'un roulement en cas de manifestation de défauts de surface localisés sur chaque élément du roulement (la bague extérieure, la bille et la bague intérieure). Par ailleurs, un élément défectueux crée une signature distinctive en relation avec la dynamique fondamentale du roulement. Cette information est intégrée dans un signal temporel perturbé par du bruit. Les fréquences caractéristiques (signatures) d'un roulement dépendent de sa configuration géométrique et de sa vitesse, et seront discutées dans la section suivante.

III.2. Signatures de défaut et fréquences caractéristiques

Lorsque qu'une imperfection se manifeste à un endroit spécifique d'un des composants du roulement, cela provoque des vibrations dans l'ensemble. Effectivement, lorsqu'il y a un défaut sur le chemin de roulement d'une bague ou sur une bille, un choc mécanique se produit chaque fois que le défaut coïncide avec un point de contact bille/bague. Alors, ces secousses répétées engendrent des ondulations. De façon plus simple, cette oscillation peut être représentée par un signal périodique qui prend en compte la période caractéristique de l'élément défectueux. Il sera possible de dire, pour chaque type de défaut, qu'il existe une fréquence spécifique ou fréquence de défauts qui peut être calculée en tenant compte de la géométrie du roulement, du nombre de billes, des vitesses de rotation et des bagues intérieure et extérieure.

Différentes fréquences sont habituellement observées pour les différents types de défauts :

-  Défaut de bague extérieure ;
-  Défaut de billes ;
-  Défaut de cage ;

✚ Défaut de bague intérieure.

Ces fréquences théoriques sont aussi calculées en se basant sur les équations expliquées dans la section suivante, et sur la figure III.1 montrant la structure du roulement [84].




Figure III.1 : Géométrie d'un roulement.

Les différents paramètres géométriques de ce type de roulement sont listés dans le tableau III.1 qui suit :

Tableau III.1 : Paramètres géométriques.

| Paramètres géométriques du roulement | |
|--------------------------------------|--|
| n_b | Nombre de billes |
| α | Angle de contact |
| D | Diamètre du cercle primitif |
| d | Diamètre de l'élément roulant (billes) |
| D_0 | Diamètre de la bague externe |
| D_i | Diamètre de la bague interne |

III.2.1. Défaut de la bague extérieure

Les composants annexes qui entourent un roulement sont liés à une autre pièce. En général, la bague extérieure est fixe donc la fréquence d'un défaut affectant cette bague est appelée aussi fréquence de passage de billes [85]. La représentation vibratoire de ce défaut est semblable à un peigne de lignes dont l'espacement correspond à la fréquence du défaut. Chaque partie de ce peigne est liée à une paire de bandes latérales séparées par la fréquence de rotation, comme le montre la figure III.2 [19].

La fréquence caractéristique de ce défaut est nommée par F_{BPFO} (Fréquence de Passage de Billes de Défaut de la Bague Extérieure), et donnée par l'équation (III.1).

$$F_{BPFO} = \frac{n_b}{2} f_r \left[1 - \left(\frac{d}{D} \cos \alpha \right) \right] \quad (\text{III.1})$$

Avec : f_r : fréquence de rotation de la bague intérieure (la bague extérieure est supposée fixe) ; d : le diamètre de la bille ; D : le diamètre du cercle primitif ; n_b : le nombre de billes et α : l'angle de contact.

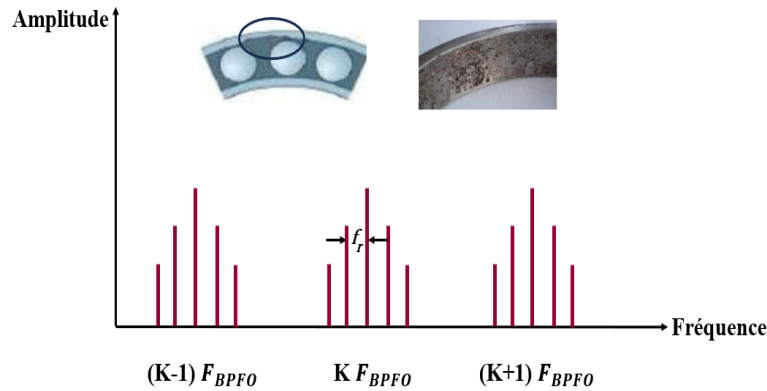


Figure III.2 : Caractéristiques vibratoires d'une anomalie sur une bague externe [19, 13].

III.2.2. Défaut de l'élément roulant (billes)

La fréquence de défaut de bille est habituellement désignée sous le nom de fréquence de rotation de bille. La première fréquence de défaut est identique à la fréquence de rotation de la bille sur elle-même. En outre, chaque rotation fait que la bille touche à la fois la bague intérieure et extérieure, provoquant ainsi des chocs deux fois plus fréquemment [85,86].

Sa fréquence caractéristique est nommée généralement par son acronyme (Ball Spin Frequency Fault), et donnée par l'équation (III.2) [87].

$$F_{BSF} = \frac{D}{d} f_r \left[1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right] \quad (\text{III.2})$$

La représentation vibrante de ce défaut prend la forme d'un peigne de lignes. Chaque partie du peigne est liée à plusieurs paires de bandes latérales éloignées de la fréquence de la cage, comme indiqué dans la figure III.3 [19, 13].

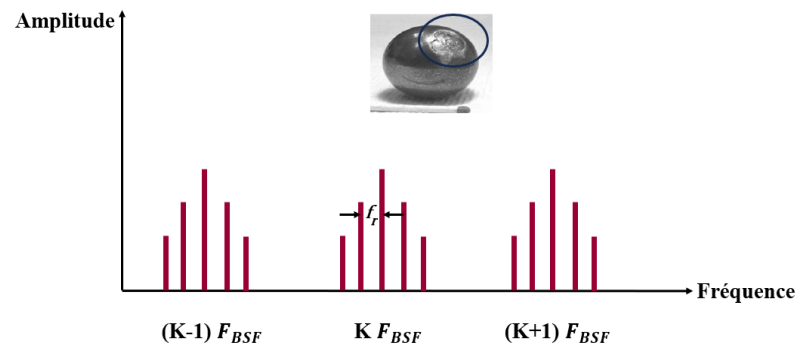


Figure III.3: Signature vibratoire d'un défaut de bille [19, 13].

III.2.3. Défaut de cage

Il est nécessaire que les axes des billes et la cage bougent à une vitesse qui équivaut à la moyenne des vitesses des bagues intérieure et extérieure afin d'éviter tout glissement des bagues [85]. Le défaut de la cage se manifeste par la présence des raies à la fréquence de la cage F_{FTF} et ses harmoniques [19]. La fréquence de ce problème est équivalente à la vitesse de rotation de la cage, connue sous le nom de (Fréquence fondamentale de défaut de la cage), et peut être déterminée en prenant en compte le diamètre primitif, l'angle de contact et le diamètre de la bille, comme indiqué dans l'équation (III.3) [87].

$$F_{FTF} = \frac{f_r}{2} \left[1 \pm \left(\frac{d}{D} \cos \alpha \right) \right] \quad (\text{III.3})$$

III.2.4. Défaut de bague intérieure

Habituellement, la bague interne est attachée à l'arbre, ce qui signifie qu'elle tourne à la même vitesse que l'arbre. L'image vibratoire de ce défaut de bague ressemble à un peigne de raies avec plusieurs paires de bandes latérales espacées de la fréquence de rotation pour chaque composant de ce peigne. La fréquence spécifique de ce problème est nommée (Fréquence de passage des billes de défaut de la bague intérieure), et est déterminée par l'équation (III.4).

$$F_{BPFI} = \frac{n_b}{2} f_r \left[1 + \left(\frac{d}{D} \cos \alpha \right) \right] \quad (\text{III.4})$$

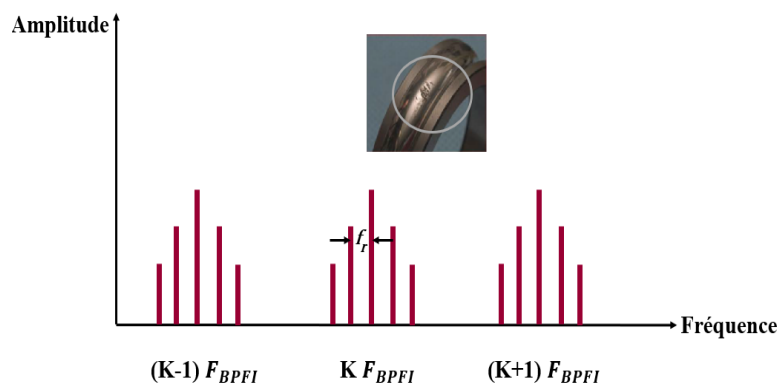


Figure III.4: signature vibratoire d'un défaut de bague intérieure [19, 13].

III.3. Modélisation du roulement

La modélisation vise à simplifier la complexité d'un système mécanique et à anticiper son comportement dynamique sur une période définie, tout en se rapprochant de la réalité. Dans cette partie, nous nous penchons sur l'étude du comportement vibratoire du roulement qui peut se faire par trois modèles de modélisation. Ces modèles incluent le modèle de traitement du signal tel que le modèle de Sheen [88], le modèle de Meunier [89]. Le modèle dynamique (vibratoire) qui permet d'étudier la réponse vibratoire du roulement en le considérant comme un système mécanique isolé, défini par un système masse-ressort, tel que décrit par le modèle de Maxwell qui prend en compte la distribution de la charge et les forces d'excitation. Le dernier modèle est le modèle des éléments finis, qui permet de transformer un système d'équation différentielle difficile à résoudre en un système d'équations linéaires simple à traiter. Dans ce contexte, nous optons sur le modèle de traitement du signal, lequel est présenté de manière détaillée dans la section qui suit.

III.3.1. Modélisation du roulement par traitement de signal

En théorie, la simulation analytique des signaux vibratoires résultants des défauts des roulements à travers les modèles de traitement du signal a été abordée à l'aide de plusieurs modèles mathématiques [88,89, 86 et13] . Le modèle de Meunier [89] se caractérise par le produit de convolution entre la réponse de résonance de la structure et la force excitatrice impulsionnelle, tandis que le modèle de Sheen [88], repose sur la démodulation des signaux vibratoires. Dans cette optique, nous nous concentrons sur le modèle développé par Sheen, lequel est abordé en détail dans le paragraphe suivant.

III.3.2. Modèle de Sheen pour la simulation des signaux vibratoires

Le modèle proposé se base sur la fonction d'enveloppe-autocorrélation, conçue pour effectuer la démodulation en temps réel des signaux vibratoires. Cette démodulation est réalisée par un filtre complexe basé sur la transformée de Hilbert, et permet de fournir directement un signal complexe en fonction de la fréquence et du temps. Ainsi, l'enveloppe peut être dérivée de la valeur absolue du signal complexe. Trois paramètres, le facteur d'échelle, la fréquence centrale et la largeur de la bande passante, sont désignés pour obtenir une convergence rapide de la forme d'onde, un gain constant de la bande passante et une faible distorsion de phase. De la sorte, un intervalle de forme d'onde fini du filtre proposé peut être appliqué à la démodulation des signaux de vibration. D'après l'analyse théorique et les études expérimentales, il est démontré que le filtre proposé peut être appliqué efficacement à la démodulation des signaux de vibration en temps réel d'un système de roulement à billes.

III.3.2.1. Filtre complexe pour la transformée de Hilbert

Dans le diagnostic d'un système de roulements, Les signaux mesurés présentent une modulation d'amplitude et la propriété de translation de fréquence apparaît donc dans les spectres de vibration. Le phénomène de modulation d'amplitude est dû au fait qu'un signal porteur à haute fréquence est modifié par un signal modulant à basse fréquence. Pour traiter ce phénomène, la technique de résonance à haute fréquence est introduite, qui tente de dériver le signal modulant à basse fréquence du signal modulé en filtrant le signal porteur à haute fréquence. Dans la technique de résonance à haute fréquence, un filtre complexe pour la transformée de Hilbert ayant les propriétés suivantes : un gain constant dans la bande passante et une orthogonalité parfaite sont nécessaires pour filtrer la bande autour de la fréquence de résonance. Si un signal complexe est dérivé de la convolution d'un signal de vibration et du filtre complexe, un signal d'enveloppe peut être la valeur absolue du signal complexe. Ainsi, le filtre complexe peut être considéré comme étant de la forme :

$$h(t) = h_r(t) + jh_i(t) \quad (\text{III.5})$$

Où : $h_i(t)$ est la transformée de Hilbert pour $h_r(t)$. Afin de réaliser un tel filtre complexe pour la transformée de Hilbert, certaines propriétés sont considérées comme suit :

- 1) Si $h_r(t)$ est une fonction paire, $h_i(t)$ sera impaire ;
- 2) La fonction $h_i(t)$ doit être orthogonale à $h_r(t)$;
- 3) Les deux fonctions $h_i(t)$ et $h_r(t)$ doivent être des filtres passe-bande.

Dans ce qui suit, un tel filtre complexe pour la transformée de Hilbert est d'abord proposé et défini comme suit :

$$h_{a,f_c,f_w}(t) = \frac{1}{j\pi t} e^{-(t/a)^2} \left(e^{-j2\pi(f_c - f_w/2)t} - e^{-j2\pi(f_c + f_w/2)t} \right) \quad (\text{III.6})$$

Où : a , f_c et f_w sont le facteur d'échelle, la fréquence centrale et la largeur de la bande passante, respectivement. D'autre part la partie réelle et la partie imaginaire du filtre complexe $h_{a,f_c,f_w}(t)$ sont respectivement $h_r(t)$ et $h_i(t)$ respectivement, et peuvent être écrites comme suit :

$$h_r(t) = \frac{1}{\pi t} e^{-(t/a)^2} \left[\sin\left(2\pi\left(f_c + \frac{f_w}{2}\right)t\right) - \sin\left(2\pi\left(f_c - \frac{f_w}{2}\right)t\right) \right] \quad (\text{III.7})$$

$$h_i(t) = \frac{1}{\pi t} e^{-(t/a)^2} \left[\cos\left(2\pi\left(f_c + \frac{f_w}{2}\right)t\right) - \cos\left(2\pi\left(f_c - \frac{f_w}{2}\right)t\right) \right] \quad (\text{III.8})$$

Ce filtre est calculé au moyen d'un algorithme bien structuré [88], puis testé sur un train d'impulsion simulé, où chaque impulsion est modulée par deux fréquences de résonance simplifiées du système. De plus, le signal modulé est le produit entre le signal modulant et le signal porteur. Le signal modulant correspond aux impacts causés par les défauts d'un roulement et peut être représenté par des impulsions de vibrations à décroissance exponentielle [90]. Ainsi, le signal porteur est une combinaison des fréquences de résonance du roulement ou même du système mécanique. La fréquence du signal modulant est toujours beaucoup plus petite que celle du signal porteur. La démodulation des signaux vibratoires s'exprime par [88, 91]:

$$x(k) = e^{-\alpha k t'} \left(\sin 2\pi f_1 k T_s \right) + \left(\sin 2\pi f_2 k T_s \right) \quad (\text{III.9})$$

$$t' = \text{mod}\left(k T_s, \frac{1}{f_0}\right) \quad \text{Ce qui implique que } e^{-\alpha k t'} \text{ soit le signal modulant, ainsi que}$$

$\left(\sin 2\pi f_1 k T_s \right) + \left(\sin 2\pi f_2 k T_s \right)$ soit le signal porteur.

Où : f_1 et f_2 sont les fréquences de résonance ; f_0 est la fréquence de défaut d'impact ; α : fréquence exponentielle ; k : nombre d'itération ; T_s : temps d'échantillonnage.

III.3.3. Résultats de simulation analytique des signaux vibratoires du roulement

La simulation des signaux de défauts du roulement est réalisée en utilisant les paramètres des mesures réelles générées par le banc d'essai de CWRU (voir la section prochaine). Dans cette partie, nous présentons les résultats de simulation des signaux de défauts de la bague intérieure du roulement. La charge appliquée au roulement est de 3 HP avec la vitesse de rotation n est de 1730 tr/mn, et la fréquence d'échantillonnage f_s de 12000 Hz pour les différents diamètres (0.007", 0.014", 0.021", 0.028"). La fréquence de défaut de la bague intérieure est calculée à travers l'équation III.4 présentée précédemment. Les paramètres géométriques du roulement utilisé dans la pratique sont listés dans le tableau présenté dans la section prochaine. Les autres paramètres sont listés dans le tableau III.2 :

Tableau III.2 : Paramètres des mesures réelles.

| Paramètres | Equation de calcul | Définition |
|------------|---|---|
| f_r | $\frac{n}{60} = \frac{1730}{60} = 28,83$ [Hz] | Fréquence de rotation |
| f_0 | $F_{BPFI} = \frac{9}{2} 28,83 \left[1 + \frac{8}{39} \right] = 156,36$ [Hz] | Fréquence de défaut de la bague intérieure |
| T_s | $T_s = \frac{1}{f_s} = \frac{1}{12000}$ [s] | Temps d'échantillonnage |
| T | [0, 0.1] avec un pas d'échantillonnage $\frac{1}{T_s}$ [s] | Vecteur de temps |
| α | 800 | Fréquence exponentielle |
| f_1 | 97.53, 28.79, 69.25 et 246.2 Hz pour (0.007", 0.014", 0.021", 0.028") respectivement. | Premières fréquences de résonance pour les différents diamètres de défauts |
| f_2 | 309.53, 69.51, 311.2 et 369.3 Hz pour (0.007", 0.014", 0.021", 0.028") respectivement. | Deuxièmes fréquences de résonance pour les différents diamètres de défauts |
| f_3 | 774.5, 779.4, 466.9 et 865.3 Hz pour (0.007", 0.014", 0.021" et 0.028") respectivement. | Troisièmes fréquences de résonance pour les différents diamètres de défauts |

Les résultats sont présentés sous forme de représentations temporelle et fréquentielle sans l'addition du bruit comme suit :

III.3.3.1. Représentation temporelle et fréquentielle avec défaut et sans bruit

Les figures ci-dessous illustrent les signaux vibratoires simulés dans le domaine temporel et fréquentiel pour le défaut de la bague intérieure, avec différents diamètres de défauts (0,007", 0,014", 0,021" et 0,028").




Figure III.5 : Signal simulé de défaut de la bague intérieure de 0,007". (a) : représentation temporelle. (b) : représentation fréquentielle.




Figure III.6 : Signal simulé de défaut de la bague intérieure de 0,014". (a) : représentation temporelle. (b) : représentation fréquentielle.




Figure III.7 : Signal simulé de défaut de la bague intérieure de 0,021". (a) : représentation temporelle. (b) : représentation fréquentielle.

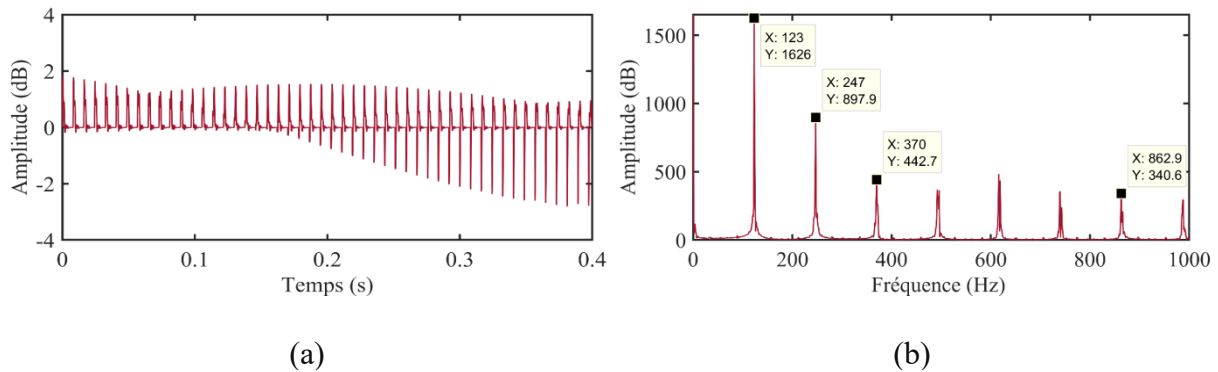


Figure III.8 : Signal simulé de défaut de la bague intérieure de 0,028". (a) : représentation temporelle. (b) : représentation fréquentielle.

En observant les formes des résultats obtenus, on remarque que plus le diamètre du défaut de la bague intérieure augmente, plus le niveau vibratoire du signal augmente. Aussi, les spectres obtenus montrent les fréquences de résonance et autour d'elles, les raies latérales séparées par une valeur correspondant à la fréquence de défaut, laquelle est de 156,36 Hz.

III.3.3.2. Représentation temporelle et fréquentielle avec défaut et avec différents niveaux de bruit

Afin de mieux rapprocher les signaux vibratoires simulés à ceux mesurés en pratique, différents niveaux de bruit blanc sont ajoutés aux signaux simulés. Ensuite, un ensemble d'indicateurs de surveillance vibratoire est calculé pour chaque niveau du bruit ajouté afin de déterminer la sensibilité de chaque indicateur à la détection précoce des défauts du roulement.

Les signaux vibratoires simulés comprenant de défaut ainsi qu'un ajout de bruit sur la bague intérieure et Le spectre de ce signal, avec une vitesse de rotation de 1730 tr/mn et un diamètre de défaut de 0,021" sont illustrés dans les figures ci-dessous :




Figure III.9 : Représentation temporelle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 1,5.




Figure III.10 : Représentation fréquentielle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 1,5.

La simulation du même signal est également réalisée en augmentant le rapport signal sur bruit (SNR) à 8, et on obtient les représentations temporelle et fréquentielle illustrées dans les figures III.11 et III.12 respectivement :




Figure III.11 : Représentation temporelle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 8.




Figure III.12 : Représentation fréquentielle du signal simulé de défaut de la bague intérieure de 0,021" et de SNR de 8.

D'après ces résultats, il est possible de constater que les amplitudes des signaux simulés augmentent proportionnellement à l'augmentation du bruit. Ces résultats seront examinés plus en détail par le calcul d'indicateurs scalaires tels que le kurtosis et le RMS en fonction du SNR. Également les résultats de calcul sont listés dans le tableau III.3 :

Tableau III.3 : Variation des facteurs de kurtosis et de RMS en fonction du SNR.

| SNR | Kurtosis | RMS |
|-----|----------|----------|
| 0 | 3.9982 | 142.9506 |
| 1,5 | 4.5924 | 130.5718 |
| 5 | 5.8263 | 111.4102 |
| 8 | 7.2652 | 101.9136 |
| 15 | 8.8419 | 94.7938 |
| 25 | 9.3789 | 93.0089 |
| 35 | 9.4526 | 92.7254 |
| 40 | 9.4606 | 92.7159 |

Pour mieux éclaircir les résultats de calcul obtenus, les figures III.13 et III.14 montrent la variation de facteur du Kurtosis et de RMS en fonction de l'augmentation du rapport signal sur bruit (SNR), respectivement.




Figure III.13 : Représentation de la variation du Kurtosis en fonction du SNR.




Figure III.14 : Représentation de la variation de RMS en fonction du SNR.

En analysant les résultats des calculs statistiques, on remarque que le facteur du Kurtosis devient plus réactif à une augmentation graduelle du rapport signal sur bruit (SNR). Cependant, à certain niveau de SNR, le kurtosis commence à se stabiliser, sachant que le kurtosis a des seuils prédéfinis qui détermine l'état de dégradation du système, donc si $Ku = 3$, le roulement ne présente aucun défaut ; si $3 < Ku < 6$ le roulement est légèrement dégradé et si $Ku > 6$ le roulement est endommagé. A la différence du facteur de RMS, qui présente une sensibilité moindre à l'augmentation du SNR. On peut donc conclure que le facteur de Kurtosis est efficace dans la détection des défauts avec bruit. En revanche, le facteur de RMS ne convient pas bien à tels scénarios de détection.

III.3.4. Description de banc d'essai de CWRU

Les signaux de vibrations (accélération) sont collectés à l'aide du banc d'essai réalisé au niveau de la Case Western Reserve University (CWRU, centre de données sur les roulements) [92]. Comme montré dans la figure III.15, le banc d'essai est se compose d'un moteur électrique, d'un capteur de couple et d'un codeur, ainsi que d'un dynamomètre. Les signaux de vibration ont été mesurés par des accéléromètres fixés au moteur par des bases magnétiques, placées dans le sens vertical sur le boîtier du roulement de l'extrémité motrice du moteur. Les roulements défectueux sont réinstallés dans le moteur et la fréquence d'échantillonnage est fixée à 12 kHz. Ainsi, les signaux vibratoires mesurés ont été effectués avec quatre charges différentes (0 Nm, 1 Nm, 2 Nm et 3 Nm), à quatre vitesses de moteur correspondant à 1797, 1772, 1750 et 1730 RPM, respectivement.




Figure III.15 : Banc d'essai expérimental de la CWRU [92].

L'ensemble des données des vibrations mesurées dans le roulement de l'extrémité motrice contient environ 64 signaux, répartis entre des états sans défauts et des états endommagés des roulements. Quatre d'entre eux appartiennent aux roulements normaux, tandis que les autres représentent les roulements défectueux avec des défauts dans la bague extérieure, l'élément roulant et la bague intérieure. Les défauts des roulements sont créés artificiellement et séparément au niveau de la bague extérieure, de l'élément roulant et de la bague intérieure à l'aide de l'usinage par électroérosion (EDM), qui représente une méthode de traitement des métaux durs ou des composants mécaniques qui ne peuvent pas être pénétrés par les méthodes conventionnelles. Dans ce cas, les défauts sont liés à un trou central et sont déterminés par leur diamètre. Les diamètres des défauts examinés ici correspondent à des diamètres de défaut de 0,007", 0,014", 0,021" et 0,028" pour les trois éléments du roulement : la bague extérieure, l'élément roulant et la bague intérieure. Les roulements à billes utilisés dans l'expérience sont de type 6205-2 RS JEM SKF, et leurs dimensions sont indiquées dans le tableau III.4 :

Tableau III.4 : Paramètres du roulement 6205-2 RSJEM SKF.

| Caractéristiques du roulement | Dimensions |
|---------------------------------|------------|
| Diamètre de la bague intérieure | 25mm |
| Diamètre de la bague extérieure | 52 mm |
| Diamètre intermédiaire (D) | 39 mm |
| Epaisseur (e) | 15 mm |
| Diamètre de la bille (d) | 8mm |
| Nombre de billes (n_b) | 9 |
| Angle de contact (α) | 0 rad |

III.3.4.1. Représentation du modèle réel sans défaut

Les signaux temporels provenant d'un roulement sans défaut, ainsi que d'autres éléments présentant des défauts, sont enregistrés au format Matlab. La représentation temporelle et fréquentielle est illustrée dans les figures III.16 et III.17, respectivement :




Figure III.16 : Représentation temporelle d'un signal réel sans défaut.




Figure III.17 : Représentation fréquentielle d'un signal réel sans défaut.

III.3.4.2. Représentation des signaux réels avec défaut

La représentation temporelle et fréquentielle des signaux réels de la bague intérieure présentant des défauts de diamètres différents (0,007", 0,014", 0,021" et 0,028") à une vitesse de rotation de 1730 RPM est illustrée dans les figures suivantes, respectivement :




Figure III.18 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,007".




Figure III.19 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,007".




Figure III.20 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,014".




Figure III.21 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,014".




Figure III.22 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,021".




Figure III.23 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,021".




Figure III.24 : Représentation temporelle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,028".




Figure III.25 : Représentation fréquentielle d'un signal réel avec défaut de la bague intérieure de diamètre de 0,028".

En comparant les allures des spectres obtenus par le modèle simulé pour les différents diamètres de défauts de la bague intérieure du roulement avec les spectres obtenus à partir des signaux réels, on constate une similarité des pics apparus. De plus, il est remarqué que l'augmentation du diamètre de défaut entraîne une augmentation du niveau vibratoire des signaux. Afin de clarifier davantage les résultats obtenus, nous les synthétisons tous dans le tableau III.5 :

Tableau III.5 : Comparaison entre les signaux simulés et les signaux réels.

| | | Résultats du Modèle Simulé | | | | Résultats du Modèle Réel | | | |
|--------------|------|----------------------------|-------|-------|-------|--------------------------|-------|-------|-------|
| Diamètres | Pics | f_1 | f_2 | f_3 | f_4 | f_1 | f_2 | f_3 | f_4 |
| 0, 0 0 | x | 96.99 | 156 | 313 | 774.9 | 97.53 | 154.9 | 309.8 | 774.5 |
| | y | 227.2 | 1290 | 859.4 | 250 | 3280 | 5987 | 3621 | 2251 |
| 0,0 14' - | x | 29 | 68.99 | 156 | 781.9 | 28.79 | 69.51 | 155.9 | 779.4 |
| | y | 303.7 | 223.3 | 1309 | 373.3 | 2657 | 2375 | 2683 | 877.2 |
| 0,0 21' - | x | 68.99 | 156 | 313 | 469 | 69.25 | 155.6 | 311.2 | 466.9 |
| | y | 268.6 | 1517 | 816.7 | 480.1 | 6103 | 10180 | 6311 | 3117 |
| 0,0 28' - | x | 123 | 247 | 370 | 862.9 | 123.1 | 246.2 | 369.3 | 865.3 |
| | y | 1626 | 897.9 | 442.7 | 340.6 | 8071 | 3377 | 2812 | 4299 |

III.5. Conclusion

Le présent chapitre a été dédié à développer une modélisation mathématique permettant de simuler le comportement vibratoire du roulement et d'analyser sa réponse vibratoire. La simulation des signatures vibratoires à partir du modèle développé a été comparée avec celle obtenue par le modèle réel, ce qui valide ainsi l'efficacité de ce dernier. L'ajout de différents niveaux du bruit avait pour but de démontrer l'effet de sévérité du défaut sur le fonctionnement du roulement. L'analyse temporelle et fréquentielle des signaux vibratoires permet une identification précoce des défauts et un diagnostic précis de l'état du roulement. Le chapitre qui suit vise à appliquer un ensemble de techniques avancées de traitement du signal pour l'identification et la détection de défauts du roulement, tant dans les simulations que dans les situations réelles.

Chapitre IV

Détection des défauts de roulement par l'application des méthodes de traitement du signal

IV.1. Introduction

L'objectif de ce chapitre est de vérifier l'efficacité des méthodes de traitement du signal proposées pour la détection et l'identification des défauts du roulement. La première partie du chapitre se concentre sur la présentation de la technique de la transformée en ondelettes, en explorant ses différents types et en l'appliquant au modèle de simulation proposé. Tandis que, la deuxième partie sert à exposer la méthode de décomposition en mode empirique (EMD), qui est une technique de traitement du signal très avancée. L'idée ici est de faire une étude comparative entre les deux techniques de traitement du signal, tout en les appliquant d'un part sur les signaux simulés et d'autre part sur les signaux réels.

IV.2. Théorie des ondelettes

IV.2.1. Définition d'une ondelette

Une ondelette, notée $\psi(t)$, est une fonction continue qui s'annule en dehors d'un intervalle R . elle permet de vérifier une condition technique, généralement appelée condition d'admissibilité, qui s'écrit comme suit :

$$0 < C_{\psi} = \int_{-\infty}^{+\infty} \frac{|\psi(f)|^2}{|f|} df < \infty \quad (\text{IV.1})$$

Où : $\psi(f)$ désigne la transformée de Fourier de l'ondelette $\psi(t)$ et C_{ψ} est une constante déterminée par la condition d'admissibilité.

De plus, l'ondelette est localisée sur un court intervalle de temps et possède une moyenne nulle pour les fonctions avec une décroissance suffisante. Il s'avère alors que les conditions d'admissibilité sont équivalentes à la relation exprimée comme suit :

$$\int_{-\infty}^{+\infty} \psi(t).dt = 0 \quad (\text{IV.2})$$

Cela signifie que la fonction doit se déplacer de haut en bas sur l'axe t, elle doit se comporter comme une onde, ce qui, avec la propriété supposée de décroissance, justifie le choix

du terme ondelette. C'est cette propriété qui permet une localisation efficace à la fois dans le temps et dans la fréquence, contrairement à la transformée de Fourier, qui décompose le signal en termes de sinus et de cosinus formant des ondes de durée infinie [93].

Également, Une ondelette est définie par un couple (a, b) qui permet de caractériser une famille d'ondelette, où a désigne le paramètre d'échelle et b le paramètre de translation de l'ondelette mère $\psi(t)$. A partir de cette ondelette mère, on génère un ensemble de fonctions $\psi_{a,b}(t)$ et selon la formule de base suivante :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (\text{IV.3})$$

Le paramètre b positionne l'ondelette sur l'axe du temps, tandis que le paramètre a contrôle la fréquence de l'ondelette (contraction : haute fréquence, dilatation : basse fréquence), comme montre la figure IV.1 [13].

- ❖ Si $|a| \ll 1$, l'ondelette $\psi_{a,b}(t)$ devient fortement très concentrée autour de l'ondelette mère $\psi(t)$, et le contenu en fréquence tournera vers les hautes fréquences du plan d'analyse.
- ❖ Si $|a| \gg 1$, l'ondelette $\psi_{a,b}(t)$ est très étalée et le contenu fréquentiel se déplacera vers les basses fréquences du plan d'analyse.
- ❖ Si on fait varier le paramètre de dilatation a , le nombre d'oscillations de l'ondelette reste toujours constant [14].

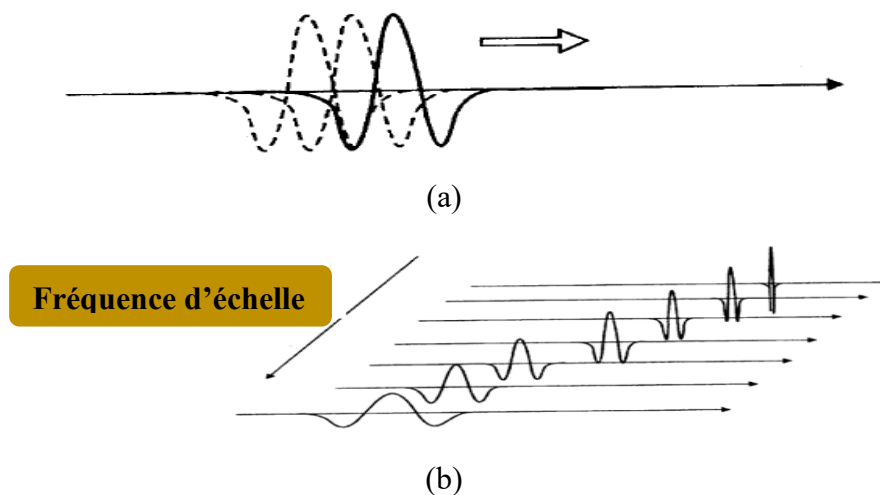


Figure IV.1. (a) : Changement de position des ondelettes par la translation.

(b) : Changement d'échelle des ondelettes [13].

IV.2.2. Types de transformées en ondelettes

Il existe deux catégories de transformations en ondelettes : la transformation continue en ondelettes et la transformation discrète en ondelettes, qui seront abordées dans les prochains paragraphes [94, 95].

IV.2.2.1. Transformée en Ondelette Continue (TOC)

La TOC implique de mesurer la similitude entre $x(t)$ et l'ondelette $\psi_{a,b}(t)$ dilatée par un facteur d'échelle a , qui détermine sa fréquence, et le paramètre de décalage temporel b [96]. La fonction d'une transformée en ondelettes est déterminée par un produit scalaire avec le signal $x(t)$ comme indiqué dans l'équation suivante [97] :

$$X_{TOC}(a,b) = \langle x(t), \psi_{a,b} \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (IV.4)$$

Où la description de $x(t)$ repose sur les coefficients d'ondelettes, selon la formule suivante [94]:

$$x(t) = \frac{1}{C_\psi} \int_0^{+\infty} \int_{-\infty}^{+\infty} X_{TOC}(a,b) \psi_{a,b} \frac{dad b}{a^2} \quad (IV.5)$$

IV.2.2.2. Transformée en Ondelette Discrète (TOD)

La TOD est une version de la transformée en ondelettes qui utilise un groupe discret d'échelles et de translations en ondelettes, tout en respectant des règles spécifiques [98]. Les paramètres a et b deviennent donc :

$$\begin{cases} a = a_0^m \\ b = nb_0 a_0^m \end{cases} \quad (IV.6)$$

Où $n, m \in \mathbb{Z}$, a_0 est un paramètre de dilatation et b_0 est un paramètre de translation.

On choisit pour la majorité des applications $a_0 = 2$ et $b_0 = 1$. Le pas de dilatation $b = nb_0 2^m$ correspond à un réseau dyadique $(t, f) = (b = nb_0 2^m, 2^m f_0)$ où f_0 est la fréquence de l'ondelette mère. Les ondelettes enfants correspondantes sont données par l'équation suivante :

$$\psi_{(m,n)}(t) = a_0^{m/2} \psi(a_0^{-m} t - nb_0) \quad (IV.7)$$

La discrétisation de la transformée d'ondelettes continue est donnée par :

$$X_{TOD}(m, n) = a_0^{-m/2} \int_{-\infty}^{+\infty} x(t) \psi(a_0^{-m} t - nb_0) \quad (IV.8)$$

L'application de la transformée en ondelettes repose sur le choix de l'ondelette mère qu'on trouve évidemment de multiples familles d'ondelettes. Ces familles vont être bien décrites dans les paragraphes qui suivent. Également la transformée en ondelette discrète se subdivise en deux types : la transformée en paquets d'ondelettes et la transformée multi résolution en ondelettes.

IV.2.3. Différentes familles d'ondelettes

Parmi les ondelettes les plus utilisées on vient de citer quelques-unes avec leurs formes et leurs propriétés.

❖ Ondelette de Morlet

L'ondelette de Morlet a été inventée par Jean Morlet et Alex Grossmann qui sont les pionniers dans le domaine de l'analyse des ondelettes. Elle est définie par [99]:

$$\psi(t) = C e^{-\frac{t^2}{2}} \cdot \cos(5t) \quad (IV.9)$$

Où : C est une constante de normalisation de construction.

L'ondelette de Morlet se représente donc comme un cosinus modulé en amplitude par une gaussienne. Ce qui explique et vérifie qu'elle possède un spectre à bande étroite comme un filtre passe-bande. La forme de cette ondelette est illustrée dans la figure (IV.2) :




Figure IV.2 : Forme de l'ondelette de Morlet.

❖ Ondelette chapeau mexicain

C'est une ondelette relativement simple obtenue comme étant une dérivée seconde de Gaussienne comme l'indique la figure IV.3 et elle est définie par l'équation suivante :

$$\psi(t) = \left(\frac{2}{\sqrt{3}} \pi^{-\frac{1}{4}} \right) (1-t^2) e^{-\frac{t^2}{2}} \quad (\text{IV.10})$$




Figure IV.3 : Forme de l'ondelette chapeau mexicain [100].

❖ Ondelette de Haar

L'ondelette de Haar a été construite par Alfred Haar qui a construit également des bases considérées comme le fondement de la théorie des ondelettes. L'ondelette mère $\psi(t)$ qui génère les ondelettes de Haar est une fonction constante par morceaux et est définie par [101]:

$$\psi(t) = \begin{cases} 1 \text{ pour } 0 < t \leq \frac{1}{2} \\ -1 \text{ pour } \frac{1}{2} \leq t < 1 \\ 0 \text{ ailleurs} \end{cases} \quad (\text{IV.11})$$

La forme de ce type d'ondelette est présentée sur la figure IV.4 :




Figure IV.4 : Forme de l'ondelette de Haar [101].

❖ Ondelettes de Daubechies

Ingrid Daubechies a cherché à construire des bases d'ondelettes orthogonales à support compact et à m moments nuls, définissant une transformée en ondelettes discrète. Par la suite, Daubechies a construit des ondelettes à support compact les plus symétriques possibles

appelées Simplets. Les simplets ont le même nombre m de moments non nuls que les ondelettes de Daubechies pour un support donné [102]:




Figure IV.5: Forme de l'ondelette de Daubechies.

❖ **Ondelette de Meyer**

Ce type d'ondelette a été construit par Y. Meyer qui a défini cette ondelette sur des bases appelées bases orthogonales d'ondelettes, cette dénomination signifie que la décomposition est unique « base » et que les ondelettes sont indépendantes « ou orthogonales ». L'ondelette mère ψ est définie dans le domaine fréquentiel, tel que [103] :

$$\psi(\omega) = \begin{cases} (2\pi)^{-1/2} e^{\frac{j\omega}{2}} \sin\left(\frac{\pi}{2} v\left(\frac{3}{2\pi}|\omega|-1\right)\right) & \text{Si } \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ (2\pi)^{-1/2} e^{\frac{j\omega}{2}} \cos\left(\frac{\pi}{2} v\left(\frac{3}{2\pi}|\omega|-1\right)\right) & \text{Si } \frac{4\pi}{3} \leq |\omega| \leq \frac{8\pi}{3} \\ 0 & \text{Si } |\omega| \notin \left[\frac{2\pi}{3}, \frac{8\pi}{3}\right] \end{cases} \quad (IV.12)$$

Avec v est une fonction de classe C^k (k arbitraire pouvant être égale à l'infini) et elle définie par :

$$v(t) = \begin{cases} 0 & \text{si } t \leq 0 \\ t & \text{si } 0 \leq t \leq 1 \\ 1 & \text{si } t \geq 1 \end{cases} \quad (IV.13)$$

La forme de cette ondelette est illustrée dans la figure IV.6:




Figure IV.6 : la forme de l'ondelette de Meyer.

IV.2.4. Analyse par Paquets d'Ondelettes

La méthode des paquets d'ondelettes est une généralisation de la décomposition en ondelettes qui offre une plus riche de possibilité pour l'analyse du signal [104]. Elle consiste à décomposer le signal sur un arbre de fonctions de base obtenues à partir de l'ondelette mère. Cela s'agit toujours d'utiliser un filtre passe-bas et un autre filtre passe-haut complémentaires, mais la différence réside sur le principe de cette analyse qui sert à réitérer le processus de décomposition en approximation et en détail non plus sur les coefficients d'approximation mais aussi sur ceux des détails.

Le paquet d'ondelettes décompose le signal original qui est supposé stationnaire ou non stationnaire dans des bandes de fréquence indépendantes. C'est une approche efficace d'analyse basée sur la multi-résolution et souvent proposée comme méthode de diagnostic de défaut. La décomposition en paquets d'ondelettes peut donc être représentée sous la forme d'un arbre comme illustre la figure IV.7 :

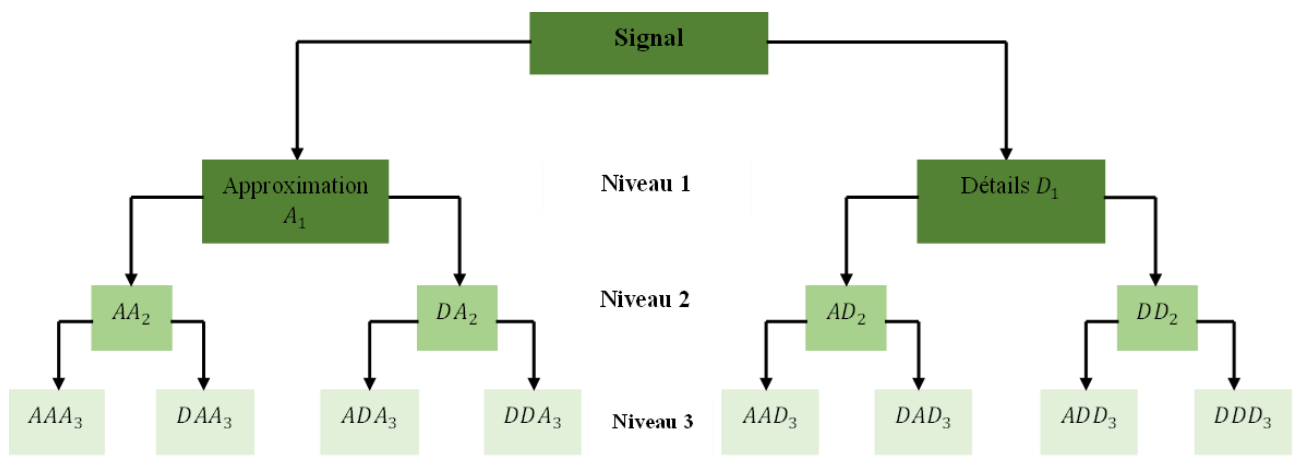


Figure IV.7 : Arbre de la décomposition en paquets d'ondelettes.

IV.2.5. Analyse Multi-Résolution en Ondelettes (AMRO)

Grâce à Mallat, l'AMRO a été présentée pour la première fois en 1989, apportant ainsi une nouvelle approche à l'analyse multi-résolution en ondelettes. Cette analyse, comme son nom l'indique, offre des résolutions temporelles et fréquentielles variées, permettant d'avoir une vue allant du plus détaillé au plus général. Cela implique de diviser le signal en utilisant l'analyse en ondelettes en passant par deux filtres complémentaires : passe-bas (L) et passe-haut (H). A ce niveau, deux vecteurs seront obtenus : cA_1 et cD_1 . Les éléments cA_1 sont appelés les approximations qu'ils correspondent aux plus basses fréquences, tandis que les éléments de cD_1 représentent les détails et correspondent aux plus hautes fréquences d'entre elles. La

procédure de cette décomposition est répétée avec les éléments du vecteur cA_1 et successivement avec chaque nouveau vecteur cA_k obtenu. Egalement, ce processus peut être répété n fois, avec n est le nombre maximal de niveaux de décomposition [105,106].

La décomposition obtenue d'un signal x , s'écrit comme suit :

$$x = cA_k + \sum_{i \leq k} cD_i \tag{IV.14}$$

$$cA_{k-1} = cA_k + cD_k \tag{IV.15}$$

Où: i et k sont des entiers.

Afin de procéder à l'analyse multi-résolution, chaque ondelette doit avoir sa propre banque de filtres, qu'on appelle généralement g_n et h_n . La bande de fréquence de chaque niveau i de la décomposition est obtenue par : $\left[0, \frac{F_{max}}{2^i}\right]$ pour les approximations et $\left[\frac{F_{max}}{2^i}, \frac{F_{max}}{2^{i-1}}\right]$ pour les détails. Où F_{max} est la fréquence maximale du signal.

Un exemple représentatif de cette décomposition de $n = 3$ est illustré dans la figure IV.8

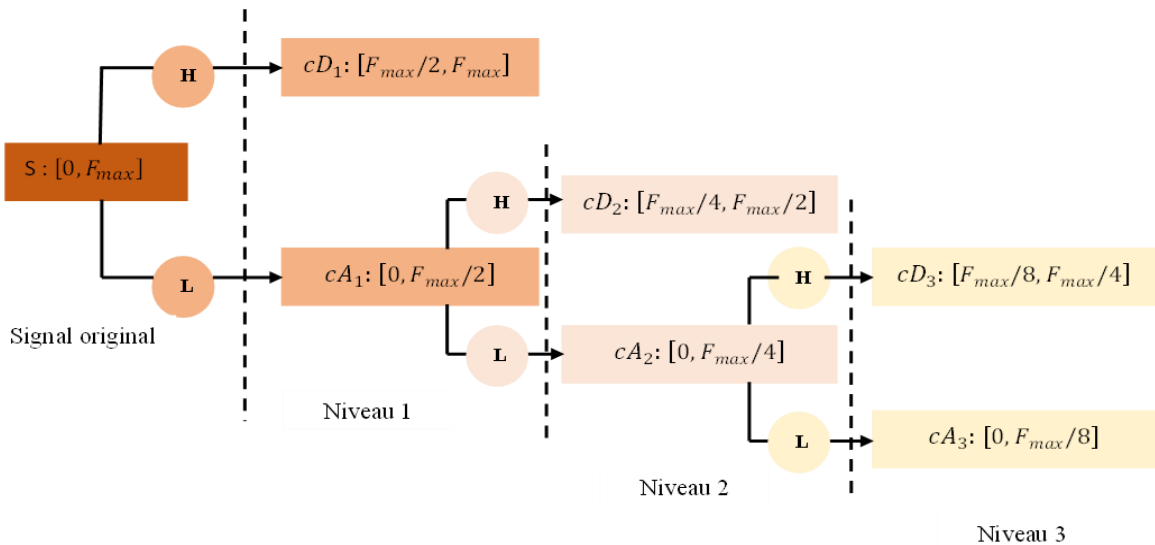


Figure IV.8 : Décomposition d'un signal en cascade en trois niveaux [107].

IV.2.6. Application de l'Analyse Multi-Résolution en Ondelettes sur les signaux simulés

Avant d'entamer le processus de décomposition en ondelettes, deux critères doivent être pris en compte : le calcul du nombre de niveaux de décomposition et la sélection de l'ondelette mère parmi les diverses familles d'ondelettes disponibles.

IV.2.6.1. Nombre de niveaux optimal de la décomposition par ondelettes

Pour effectuer une sélection optimale du nombre de niveaux de décomposition en ondelettes, il faut que le nombre de niveaux doive combiner entre ces deux conditions, de tel il ne doit pas être petit pour ne pas perdre les informations pertinentes, tout en évitant qu'il ne soit pas excessivement grand de telle sorte qu'on calcule les niveaux inutiles et passer aux plus basses fréquences. A cet effet, plusieurs travaux de recherche ont déterminé le nombre de niveaux de décomposition des signaux en ondelettes selon la nature du signal traité. Pour un signal vibratoire, le nombre de niveaux de décomposition est défini par la relation suivante [108]:

$$N \geq 2 \times \log\left(\frac{f_s}{4}\right) \quad (\text{IV.16})$$

Avec : f_s : est la fréquence d'échantillonnage.

Dans notre application, la fréquence d'échantillonnage f_s est fixée à 12000 Hz, ce qui nous permet d'effectuer une analyse multi-résolution en ondelettes avec jusqu'à sept niveaux de décomposition.

$$N \geq 2 * \log\left(\frac{12000}{4}\right) \rightarrow N = 7 \quad (\text{IV.17})$$

IV.2.6.2. Ondelette mère optimale pour la décomposition en ondelettes

Choisir l'ondelette mère la plus convenable à la décomposition permet de déterminer une résolution de la transformée en ondelettes, soit dans les deux domaines temporel et fréquentiel. Selon des travaux de recherches précédentes [109, 110], l'ondelette sélectionnée est celle qui possède un kurtosis maximal pour chaque détail reconstruit. Dans ce but, nous avons calculé le kurtosis pour chaque détail reconstruit en utilisant différents types d'ondelettes mères pour la décomposition de signal simulé de défaut de la bague extérieure, ayant une fréquence de défaut de 104,3 Hz. Les figures IV.9 (a-b) illustrent le signal simulé du défaut de la bague extérieure avec deux niveaux de bruit de SNR de 5 dB et de -3 dB. L'analyse de ces figures révèle une distinction notable en termes de kurtosis entre les deux signaux simulés. Dans le cas du signal avec bruit de SNR de 5 dB, le kurtosis est significatif, mettant en évidence uniquement la présence des fréquences de chocs. En revanche, le signal avec bruit de SNR de -3 dB présente un kurtosis faible en raison de la présence du bruit, indiquant une puissance significative du bruit par rapport à la puissance du signal et entraînant effectivement un changement total du signal. Les figures IV.10 (a-b) montrent les résultats du kurtosis calculé pour chaque détail reconstruit résultant de la décomposition multi-niveau en ondelettes utilisant

différents types d'ondelettes mères, tels que haar, db3, db4, db5, db7, db8, sym4, sym8. On observe que le kurtosis est significatif pour la décomposition utilisant l'ondelette « db3 », ce qui suggère sa pertinence en tant qu'ondelette mère utilisée dans cette application.




Figure IV.9 (a-b) : Signal simulé présentant un défaut de la bague extérieure de 104,3 Hz avec deux niveaux de bruit.

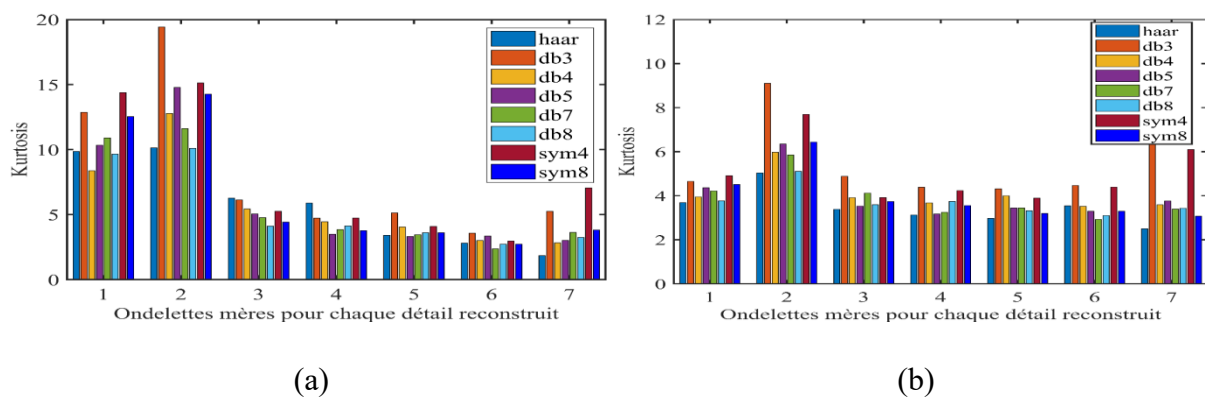


Figure IV.10 (a-b) : Kurtosis calculé de chaque détail reconstruit de la décomposition utilisant différents types d'ondelettes mères pour signal avec bruit. (a) : SNR=5 dB. (b) : SNR=-3 dB.

IV.2.6.3. Processus de l'analyse du signal simulé par la méthode de l'AMRO

Les fréquences fondamentales des défauts utilisées pour la simulation des signaux sont calculées en se basant sur les équations fournies dans le chapitre III (III.1-III.4) et les paramètres listés dans le tableau III.4. Ces fréquences sont ensuite récapitulées dans le tableau IV.1.

Tableau IV. 1 : Fréquences théoriques calculées des défauts du roulement.

| Fréquence de rotation | Fréquence de défaut de la bague intérieure | Fréquence de défaut de la bague extérieure | Fréquence de défaut de l'élément roulant | Fréquence de défaut de la cage |
|-----------------------|--|--|--|--------------------------------|
| 29.95 Hz | 162.40 Hz | 107.12 Hz | 139.86 Hz | 11.90-18.04 Hz |

Pour voir l'efficacité de cette méthode, on a pris quatre cas différents décrivant l'état du roulement (cas sain, cas de défaut de la bague extérieure, cas de défaut de l'élément roulant et cas de défaut de la bague intérieure). Le processus de l'application de la méthode de l'AMRO est décrit dans l'organigramme suivant :

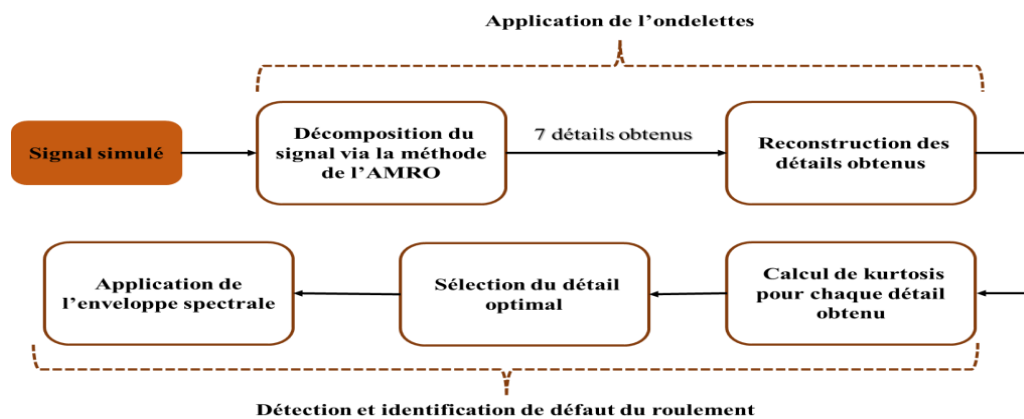


Figure IV.11 : Processus de l'application de la méthode de l'AMRO.

Ce processus est également résumé dans les étapes suivantes :

- 1) Déterminer le nombre de niveaux de décomposition n à travers l'équation (IV.17), et qui est équivalent à 7 ;
- 2) Appliquer la méthode de l'AMRO pour la décomposition du signal en sept niveaux en utilisant l'ondelette mère « db3 » ;
- 3) Reconstruire chaque détail obtenu par la transformée en ondelettes inverse pour éviter la perte de l'information utile dans les détails obtenus ;
- 4) Calculer le kurtosis de chaque détail reconstruit, puis sélectionner le détail reconstruit ayant le kurtosis le plus élevé comme optimal ;
- 5) Appliquer la méthode de l'enveloppe spectrale sur les détails reconstruits sélectionnés, pour but d'identifier les signatures de défauts du roulement.

La figure IV.12 illustre le signal temporel simulé d'un roulement en bon état, ayant un kurtosis de 2.9280, ce qui confirme que le roulement est en état normal. Par la suite, en analysant les résultats de l'application de la méthode de l'AMRO et le calcul du kurtosis de chaque détail reconstruit, comme illustré dans la figure IV.13, on remarque que le détail reconstruit 1 présente

le kurtosis le plus bas comparant à ceux des autres détails. Cela permet de le considérer comme le détail reconstruit renfermant le plus de l'information sur l'état du roulement.




Figure IV.12 : Signal simulé d'un état sain avec bruit de -1 dB.




Figure IV.13: Kurtosis calculé pour les sept détails reconstruits.

Suite à l'application de la méthode d'analyse d'enveloppe sur le détail reconstruit sélectionné, on constate que la fréquence de rotation f_r de 28 Hz et son multiple $2f_r$ équivalent à 60 Hz sont clairement identifiées dans le spectre d'enveloppe, comme le montre la figure IV.14, avec des amplitudes significatives de 0.02185 dB et 0.01818 dB respectivement. Ces fréquences sont très proches aux celles calculées théoriquement, comme indiqué dans le tableau (IV.1).




Figure IV.14: Spectre d'enveloppe du détail reconstruit 1 de l'état sain du roulement.

Pour mieux rapprocher le signal simulé de défaut de la bague extérieure de fréquence de 107.12 Hz au signal réel, on a ajouté un bruit d'un SNR de 5 dB, ce qui a donné un kurtosis de 7.2601, comme l'illustre la figure IV.15.




Figure IV.15: Signal simulé de défaut de la bague extérieure avec un bruit de 5 dB.

La figure IV.16 montre la variation du kurtosis calculé pour les sept détails reconstruit. On observe que la valeur du kurtosis est plus élevée pour le détail reconstruit 4, atteignant une valeur de 8.7799. Cela lui positionne comme le détail contenant le plus de l'information pertinente. Cette proposition est validée par le spectre d'enveloppe présenté sur la figure IV.17, qui révèle une fréquence de défaut de la bague extérieure similaire à celle calculée théoriquement, soit de 107 Hz, avec une amplitude significative de 0.008998 dB.




Figure IV.16: Kurtosis calculé pour les sept détails reconstruits.




Figure IV.17: Spectre d'enveloppe du détail reconstruit 4 de la décomposition par l'AMRO de signal simulé de défaut de la bague extérieure.

De la même procédure pour simuler le signal de défaut de la bague intérieure, on a ajouté aussi un bruit d'un SNR de 5 dB, ce qui a donné un kurtosis de 5.2323, comme indiqué dans la figure IV.18. Suite aux résultats du calcul du kurtosis pour chaque détail reconstruit, comme illustrés dans la figure IV.19, on constate que le détail 3 présente une valeur maximale du kurtosis de 8.3841, le désignant ainsi comme le détail optimal de la décomposition selon la méthode de l'AMRO.




Figure IV.18: Signal simulé de défaut de la bague intérieure d'un bruit de 5 dB.




Figure IV.19: Kurtosis calculé pour les sept détails reconstruits.

Les résultats du calcul du kurtosis sont validés par l'application de l'analyse d'enveloppe, laquelle indique une fréquence de défaut de la bague intérieure de 162 Hz, similaire à la fréquence calculée théoriquement avec une amplitude importante de 0.01113 dB comparant aux autres détails reconstruits. Le spectre d'enveloppe de détail reconstruit 3 est illustré dans la figure IV.20.




Figure IV.20: Spectre d'enveloppe de détail reconstruit 3.

Dans le dernier cas décrivant un défaut de l'élément roulant (bille) du roulement, pour simuler un signal de ce défaut similaire au signal réel on a ajouté un bruit de -3 dB donnant un kurtosis de 3.7259, comme indiqué dans la figure IV.21. Ainsi, le calcul du kurtosis de chaque détail reconstruit résultant de la décomposition de signal de défaut de la bille par la méthode de l'AMRO a révélé que le détail reconstruit 4 présente une valeur maximale de kurtosis de 7.3874, comme le montre la figure IV.21. Cela le désigne comme le détail optimal de la décomposition, car, selon le spectre d'enveloppe illustré dans la figure IV.22, il indique une fréquence de défaut plus proche de la fréquence calculée théoriquement, équivalente à 140 Hz, avec une amplitude significative de 0.00597 dB.




Figure IV.21: Signal simulé de défaut de la bille avec un bruit de -3 dB.




Figure IV.22: Kurtosis calculé pour les sept détails reconstruits.




Figure IV.23: Spectre d'enveloppe de détail reconstruit 4 de défaut de la bille.

IV.2.7. Application de la méthode de l'AMRO sur les signaux réels

Dans cette section, on a répété le même processus suivi pour analyser les signaux simulés afin d'analyser les signaux réels, dont le but est de faire une comparaison entre les deux types de signaux tout en validant l'efficacité de la méthode des ondelettes choisie.

La figure IV.24 illustre le signal temporel de l'état sain du roulement. On observe que le kurtosis est de 2.7642, ce qui signifie clairement que le roulement est en état sain. Ainsi, comme indiqué dans la figure IV.25, les résultats de la décomposition de ce signal ont montré que le détail reconstruit 1 est celui qui contient cette information, présentant un kurtosis plus bas, équivalent à 2.8601. Ceci est validé par le spectre d'enveloppe illustré dans la figure IV.26, qui indique uniquement la fréquence de rotation à 29.91 Hz qui est, exactement similaire à celle calculée théoriquement (tableau IV.1), avec une amplitude de 0.0009955 dB, ce qui confirme effectivement que le roulement est en bon état.




Figure IV.24: Signal temporel d'un état sain du roulement réel.




Figure IV.25: Kurtosis calculé pour les sept détails reconstruits d'un cas sain du roulement.




Figure IV.26: Spectre d'enveloppe du détail reconstruit 1 représentant un cas sain du roulement.

Le signal temporel d'un cas réel de défaut de la bague extérieure du roulement tournant avec une vitesse de 1797 RPM et avec une fréquence d'échantillonnage de 12000 Hz est représenté dans la figure IV.27. On remarque que le kurtosis est de 7.6494 ce qui confirme la présence de défaut dans la bague extérieure. D'après le résultat du calcul du kurtosis de chaque détail reconstruit illustré dans la figure IV.28, on observe que le détail 2 présente une valeur significative du kurtosis de 13.1134, permettant la localisation de la fréquence de défaut dans ce détail par son spectre d'enveloppe représenté dans la figure IV.29. De plus, cette figure révèle clairement la fréquence de défaut de la bague extérieure de 107.6 Hz avec une amplitude significative de 0.3865 dB.




Figure IV.27: Signal temporel de défaut de la bague extérieure du roulement.




Figure IV.28: Kurtosis calculé pour les sept détails reconstruits de défaut de la bague extérieure.




Figure IV.29 : Spectre d'enveloppe du détail reconstruit 2 de défaut de la bague extérieure.

La figure IV.30 illustre le signal temporel de défaut de la bague intérieure du roulement qui présente un kurtosis de 5.3959, confirmant la présence de défaut dans cet élément. Ensuite, l'analyse du kurtosis pour chaque détail reconstruit a révélé que le détail 2 présente une valeur importante du kurtosis de 8.7469 comme indiqué dans la figure IV.31. Cela localise bien selon le spectre d'enveloppe illustré dans la figure IV.32 le défaut de la bague intérieure à une fréquence de 161.7 Hz, qui est très proche de la fréquence calculée théoriquement. On constate également, à partir de ces résultats du calcul, que le détail reconstruit 7 indique une valeur très élevée de kurtosis de 37.8879, mais en analysant son spectre d'enveloppe, comme présenté dans la figure IV.33, on trouve qu'il ne présente aucune fréquence fondamentale de défaut. Cela revient à l'effet de débruitage par la technique des ondelettes.




Figure IV.30: Signal temporel de défaut de la bague intérieure du roulement.




Figure IV.31: Kurtosis calculé pour les sept détails reconstruit de défaut de la bague intérieure.




Figure IV.32: Spectre d'enveloppe de détail reconstruit 1 de défaut de la bague intérieure.




Figure IV.33: Spectre d'enveloppe de détail reconstruit 7 de défaut de la bague intérieure.

Le dernier cas est le défaut de la bille du roulement, représenté par le signal temporel illustré dans la figure IV.34, qui indique un kurtosis de 2.9847. Cette valeur est plus basse pour représenter un tel défaut, mais cela revient à l'effet du bruit généré par la rotation de la bille entre les deux bagues du roulement. En analysant le kurtosis calculé pour les sept détails reconstruits, illustré dans la figure IV.35, on trouve que le détail 1 présente un kurtosis significatif de 5.1570, ce qui permet de localiser précisément le défaut de la bille à une fréquence de 137.6 Hz, comme indiqué dans le spectre d'enveloppe présenté dans la figure IV.36. Le spectre contient également les fréquences de rotation ainsi que les fréquences des défauts de la bague extérieure et de la bague intérieure, à des fréquences respectives de 29.96, 107.7 et 161.6 Hz. Cela est influencé effectivement par la bille qui tourne entre les deux bagues extérieure et intérieure.




Figure IV.34: Signal temporel de défaut de la bille du roulement.




Figure IV.35: Kurtosis calculé pour les sept détails reconstruit de défaut la bille.




Figure IV.36: Spectre d'enveloppe du détail reconstruit 1 de défaut de la bille.

IV.3. Décomposition en mode empirique (EMD)

La méthode de l'EMD sert à décomposer le signal initial, noté $x(t)$, à des composantes plus informatives connues par *IMFs* et les composantes résiduelles qui ont des structures non corrélatives simples et des fonctions non trigonométriques [111, 112].

Premièrement, Une IMF est une fonction oscillante de moyenne zéro, c'est-à-dire une fonction qui doit respecter deux conditions spécifiques [68]:

- Dans l'ensemble de la séquence de données, le nombre d'extrema et de points de passage à zéro doit être égal ou différent de 1.
- Pour tout point de la séquence de données, la valeur moyenne des enveloppes définies par les maxima et minima locaux est nulle. Autrement dit, autour de l'axe du temps, le signal est localement symétrique.

Ainsi, la méthode de l'EMD passe par un algorithme dont il est résumé par des étapes synthétisées comme suit :

- 1) Identifier tous les points extrêmes locaux successifs des input $(t) = x(t)$, c'est-à-dire les maxima et les minima.
- 2) Calculer l'enveloppe supérieure, $E_{max}(t)$, et l'enveloppe inférieure, $E_{min}(t)$, par une courbe cubique qui couvre tous les maxima et minima locaux interpolés respectivement. De telle sorte, l'ensemble du signal de données est contenu dans ces deux enveloppes.
- 3) Calculer la ligne moyenne en fonction du temps désignée par $m(t)$ de ces deux enveloppes :

$$m(t) = \frac{E_{max}(t) + E_{min}(t)}{2} \quad (\text{IV.18})$$

- 4) Pour générer la IMF candidate $h_{i,k}(t)$, soustraire $m(t)$ de $h_{i,(k-1)}(t)$:

$$h_{i,k}(t) = h_{i,(k-1)}(t) - m \quad , \text{ici : } h_{1,1}(t) = x(t) \quad (\text{IV.19})$$

- 5) Si le critère d'arrêt n'est pas respecté, fixer input(t) = $h_{i,k}(t)$ et répéter les étapes 2 à 5. Dans le cas contraire, passer à l'étape 6.
- 6) Fixer le IMF $c_i(t) = h_{i,k}(t)$ et calculer le résidu $r_i(t)$ comme suit :

$$r_i(t) = r_{i-1}(t) - c_i(t) \quad , \text{où : } r_0(t) = x(t) \quad (\text{IV.20})$$

- 7) Pour trouver la composante IMF suivante, fixer $\text{input}(t) = r_i(t)$ et répéter les étapes 2 à 7. Cette procédure peut être inversée en additionnant les modes intrinsèques et le terme résiduel final pour reconstruire le signal original :

$$x(t) = \sum_{i=1}^n c_i(t) + r_{n+1}(t) \quad (\text{IV.21})$$

Le terme d'oscillation rapide est progressivement éliminé de la première à la dernière IMF au cours de la décomposition du signal à large bande, ce qui donne des signaux successifs dont le contenu fréquentiel est de plus en plus faible. Pour décomposer le signal original à large bande en composantes IMF, l'algorithme EMD utilise un processus de tamisage. Par conséquent, le critère d'arrêt est essentiel, car le concept physique du composant doit être préservé pour éviter une sur-décomposition tout au long du processus de filtrage. En général, en raison de l'écart entre les signaux, les diverses applications exigent souvent des conditions d'arrêt différentes. L'un des critères d'arrêt basé sur l'écart-type connu par standard deviation (SD) est donné par un test de convergence de type Cauchy, la différence quadratique normalisée entre deux opérations de tamisage successives est définie comme suit :

$$SD = \sum_{t=0}^T \frac{|h_{i,(k-1)}(t) - h_{i,k}(t)|^2}{h_{i,(k-1)}^2(t)} \quad (\text{IV.22})$$

Dans la pratique, des valeurs de SD de 0,2 à 0,3 ont été observées.

Cependant, la décomposition est terminée lorsque $r_n(t)$ satisfait une des conditions suivantes :

- $r_n(t)$ soit une fonction monotone ;
- Le nombre d'extrema dans $r_n(t)$ soit inférieure à 2 ;
- $r_n(t)$ soit une constante.

IV.3.1. Application de l'EMD sur les signaux simulés

La procédure suivie pour tester l'efficacité de cette technique comprend plusieurs étapes, qui sont présentées comme suit :

- 1) Application de la technique de l'EMD pour décomposer le signal simulé ;
- 2) Calcul des deux facteurs, le kurtosis et le coefficient de corrélation entre les *IMFs* obtenues et le signal original ;
- 3) Sélection de l'*IMF* ayant le coefficient de corrélation supérieure à 0.1 comme un mode utile ;

4) Application de l'analyse de l'enveloppe pour l'identification de défaut existant.

A propos de l'application de la technique de l'EMD, le facteur du kurtosis n'a pas donné exactement le mode utile résultant par la décomposition, contrairement au cas de l'utilisation de la méthode de l'AMRO dans la première partie, ce qui a nécessité l'utilisation de coefficient de corrélation qui a permis d'obtenir de meilleurs résultats. La décomposition en mode empirique (EMD) est appliquée pour les quatre états différents du roulement (état sain, état de défaut de la bague extérieure, état de défaut de la bille et état de défaut de la bague intérieure) et a généré 10 modes empiriques pour tous les cas simulés. Les résultats obtenus par cette technique sont illustrés dans les sections qui suivent :

1) Etat sain simulé du roulement

En analysant les résultats du calcul de kurtosis de chaque *IMF* obtenue et le coefficient de corrélation entre le signal original et les *IMFs* illustrés dans les figures IV.37 (a, b), on remarque que l'*IMF1* a rempli les deux conditions : le kurtosis égale à 2.1253 qui est inférieure à 3 et le coefficient de corrélation équivalent de 0.8010 qui est supérieure à 0.1. Cela confirme que le l'*IMF1* est le mode utile pour cette décomposition. La figure IV.38 illustre le spectre d'enveloppe de l'*IMF1* qui indique une fréquence de 26 Hz à une amplitude de 0.01931 dB qui est proche à celle calculée théoriquement, ce qui valide que ce mode décrit bien l'état sain de signal simulé du roulement.




Figure IV.37 (a-b) : Facteurs calculés pour les 10 *IMFs* représentant le cas sain du roulement. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.38 : Spectre d'enveloppe de l'*IMF1* de l'état sain du roulement.

2) Etat de défaut de la bague extérieure simulé

A l'aide de coefficient de corrélation calculé entre les *IMFs* et le signal original, on trouve que l'*IMF1* est corrélé avec le signal original d'un coefficient de 0.5863 et possède un kurtosis de faible intensité comme montré dans les figures IV.40 (a, b). Le spectre d'enveloppe de ce mode indique effectivement la fréquence de défaut de la bague extérieure de 107 Hz qui est une valeur similaire à celle calculée théoriquement avec une amplitude significative de 0.02281 dB.




Figure IV.39 (a-b) : Facteurs calculés pour les 10 *IMFs* représentant le défaut de la bague extérieure. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.40: Spectre d'enveloppe de l'*IMF1* de défaut de la bague extérieure.

3) Cas de défaut de la bille

D'après les résultats de calcul de coefficient de corrélation qui vaut 0.5185 comme illustrés dans la figure IV.42 (b), on remarque que l'*IMF1* est le mode utile. Cette affirmation est validée par le spectre d'enveloppe montré dans la figure IV.43 présentant une fréquence de défaut de la bille de 142 Hz qui est proche de la fréquence calculée théoriquement avec une amplitude de 0.01911 dB.




Figure IV.41 (a-b) : Facteurs calculés pour les 10 *IMF*s représentant le défaut de la bille. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.42 : Spectre d'enveloppe de l'*IMF1* de défaut de la bille.

4) Cas de défaut de la bague intérieure

Selon les coefficients de corrélation calculés entre les 10 *IMF*s et le signal original (figure IV.44 (a, b)), on constate que l'*IMF3* présente la valeur la plus élevée, soit 0.6175. La figure IV.45 illustre le spectre d'enveloppe de l'*IMF3*. Elle indique que l'*IMF3* est le mode utile, contenant une fréquence de défaut de 162Hz, qui correspond à une valeur similaire à la fréquence de défaut de la bague intérieure calculée théoriquement avec une amplitude significative de 0.01419 Db.




Figure IV.43 (a-b) : Facteurs calculés pour les 10 *IMF*s représentant le défaut de la bague intérieure. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.44: Spectre d'enveloppe de l'*IMF*3 de défaut de la bague intérieure.

En analysant tous les cas de figure étudiés pour les défauts des éléments du roulement, on constate que la méthode de décomposition en modes empiriques (EMD) identifie dans la plupart des cas l'*IMF*1 comme le mode utile contenant l'information pertinente pour détecter avec précision la présence de défauts.

Dans la section prochaine, on a refait le même processus pour les signaux réels, et les résultats de la décomposition sont présentés comme suit.

IV.3.2. Application de l'EMD sur les signaux réels

1) Cas sain du roulement réel

Tout comme le cas des signaux simulés, les résultats de la décomposition par la méthode de l'EMD des signaux réels ont également généré 10 modes (*IMF*s). Les figures IV. 46 (a, b) montrent les résultats du calcul du kurtosis et du coefficient de corrélation pour ces 10 modes, et indiquent que l'*IMF*1 est fortement corrélé avec le signal original, avec un coefficient de corrélation de 0.8286. Selon le spectre d'enveloppe illustré dans la figure IV.47, cela le positionne comme un mode utile, qui identifie la fréquence de rotation de 29.91 Hz avec une

amplitude de 0.0001151 dB, et ne présente aucune fréquence de défaut, ce qui confirme que le roulement est en bon état.

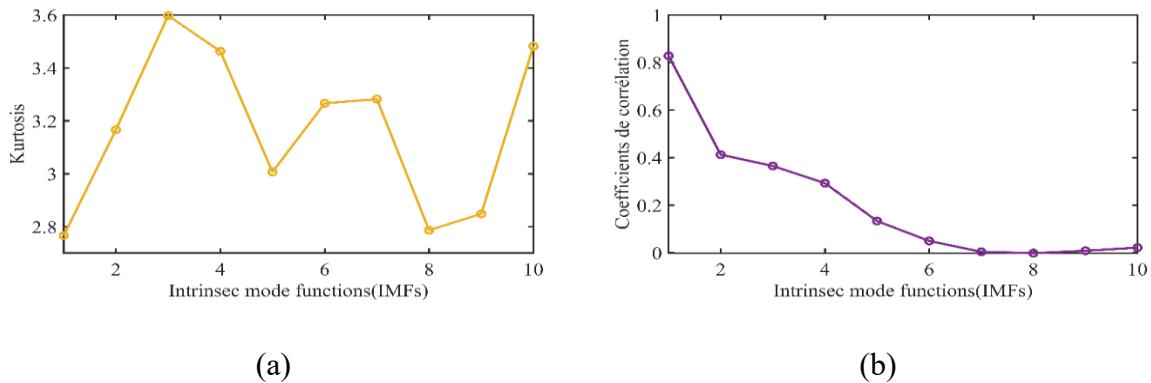


Figure IV.45 (a-b) : Facteurs calculés pour les 10 *IMF*s représentant le cas sain. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.46: Spectre d'enveloppe de l'*IMF1* d'un cas sain du roulement.

2) Cas réel de défaut de la bague extérieure

On remarque d'après la figure IV.48 (b) que le signal de défaut de la bague extérieure est fortement corrélé avec le premier *IMF* résultant de la décomposition, avec un coefficient de 0.9919. Le spectre d'enveloppe de l'*IMF1* confirme sa pertinence, contenant uniquement la fréquence de rotation de 29.9 Hz à une amplitude de 0.1114, ainsi une fréquence de défaut de 107.6 Hz correspondant à une amplitude significative de 0.5405 dB, comme indiqué dans la figure IV.49. Cela valide également la présence de défaut au niveau de la bague extérieure du roulement.




Figure IV.47 (a-b) : Facteurs calculés pour les 10 *IMF*s représentant le cas de défaut de la bague extérieure. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.48: Spectre d'enveloppe de l'*IMF1* de défaut de la bague extérieure.

3) Cas de défaut de la bille

Selon le calcul de coefficient de corrélation entre le signal original de défaut de la bille et ses *IMF*s, la figure IV.50 (b) indique que le signal est bien corrélé avec l'*IMF1* à un coefficient de 0.8286. La figure IV.51 illustre le spectre d'enveloppe de ce mode qui identifie la fréquence de défaut de la bille de 137.6 à une amplitude de 0.007111 dB, ainsi les fréquences suivantes : la fréquence de rotation, la fréquence de défaut de la bague extérieure et la fréquence de défaut de la bague intérieure. La présence de toutes ces fréquences revient à l'emplacement de cette bille entre ces éléments dans le roulement.




Figure IV.49 (a- b) : Facteurs calculés pour les 10 *IMFs* représentant le cas de défaut de la bille. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.50: Spectre d'enveloppe de l'*IMF1* de défaut de la bille.

4) Cas de défaut de la bague intérieure

La figure IV.52 (b) présente les résultats du calcul du coefficient de corrélation entre le signal original de défaut de la bague intérieure et ses 10 *IMFs*. On constate que le signal original est fortement corrélé avec son premier *IMF*, avec un coefficient de 0.9458. Le spectre d'enveloppe de ce mode, tel qu'indiqué dans la figure IV.53, identifie la fréquence de défaut de la bague intérieure à une fréquence de 161.7 Hz, avec une amplitude significative de 0.1188 dB. Ainsi les autres fréquences suivantes : la fréquence de rotation, la fréquence de la bille et la fréquence de la bague extérieure qui présentent des amplitudes moins élevées, comparant avec l'amplitude de défaut de la bague intérieure.




Figure IV.51 (a- b) : Facteurs calculés pour les 10 *IMF*s représentant le cas de défaut de défaut de la bague intérieure. (a) : Kurtosis. (b) : Coefficient de corrélation.




Figure IV.52: Spectre d'enveloppe de l'*IMF1* de défaut de défaut de la bague intérieure.

On peut conclure, à partir des résultats atteints pour les deux cas, à savoir les signaux simulés et les signaux réels, que les résultats du calcul du kurtosis pour chaque *IMF*, obtenus par la méthode de décomposition en modes empiriques (EMD), sont moins utiles comparant au coefficient de corrélation qui donne avec précision le mode pertinent et utile. On peut dire alors que le kurtosis est bien adapté à la méthode des ondelettes, tandis que le coefficient de corrélation est bien meilleur pour la méthode de l'EMD.

IV.4. Synthèse des résultats des deux méthodes : AMRO et EMD

Cette section sert à résumer tous les résultats obtenus par les deux méthodes, à savoir la méthode de l'analyse multi-résolution en ondelettes (AMRO) et la méthode de décomposition en modes empiriques (EMD), pour tous les signaux simulés et réels. Après analyse, il paraît que l'application des deux méthodes, l'AMRO et l'EMD, sur les signaux simulés et réels, montre que les signaux réels ont donné de bons résultats que les signaux simulés. Plus précisément, les pics des signaux réels sont bien identifiés dans les spectres d'enveloppe obtenus. Les fréquences de chaque état étudié, tels que l'état sain, l'état de défaut de la bague

extérieure, l'état de défaut de la bille et l'état de défaut de la bague intérieure, sont très similaires aux fréquences calculées théoriquement, comme illustré dans le tableaux IV.1. De plus, leurs amplitudes sont significatives par rapport aux signaux simulés.

En comparant maintenant entre les résultats obtenus des deux méthodes, l'AMRO et l'EMD, on constate que le kurtosis est efficace lors des calculs appliqués aux détails obtenus par l'AMRO, ce qui est validé par le spectre d'enveloppe qui donne le même détail sélectionné par le kurtosis, contrairement à la méthode de l'EMD, qui a nécessité le calcul d'un autre facteur tel que le coefficient de corrélation pour sélectionner le mode pertinent, car il s'est avéré que le kurtosis est maximal dans un *IMF* qui ne donne aucune information par le spectre d'enveloppe.

En outre, pour les signaux simulés, il est constaté que la méthode de l'AMRO est plus efficace pour détecter les défauts du roulement que la méthode de l'EMD. Contrairement à la méthode de l'EMD, les fréquences de défauts détectées par l'AMRO sont très proches aux fréquences calculées théoriquement. De plus, le calcul du kurtosis était suffisant pour sélectionner les détails pertinents, ce qui peut réduire le temps et les étapes du calcul, contrairement à la méthode de l'EMD qui requiert un autre facteur pour effectuer une sélection adéquate. De plus, ce qui concerne les signaux réels, les deux méthodes peuvent donner de meilleurs résultats, sauf on constate que l'EMD est très efficace pour détecter des amplitudes significatives par rapport aux amplitudes obtenues par la méthode de l'AMRO dans l'identification des amplitudes des fréquences de défaut. Cela revient à l'efficacité de l'EMD à filtrer et débruiter les signaux.

IV.5. Conclusion

L'idée principale de ce chapitre repose sur l'application des méthodes de traitement de signal, à savoir l'une des méthodes des ondelettes « AMRO » et la méthode de décomposition en mode empirique « EMD ». La première partie sert à exposer la théorie des ondelettes, ainsi l'application de la méthode de l'AMRO sur les deux types des signaux, les signaux simulés et les signaux réels, tout en optimisant le nombre de niveaux de décomposition et le choix de la famille d'ondelette utilisée dans cette application. Cette méthode a été proposé pour tester la sensibilité du facteur du « kurtosis » à la détection des chocs dans le signal, améliorer la qualité du signal résultant de la décomposition et garantir l'identification précoce de défauts dans les différents éléments du roulement.

Pour aboutir à une comparaison efficace entre la méthode de l'AMRO et l'EMD, la deuxième partie sert à présenter la méthode de l'EMD, puis l'application de cette dernière sur les deux signaux simulés et réels. L'objectif de cette application est pour valider l'efficacité des

de facteurs, à savoir le kurtosis et le coefficient de corrélation, dans la sélection des modes utiles et pertinent. Les modes obtenus des deux méthodes sont validés par l'application de la méthode d'analyse en enveloppe qui a permis à partir des spectres d'enveloppe des modes sélectionnés d'identifier et de détecter les pics de défauts des éléments du roulement. Il s'est avéré que la méthode de l'AMRO est meilleure en terme du temps du calcul et de la sélection de mode utile contenant significativement les fréquences et amplitudes des défauts des cas étudiés.

Après avoir traité et analysé les différents cas des signaux, le chapitre suivant sert à automatiser le diagnostic et la détection de défaut du roulement par l'apprentissage automatique.

Chapitre V

Diagnostic des défauts du roulement par l'apprentissage automatique : validation expérimentale

V.1. Introduction

Ce dernier chapitre vise à mettre en évidence l'utilité et l'efficacité de l'automatisation du diagnostic des défauts du roulement par l'application des algorithmes de l'apprentissage automatique (ML). L'objectif est de réaliser une étude comparative entre deux algorithmes largement reconnus dans le domaine de l'intelligence artificielle : la Random Forest (RF) et le Perceptron Multicouches de l'acronyme (MLP : Multi-Layer Perceptron). La première partie de ce chapitre est dédiée à la description de ces deux algorithmes, ainsi que le reste sert à exposer les résultats obtenus à partir de leur application. Ces résultats sont tous validés à travers d'essais pratiques effectués au sein du CWRU.

V.2. Description des algorithmes de la Random Forest et le Perceptron Multicouches (MLP)

Au cours des dernières décennies, les approches d'intelligence artificielle ont été au centre de la plupart des études visant à automatiser le diagnostic des défauts dans les machines tournantes. Elles peuvent être utilisées comme détecteurs de défauts et classificateurs de défauts pour faciliter le diagnostic et réduire la nécessité d'une intervention humaine[75]. Cette section sert à présenter une description détaillée des deux algorithmes largement utilisés dans la classification des défauts du roulement, la Random Forest (RF) et le Perceptron Multicouches (MLP).

V.2.1. Définition du classifieur Random Forest

L'algorithme Random Forest (RF) est une collection d'arbres de décision, où chaque arbre est formé individuellement sur un ensemble de données d'apprentissage indépendantes sélectionnées arbitrairement. Ici, l'ensemble de données d'entrée respectif pour chaque arbre est échantillonné séparément, et le taux de distribution est le même pour tous les arbres. La RF

donne de bons résultats non seulement en matière de classification et de régression, mais aussi des performances exceptionnelles en matière de sélection de variables [105].

- **Structure générale de la RF**

Premièrement, les arbres sont obtenus à partir de la combinaison d'ensembles de données avec un sous-échantillonnage Bootstrap et divers sous-ensembles de caractéristiques pour la division à chaque nœud. De même, une faible corrélation est obtenue sur la base de la sélection de sous-ensembles aléatoires de caractéristiques pour les arbres individuels. Enfin, après l'ensemble de tous les arbres, la RF se traduit par un faible biais et une faible variance pour le modèle. L'agrégation Bootstrap à partir du bagging est conçue alors pour accroître la stabilité et la précision des arbres individuels dans la RF [113].

Pour la prise de décision, la classe qui reçoit le vote majoritaire des arbres est sélectionnée dans le problème de classification. D'autre part, la moyenne des valeurs prédites par tous les arbres de décision est prise en compte dans les modèles de régression. La RF peut également surmonter le problème de l'overfitting, qui est l'un des principaux problèmes d'un algorithme d'arbre de décision. La RF utilise une technique d'accumulation, chaque fois qu'un sous-ensemble aléatoire de caractéristiques est utilisé pour former un seul arbre de décision et il agrège le résultat d'un certain nombre d'arbres de décision pour déterminer le résultat final. Ainsi, la RF est moins sujette à l'overfitting.

- **Principaux paramètres de la RF**

La diversité de l'arbre dans le RF est contrôlée par le nombre de caractéristiques. Ainsi, les paramètres de mise en œuvre de la RF sont le nombre d'arbres, le nombre de caractéristiques dans chaque division, la profondeur maximale et le nombre de nœuds feuilles de l'échantillon.

En général, un nombre élevé d'arbres est obligatoire pour obtenir une solution stable pour les problèmes de classification [79]. Le modèle RF consiste en un processus de division réalisé en divisant le nœud unique en deux nœuds ou plus. Le processus de vote majoritaire détermine la sortie finale du modèle, comme l'illustre la figure V.1.

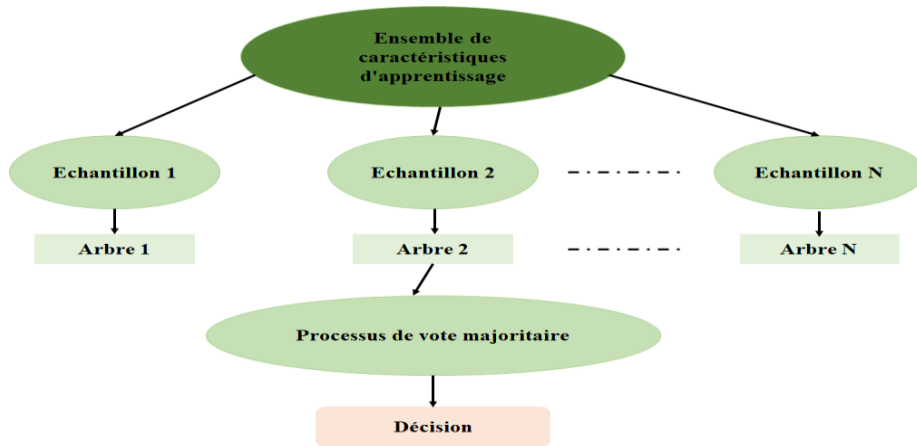


Figure V.1 : L'architecture du classifieur de la RF.

V.2.2. Définition du classifieur du Perceptron Multicouches (MLP)

Le MLP est l'architecture neuronale la plus populaire dans diverses applications industrielles [114]. Le MLP peut approximer la correspondance entre les entrées et les sorties dans un système non linéaire. Dans de tels cas, le MLP agit comme un modèle de substitution qui apprend les relations sous-jacentes entre les points de données d'entrée et de sortie. En formant un MLP sur un ensemble de données contenant des paires entrée-sortie, il apprend à approximer la relation inverse, ce qui lui permet de prédire les paramètres d'entrée ou les causes lorsqu'on lui donne des sorties observées. Cette approche s'avère particulièrement utile lorsqu'il s'agit de systèmes complexes ou non linéaires pour lesquels les méthodes analytiques traditionnelles peuvent poser des problèmes.

- **Architecture générale du MLP**

La structure du réseau MLP comprend des neurones regroupés en couches, d'entrée et de sortie, ainsi que des couches cachées qui n'ont pas de connexion directe avec les signaux externes. Chaque neurone de chaque couche est connecté à un neurone de la couche suivante, il n'y a pas de connexions entre les neurones d'une même couche et les données sont traitées en parallèle. L'architecture du réseau, qui comprend le nombre de couches et de neurones, ainsi que la qualité et la quantité des données d'apprentissage, joue un rôle essentiel dans l'obtention de résultats précis. La structure du réseau MLP avec une couche cachée est illustrée dans la figure V.2. En général, le réseau MLP peut être décrit comme suit :

$$y_k = f_2 \left(\sum_{i=1}^M w_{ki}^{(2)} \times f_1 \left(\sum_{j=1}^N w_{ij}^{(1)} \times x_j + w_0^{(1)} \right) + w_0^{(2)} \right) \quad (V.1)$$

Où $y_k \rightarrow k$ -ième sortie du réseau ; $x_j \rightarrow j$ -ième entrée du réseau ; $w_{ij}^{(1)}, w_{ki}^{(2)} \rightarrow$ poids de la première et de la deuxième couche cachée, respectivement ; $w_0^{(1)}, w_0^{(2)} \rightarrow$ biais dans la première et la deuxième couche cachée, respectivement.

Les réseaux neuronaux ont la capacité de discriminer des modèles complexes à partir de données et peuvent être entraînés à prédire les composants défectueux. Le réseau subit des mises à jour de poids et de biais en utilisant la technique d'optimisation de Levenberg-Marquardt [115].




Figure V.2 : Exemple de la structure du réseau de Perceptron Multicouche (MLP).

V.3. Critère d'évaluation de la classification des défauts

L'évaluation de la performance de classification des défauts peut être quantifiée en termes d'exactitude (accuracy), de sensibilité, de spécificité, de précision et de moyenne g.

- **Exactitude (accuracy)**

Exactitude ou ce qui est connu sous l'acronyme (accuracy) est le pourcentage d'exemples correctement classés, c'est-à-dire le pourcentage de prédictions correctes par rapport au nombre total de prédictions. Une classification avec une précision élevée est généralement considérée comme meilleure. Elle est définie comme suit [116]:

$$Exactitude = \frac{V_p + V_N}{V_p + V_N + F_p + F_N} \quad (V.2)$$

- **Sensibilité**

La sensibilité est la capacité d'obtenir un résultat positif en présence d'un défaut. Elle est donnée par :

$$\text{Sensibilité} = \frac{V_p}{V_p + F_N} \quad (\text{V.3})$$

- **Spécificité**

La spécificité est la capacité d'obtenir un résultat négatif en l'absence du défaut, et elle est donnée par la formule suivante :

$$\text{Spécificité} = \frac{V_N}{V_N + F_p} \quad (\text{V.4})$$

- **Précision**

La précision est le rapport entre les exemples positifs prédits et les exemples réellement positifs. Elle reformulée par :

$$\text{Précision} = \frac{V_p}{V_p + F_p} \quad (\text{V.5})$$

- **Moyenne -G**

La moyenne-Géométrique, aussi connue par le nom G-mean, est une mesure particulièrement utile lorsque les classes sont déséquilibrées. Elle combine entre la sensibilité et la précision en une seule mesure, et elle écrite par :

$$\text{Moyenne -G} = \sqrt{\text{Sensibilité} + \text{Précision}} \quad (\text{V.6})$$

- **F1-score**

Le F1-score résume les valeurs de précision et la sensibilité en une seule mesure et peut être simplifié et exprimé directement à partir des composantes de la matrice de confusion.

$$\text{F1-score} = \frac{V_p}{V_p + \frac{1}{2}(F_p + F_N)} \quad (\text{V.7})$$

- **Matrice de confusion (Confusion Matrix)**

La matrice de confusion est une table qui illustre le nombre de prédictions correctes et incorrectes réalisé par le modèle. Elle est souvent utilisée pour visualiser les performances du modèle en termes de vrais positifs, faux positifs, vrais négatifs et faux négatifs.

Où :

- ✓ V_p : Vrai positif qui représente un résultat où le modèle prédit correctement la classe positive (défaut détecté).
- ✓ V_N : Vrai négatif qui représente un résultat où le modèle prédit correctement la classe négative (aucun défaut détecté).
- ✓ F_p : Faux positif qui représente un résultat où le modèle prédit incorrectement la classe positive.
- ✓ F_N : Faux négatif qui représente un résultat où le modèle prédit incorrectement la classe négative.

V.4. Extraction des indicateurs de défauts du roulement

La phase d'extraction des caractéristiques des défauts localisés sur les éléments du roulement se base principalement sur l'analyse des amplitudes des fréquences de défauts obtenues par la combinaison Ondelettes-Enveloppe spectrale, comme illustré dans le processus d'analyse des signaux réels dans la section IV.2.7 du chapitre IV. Ainsi, afin d'extraire les indicateurs des pics des fréquences caractéristiques obtenus à partir des spectres d'enveloppe des différents cas sains et défectueux, les amplitudes de ces fréquences sont analysées pour quatre charges différentes (0 Nm, 4 Nm, 8 Nm et 12,3 Nm) et pour différents diamètres de défauts (0,1778 mm, 0,3556 mm, 0,5334 mm et 0,7112 mm), de la bague extérieure, de la bille et de la bague intérieure. En prenant le cas de défaut de la bague extérieure, plusieurs exemples d'amplitudes d'harmoniques sélectionnées sont montrés dans les figures V.3 à V.6. Ces exemples couvrent les situations où, d'une part la charge est fixée à 0 Nm et le diamètre de défaut varie de 0,1778 mm à 0,5334 mm, et d'autre part, le défaut est maintenu à un diamètre important tout en changeant le couple de charge de 0 Nm à 12,3 Nm, avec différentes positions de l'accéléromètre (centrale, orthogonale et opposée).




Figure V.3: Diamètre variable et charge fixe à 0 Nm avec une position centrale de l'accéléromètre.




Figure V.4: Charge variable et diamètre fixe à 0.5534 mm avec une position centrale de l'accéléromètre.

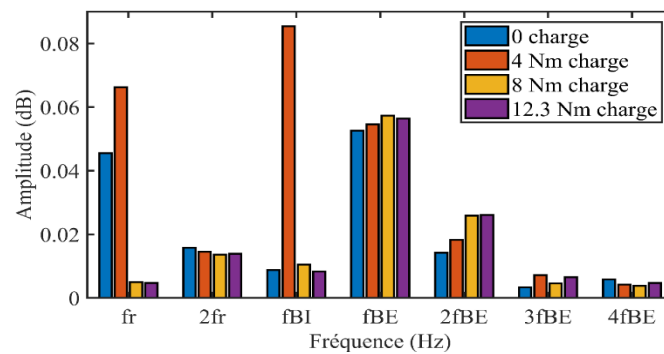


Figure V.5: Charge variable et diamètre fixe à 0.5534 mm avec une position orthogonale de l'accéléromètre.




Figure V.6 : Charge variable et diamètre fixe à 0.5534 mm avec une position opposée de l'accéléromètre.

Une analyse détaillée des résultats obtenue a permis de vérifier comment le couple de charge, le diamètre du défaut et la position de l'accéléromètre affectent les amplitudes harmoniques des fréquences caractéristiques de défauts. D'après les figures V.3-V6, les harmoniques sélectionnées sont caractérisées par une certaine conformité avec le changement de la valeur du diamètre du défaut, du couple de charge et de la position de l'accéléromètre.

Une augmentation significative de l'amplitude du défaut de la bague extérieure (f_{BE}) est observée lorsque le diamètre du défaut augmente, comme le montre la figure V.3. En outre, lorsque la valeur du couple de charge augmente, comme illustré dans la figure V.4, les harmoniques sélectionnées sont caractérisées par une augmentation de l'amplitude. Également, pour la même condition, on constate que la position de l'accéléromètre joue un rôle important dans la prise des mesures des vibrations générées par les défauts du roulement. En analysant les figures V.4, V.5 et V.6, on trouve que lorsque l'accéléromètre est positionné au centre du roulement, les amplitudes harmoniques de défauts augmentent significativement comparant aux autres positions : orthogonale et opposée. En appliquant la même procédure aux autres défauts de la bague intérieure et de la bille, on trouve que ces conditions sont satisfaites par les fréquences suivantes : f_r , $2f_r$, f_{BI} , $2f_{BI}$, $3f_{BI}$, f_{ER} , $2f_{ER}$, f_{ER+} , $4f_{ER}$, f_{BE} , $2f_{BE}$, $3f_{BE}$ et $4f_{BE}$. Ces fréquences sont donc considérées comme de nouveaux indicateurs caractéristiques qui seront utilisées comme entrées pour former le système d'apprentissage automatique basé sur les classifieurs de Random Forest (RF) et de Perceptron Multicouche (MLP).

V.5. Localisation de défauts du roulement par l'application de RF et de MLP

Le diagnostic par la localisation des défauts du roulement repose principalement sur la comparaison des résultats atteints par l'application de Random Forest et de Perceptron multicouche sur des signaux vibratoires réels de CWRU. Les différents résultats sont donc représentés dans les sections qui suivent.

V.5.1. Application de l'algorithme de Random Forest

Pour compléter le processus de diagnostic des défauts du roulements, l'apprentissage automatique basé sur la Random Forest est utilisé pour localiser et classifier les défauts de la bague extérieure, de l'élément roulant (bille) et de la bague intérieure. L'ensemble de données utilisé pour entraîner l'algorithme RF forme une matrice de (64x12), où 64 représente le nombre total de signaux réels comprenant le roulement sain, le roulement avec défauts de la bague extérieure, de la bille et de la bague intérieure. Le nombre 12 représente les caractéristiques extraites pour chaque signal. La structure du modèle RF et son diagramme schématique sont présentés dans la figure V.7.




Figure V.7 : Diagramme schématisé du modèle de Random Forest proposé.

Pour construire le modèle d'apprentissage automatique basée sur la RF, l'ensemble de données de 64 signaux est divisé en un ensemble d'entraînement représentant 80 % des données (51 signaux) et un ensemble de test contenant 20 % des données (13 signaux). Ce choix de ratio est basé sur une analyse empirique de la littérature selon les résultats de [117], où le ratio 80 : 20 est reconnu comme étant plus précis pour l'utilisation de la RF, notamment dans la classification des défauts de roulements [105].

Après avoir réalisé de multiples tests sur le classificateur RF, on constate que sa capacité de classification atteint un taux d'exactitude remarquable de 99,54 %, ce qui semble être optimal pour identifier les défauts du roulement. L'évaluation des performances de classification des défauts peut être quantifiée à travers des mesures telles que l'exactitude, la sensibilité, la spécificité, la précision et la moyenne g, comme expliqué ci-dessous :

Tableau V.1 : Critères d'évaluation du modèle RF.

| Paramètres | Critères d'évaluation | | | | |
|------------|-----------------------|-------------|-------------|-----------|-----------|
| | Exactitude | Sensibilité | Spécificité | Précision | Moyenne-G |
| T= 40 | 98.92% | 97.67 % | 99.30 % | 97.67 % | 95.74 % |
| T=13 | 97.46 % | 98 % | 97.30 % | 95.50 % | 97.63 % |
| T=3 | 99.08 % | 98 % | 99.40 % | 98 % | 98.65% |
| T=11 | 99.54 % | 100 % | 99.40 % | 98.50 % | 99.69 % |

Malgré la limitation de la base de données, la sensibilité montre un taux élevé de 100 %. Cela indique une capacité très élevée à obtenir un résultat positif lorsque le roulement est défectueux. De même, la spécificité tend vers un taux très élevé de 99,40%, en d'autres termes,

cela signifie qu'il est probable d'obtenir un résultat négatif lorsque le roulement est sain. De plus, le classificateur est très précis avec un taux de 98.50 %, indiquant ainsi sa capacité à prédire correctement un vrai résultat positif à partir de tous les cas prédits positifs par le classificateur. Par ailleurs, le taux de moyenne générale est une indication d'une bonne ou d'une mauvaise performance dans la classification des cas positifs, même si les cas négatifs sont correctement classés en tant que tels. Dans le cas présent, la valeur de la moyenne G a un taux élevé de 99,69 %, ce qui indique que les cas positifs sont bien classés. Enfin, la précision ou le taux de cas correctement classés, est évaluée à 99,54 %. Ces résultats de mesure des performances prouvent les capacités et l'efficacité du classificateur.




Figure V.8 : Taux d'exactitude en fonction du nombre d'arbres de RF.

Également, les résultats obtenus par le modèle RF peuvent être influencés par le nombre d'arbres sélectionnés lors de l'entraînement de ce modèle. La figure V.8 montre le taux d'exactitude en fonction du nombre d'arbres. Elle présente également que la valeur optimale du nombre d'arbres de RF est de 11 arbres, permettant d'achever un taux d'exactitude égale à 99.54 %. Cela suggère que l'utilisation de l'apprentissage automatique basé sur la RF améliore l'efficacité de la localisation de défauts des éléments du roulement.

V.5.2. Application de l'algorithme de MLP

L'architecture optimale proposée pour cette étude de cas du perceptron multicouche (MLP) comprend une couche d'entrée avec 65 neurones, une couche cachée contenant 25 neurones, et une couche de sortie composée d'un seul neurone. Le modèle utilise le même ensemble de données que celui utilisé dans la classification des défauts par la RF. La base de données d'entrée/ sortie utilisée contient 64 exemples (signaux). Environ 85 % de ces signaux (54 signaux) sont utilisés pour l'entraînement, tandis que les 15 % restants (10 signaux) sont

réservés pour la phase de test. Le diagramme schématique du modèle MLP proposé est illustré dans la figure V.9.




Figure V.9 : Diagramme schématique du modèle MLP proposé.

Plusieurs essais sont effectués pour optimiser les performances du modèle MLP en ajustant des paramètres spécifiques, tels que la fonction d'activation, le nombre de couches ainsi le nombre de neurones utilisés. Dans notre étude, le modèle MLP est testé dans les cas suivants :

- ✓ Deux modèles sont testés avec une seule couche d'entrée, présentant des variations du nombre de neurone entre 55 et 45 neurones et une couche de sortie contenant un seul neurone.
- ✓ Deux modèles sont testés, comportant une couche d'entrée de 55 ou 65 neurones, une couche cachée de 25 neurones, et une couche de sortie contenant un seul neurone.

La performance de classification des défauts des éléments du roulement peut être évaluée par les critères métriques d'évaluation listés dans le tableau V.2, comme suit :

Tableau V.2 : Critères d'évaluation du modèle MLP.

| Paramètres | | Critères d'évaluation | | | | |
|--|----------------------|-----------------------|-------------|-------------|-----------|-----------|
| | | Exactitude | Sensibilité | Spécificité | Précision | Moyenne-G |
| Couche d'entrée et couche de sortie | (55, 1) neurones | 70 % | 60% | 80% | 75 % | 67.082 % |
| | (45, 1) neurones | 90 % | 100 % | 87.5 % | 66.667% | 81.65 % |
| Couche d'entrée, couche cachée et couche de sortie | (55, 25, 1) neurones | 90 % | 50 % | 100 % | 100 % | 70.711 % |
| | (65, 25, 1) neurones | 100 % | 100 % | 100 % | 100 % | 100 % |

L'ensemble de ces mesures donne un aperçu de l'efficacité de l'algorithme MLP dans la classification des défauts. Pour le premier modèle, comprenant une couche d'entrée de 55 neurones et une couche de sortie d'un seul neurone, le taux d'exactitude (accuracy) est de 70 %, c'est-à-dire que le classificateur n'a pas réussi à classer correctement 3 cas de défauts. Ainsi, le deuxième modèle, doté d'une couche d'entrée de 45 neurones et d'une couche de sortie d'un seul neurone, offre un taux d'exactitude de 90 %, présentant 1 exemple de défaut mal classés. Par ailleurs, la sensibilité démontre un taux exceptionnel de 100 %. Cela signifie une capacité remarquable à détecter avec précision les cas positifs de défauts du roulement.

Un modèle structuré d'une couche d'entrée de 55 neurones, d'une couche cachée aussi de 25 neurones et d'un neurone dans la couche de sortie affiche également un taux d'exactitude de 90 % et de sensibilité de 50 %. De plus, il démontre son efficacité de classer les défauts avec une précision de 100 %, tout en ayant une spécificité de défaut également de 100 %. Le dernier modèle, ayant une structure similaire à celle du précédent mais avec 65 neurones dans la couche d'entrée, atteint un taux impressionnant d'exactitude de 100 %, ce qui indique l'excellence du classificateur à classer tous les cas correctement. De même, la sensibilité présente un taux de 100 %, cela démontre une capacité remarquable à détecter avec précision les cas positifs de défauts du roulement. De plus, la spécificité se rapproche d'un taux de 100 %, indiquant une forte probabilité d'identification correcte des cas négatifs lorsque le roulement est en bon état. Le classificateur affiche également un niveau de précision de 100 %, mettant en évidence sa capacité à prédire les cas positifs avec une grande précision. La moyenne-G est une cruciale pour évaluer les performances du classificateur, en particulier pour évaluer son efficacité dans la classification des cas positifs, indépendamment de l'identification correcte des cas négatifs. Il est remarquable que sa valeur atteigne un taux de 100 %, indiquant une classification précise des cas positifs.

Ces résultats sont clairement mis en évidence par les matrices de confusion, telles qu'illustrées dans les figures V.10 et V.11 suivantes :




Figure V.10 : Matrice de confusion d'une structure de : (a) : (55, 1) neurones. (b) : (45, 1) neurones.

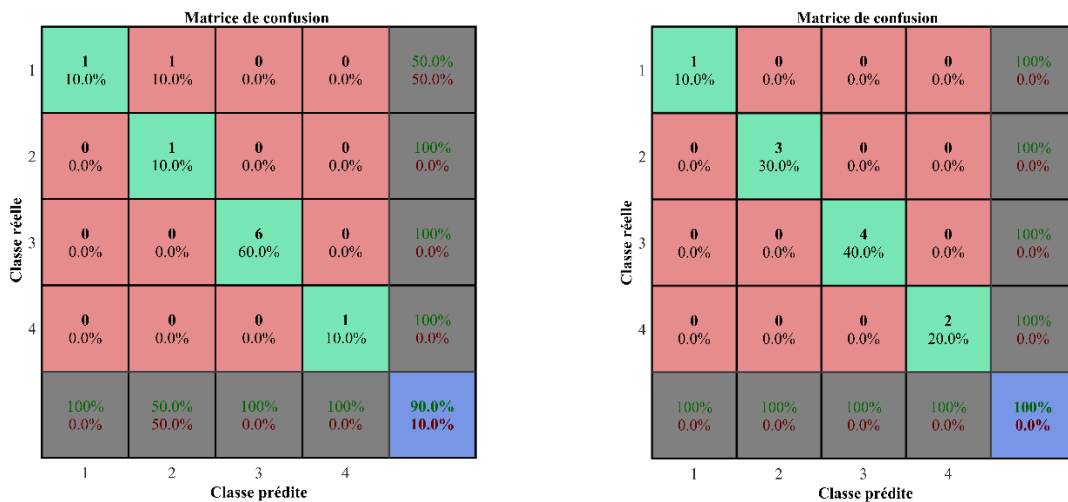


Figure V.11 : Matrice de confusion d'une structure de : (a) : (55, 25, 1) neurones. (b) : (65, 25, 1).

Dans l'évaluation de la matrice de confusion pour les quatre classes obtenues par le classificateur du réseau neuronal MLP, des techniques de l'entraînement et de test rigoureuses ont été appliquées à l'aide des caractéristiques extraites des défauts. Une analyse complète des résultats obtenus, présentés dans les matrices de confusion des figures V.10 (a, b) et V.11 (a, b), montre l'effet du nombre de couches et du nombre de neurones utilisés pour former le modèle MLP.

Prenant l'exemple de la figure V.10 (b), les quatre premières cellules diagonales indiquent le nombre et le pourcentage de classifications correctes par le classifieur MLP

comprenant une couche d'entrée et une couche de sortie de (45, 1) neurones. Par exemple, 2 cas de la classe 1 libellée comme « roulement sain » sont correctement classés. Cela correspond donc à 20 % des 10 cas proposés. De même, 3 cas de la classe 2 sont correctement classés comme défaut de la bague intérieure. Cela correspond à 30 % de l'ensemble des cas. La troisième cellule diagonale comporte 2 cas de la classe 3 correctement classés comme défaut de la bague extérieure, ce qui correspond à 20 % de tous les cas. La quatrième cellule comporte aussi 2 cas de la classe 4 correctement classés comme étant un défaut de la bille, ce qui correspond à 20 % de tous les cas. Quand, 1 cas de la classe 4 (défaut de la bille) est incorrectement classé comme défaut de la bague extérieure, ce qui correspond à 10 % de tous les cas. En résumé, les trois premières classes sont correctement classées, tandis que pour la quatrième classe, sur 3 prédictions de défaut de la bille, 66.7 % sont correctes et 33.3 % sont erronées. Dans l'ensemble, 90 % des prédictions sont correctes et 10 % sont erronées.

En particulier, la matrice de confusion illustrée dans la figure V.11 (b), comprenant une couche d'entrée, une couche cachée et une couche de sortie de (65,25,1) neurones respectivement, révèle une précision de 100 %. Chaque cellule de cette matrice représente une combinaison spécifique d'étiquettes de classes prédites et réelles, indiquant l'absence d'échec de classification dans toutes les classes. Ainsi, les éléments diagonaux indiquent le nombre de vrais positifs pour chaque classe. Dans ce contexte, ces valeurs sont optimisées, mettant en évidence la capacité précise du classificateur à identifier les défauts dans chaque classe. En effet, l'absence d'éléments hors diagonale signifie l'absence d'erreurs de classification, soulignant une capacité du classificateur à assigner avec précision les instances à leurs classes respectives.

Enfin, en analysant les figures V.10 (a, b), on constate que le nombre de neurones affecte l'efficacité de classification de défauts. Un MLP avec une structure de (55,1) neurones présente un taux d'exactitude de 70 %, ainsi qu'un MLP avec une structure de (45,1) neurones atteint un taux d'exactitude de 90 %. Également, un taux d'exactitude impressionnant de 100 % est achevé avec une structure comprenant une couche d'entrée, une couche cachée et une couche de sortie de (65, 25,1) neurones (figure V.11 (b)), tout en montrant l'effet de nombre de couche sur la précision de classification de défauts. Ces performances exceptionnelles soulignent la capacité du réseau neuronal MPL à discerner des modèles et des caractéristiques complexes dans l'ensemble de données, ce qui facilite une classification précise dans toutes les classes.

V.6. Etude comparative entre les deux algorithmes de classification

D'après une analyse pertinente des performances atteintes par l'application du MLP et de RF pour la classification des défauts du roulement, il est observé que les deux classificateurs fournissent des résultats satisfaisants, ce qui revient à leur approche. La RF forme un ensemble d'arbres de décision qui a permis de combiner les prédictions de plusieurs catégories de défauts du roulement existants pour améliorer la précision globale du modèle. La classification par la RF affiche un taux d'exactitude optimal de 99.54 %. Ce résultat est clairement influencé par l'architecture du modèle proposé. Il apparaît ainsi que la sélection de 11 arbres pour l'entraînement des indicateurs des défauts extraits se révèle optimal pour aboutir aux performances visées du classificateur. D'autre part, grâce à une conception d'une architecture idéale du modèle MLP, comprenant une couche d'entrée, une couche cachée et une couche de sortie de (65, 25, 1) neurones, le MLP atteint un taux d'exactitude impressionnant de 100 %. Cela revient à son architecture basée sur un réseau neuronal artificiel qui apprend à travers des données en ajustant les poids de connexion entre les neurones. Dans ce contexte, le MLP semble plus adapté pour la classification des défauts du roulement, présentant une capacité à avoir zéro échec lors de la classification.

En résumé, bien que les deux modèles fournissent des résultats satisfaisants, la précision de classification des différents types de défauts du roulement dépend d'une manière significative à la qualité des caractéristiques extraites lors de la détection de défauts par les techniques d'analyses des signaux vibratoires générés par le roulement.

V.7. Conclusion

Dans ce chapitre, une nouvelle stratégie basée sur un nouvel ensemble de caractéristiques extraites en utilisant une technique de diagnostic automatique combinée entre la TOD-ENV spectrale pour la détection et l'identification des défauts des différents éléments du roulement et les algorithmes de l'apprentissage automatique, à savoir le MLP et la RF.

Dans un premier temps, les signaux vibratoires bruts du roulement, tels que les signaux des roulements sains, des défauts de la bague extérieure, des défauts de la bille et des défauts de la bague intérieure, ont été décomposés par la TOD afin d'obtenir un certain nombre d'approximations et de détails à l'aide de la fonction d'ondelettes de db3. La TOD assure à la fois la décomposition et le débruitage du signal, ce qui nécessite la reconstruction des détails fournis pour éviter toute perte d'information. Ensuite, seuls les détails reconstruits pertinents

ont été sélectionnés sur la base du facteur statistique « kurtosis afin de réduire la dimensionnalité de la structure originale du signal de vibration.

La présence des fréquences des défauts du roulement de la bague extérieure, de la bille et de la bague intérieure a été prouvée par l'application de l'analyse par l'ENV spectrale qui permet d'extraire un nouvel ensemble de caractéristiques de fréquence. Ces caractéristiques ont ensuite été utilisées comme entrées pour l'entraînement du classificateur de la RF, avec une précision de 99,54 %. De même, pour entraîner le classificateur du MLP, affichant une précision de 100 %.

Cela souligne la qualité de la structure des caractéristiques, ainsi que l'efficacité et la robustesse de la stratégie proposée pour la détection et la localisation des défauts du roulement. En outre, ce diagnostic automatique des défauts du roulement contribue à un niveau optimal de maintenance prédictive en assurant une détection précoce des défauts du roulement des machines tournantes.

Conclusion générale

Cette thèse s'inscrit dans le cadre de l'automatisation du diagnostic des défauts de roulements par l'analyse des signaux vibratoires, en appliquant une nouvelle stratégie de détection et de localisation des défauts basée sur la combinaison des techniques avancées de traitement du signal et d'apprentissage automatique. L'idée de base réside sur l'extraction des caractéristiques des défauts via une procédure pertinente de sélection des parties du signal riche en informations nécessaires pour décrire l'état du roulement ainsi que ses différents éléments.

En premier lieu, nous avons discuté des connaissances générales sur la maintenance, le diagnostic et la surveillance grâce à l'analyse des vibrations, en les reliant, puis nous avons présenté les différents types de roulements et leurs diverses applications.

Dans un deuxième lieu, nous avons exposé un état de l'art sur les diverses techniques utilisées dans le domaine du traitement du signal, en particulier pour le diagnostic des défauts de roulements. Nous avons également cité quelques méthodes de l'intelligence artificielle considérées dans la classification et la localisation des défauts.

Par la suite, nous avons développé, à l'aide des études précédentes, un modèle mathématique qui simule et décrit la réponse vibratoire d'un roulement en fonctionnement normal ainsi que dans son état défectueux. Ce modèle prend en considération la fréquence d'échantillonnage, les fréquences de chocs, la position du défaut (bague intérieure, bille, bague extérieure) et l'effet du niveau de bruit. Nous avons également démontré deux propositions : l'effet du diamètre du défaut sur la gravité de l'état du système, ainsi que la sensibilité exceptionnelle du facteur de kurtosis aux défauts de chocs. Cela est validé par une comparaison entre les signaux simulés et les signaux réels.

Deux processus basés sur les techniques de traitement du signal vibratoire ont été proposés pour la détection des défauts de roulement : le premier processus réside sur l'application de la méthode des ondelettes aux signaux simulés ainsi qu'aux signaux réels. Les résultats atteints montrent l'efficacité de cette technique dans l'amélioration de la sensibilité de l'indicateur de kurtosis pour la détection précoce des défauts du roulement. De même, le deuxième processus repose sur la décomposition des signaux vibratoires par la méthode de l'EMD. L'IMF pertinent, qui contient de l'information utile sur le défaut est sélectionné à partir

du calcul des coefficients de corrélation et de kurtosis. Les résultats obtenus montrent que le kurtosis est plus sensible aux défauts de choc et que la méthode des ondelettes atteint avec succès les objectifs visés pour la détection et l'identification des défauts.

L'identification et la détection des caractéristiques des défauts représentent une partie essentielle pour l'automatisation du diagnostic des défauts du roulement par les algorithmes de l'apprentissage automatique. L'efficacité des techniques appliquées est validée par des signaux générés à partir des essais expérimentaux réalisés par le banc d'essai de CWRU (Case Western Reserve University). Une étude comparative est effectuée entre le classificateur de RF et de MLP montre également la pertinence et la robustesse des caractéristiques des défauts extraites à travers la méthodologie suivie.

La principale contribution de ce travail de thèse est de développer une stratégie de diagnostic automatique des défauts du roulement basée sur une nouvelle technique d'extraction des caractéristiques des défauts à partir des techniques avancées du traitement de signal et d'intelligence artificielle. Cette combinaison des techniques été testées et validées par des cas réels représentant les défauts du roulement, comme elle mérite d'être testée sur d'autres cas de défauts, notant les défauts de rotor de bar, les défauts des engrenages, les défauts statoriques du moteur...etc. Les algorithmes de classification de défauts présentent évidemment des opportunités de développements et d'optimisation des techniques comprenant l'aspect de classification en temps réel.

Références bibliographiques

- [1] M. F. Yakhni *et al.*, “Variable speed induction motors’ fault detection based on transient motor current signatures analysis: A review,” *Mech. Syst. Signal Process.*, vol. 184, pp. 1–22, 2023, doi: 10.1016/j.ymssp.2022.109737.
- [2] C. Lessmeier, J. K. Kimotho, D. Zimmer, and W. Sextro, “Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: a benchmark data set for data-driven classification.,” *Third Eur. Conf. Progn. Heal. Manag. Soc. 2016*, no. Cm, pp. 152–156, 2016.
- [3] M. ETIENNE Fournier, “Protocole de Diagnostic des Entraînements Asynchrones par Références : Application à la Détection des Déséquilibres Mécaniques et des Défauts de Courroie,” Thèse de Doctorat, Université de Toulouse, 2015.
- [4] KERROUMI Sanaa, “Extraction des Paramètres et Classification Dynamique Dans le Cadre de la Détection et du Suivi de Défaut de Roulements,” Thèse de Doctorat, Université De Reims Champagne-Ardenne, Octobre, 2016.
- [5] R. A. Rahman, M. F. Erikyatna, and A. F. Hery, “Study on Predictive Maintenance of V-Belt in Milling Machines Using Machine Learning Study on Predictive Maintenance of V-Belt in Milling Machines Using Machine Learning,” vol. 6, no.2, pp.85-94 November, 2022, doi: 10.17977/um016v6i22022p085.
- [6] A. Picot, Z. Obeid, J. Régnier, S. Poignant, O. Darnis, and P. Maussion, “Statistic-based spectral indicator for bearing fault detection in permanent-magnet synchronous machines using the stator current,” *Mech. Syst. Signal Process.*, vol. 46, no. 2, pp. 424–441, 2014, doi: 10.1016/j.ymssp.2014.01.006.
- [7] M. Ye, J. Zhang, and J. Yang, “Bearing Fault Diagnosis under Time-Varying Speed and Load Conditions via Observer-Based Load Torque Analysis,” *Energies*, vol. 15, no. 10, 2022, doi: 10.3390/en15103532.
- [8] A. Allouche *et al.*, “A PLL based mechanical faults detection in PMSM at variable speed,” vol. 51, no. 24, pp. 1445–1451, 2018, doi: 10.1016/j.ifacol.2018.09.534.
- [9] M. A. Jamil and S. Khanam, “Fault Classification of Rolling Element Bearing in Machine Learning Domain,” *Int. J. Acoust. Vib.*, vol. 27, no. 2, pp. 77–90, 2022, doi: 10.20855/ijav.2022.27.21829.
- [10] R. Abdelkader, A. Kaddour, A. Bendiabdellah, and Z. Derouiche, “Rolling Bearing Fault Diagnosis Based on an Improved Denoising Method Using the Complete Ensemble Empirical Mode Decomposition and the Optimized Thresholding Operation,” *IEEE Sens. J.*, vol. 18, no. 17, pp. 7166–7172, 2018, doi: 10.1109/JSEN.2018.2853136.
- [11] Association Française de Normalisation (AFNOR), “Norme X60-010 : Maintenance industrielle,” 1994.
- [12] BEN SALEM Abdeljabbar, “Modèles Probabilistes de Séquences Temporelles et Fusion de Décisions. Application à la Classification de Défauts de Rails et à leur Maintenance,” Thèse de Doctorat, Université de Henri Poincaré, Nancy 1, 2008.

- [13] ABDELKADER Rabah, “Contribution au diagnostic de défauts de roulements par analyse de signaux vibratoires,” Thèse de doctorat, Université des Sciences et de la Technologie d’Oran.
- [14] AYAD Mouloud, “Recherche De Signatures Robustes Des Défauts Dans Une Machine Tournante a Travers L’Analyse De Signaux Vibratoires,” Thèse de doctorat, Université Ferhat Abbas de Sétif, 2015.
- [15] DJEBILI Omar, “Contribution à La Maintenance Prédictive par Analyse Vibratoire des Composants Mécaniques Tournants. Application aux Butées à Billes Soumises à la Fatigue de Contact de Roulement,” Thèse de Docotrat, University de Boumerdes, 2013.
- [16] Association Française de Normalisation (AFNOR), “Norme X60-000 : Niveaux de Maintenance industrielle,” 2016.
- [17] BENNEDJAI Soumaya, “Contribution à l’amélioration de la sûreté d’exploitation des moteurs à induction,” Thèse de Doctorat, University de Annaba, 2016.
- [18] BESSAM Besma, “Analyse et détection des défauts dans la machine asynchrone à base des techniques intelligentes,” Université Mohamed Khider, Biskra, 2016.
- [19] BOUDIAF Adel, “Contribution au Diagnostic des Défauts dans les Machines Tournantes par Analyse Multirésolution,” Thèse de Doctorat, Université de Guelma, 2016.
- [20] MEDOUED Ammar, “Surveillance Et Diagnostic Des Défauts Des Machines Electriques : Applications Aux Moteurs Asynchrones,” Thèse de Doctorat, Université de Skikda, 2012.
- [21] CHAHMI Abdelghani, “Identification Paramétrique de la Machine Asynchrone Dédiée au Diagnostic,” Thèse de Doctorat, Université d’Oran, 2017.
- [22] S. Nandi, H. A. Toliyat, and X. Li, “Condition monitoring and fault diagnosis of electrical motors - A review,” *IEEE Trans. Energy Convers.*, vol. 20, no. 4, pp. 719–729, 2005, doi: 10.1109/TEC.2005.847955.
- [23] AMAROUAYACHE Iskander Imed Eddine, “Surveillance et Diagnostic des Défauts des Machines Tournantes dans le Domaine Temps-Fréquences Utilisant la Décomposition Modale Empirique,” Thèse de Doctorat, University de Annaba, 2021.
- [24] Organisation Internationale de Normalisation (ISO), “Norme ISO 2041: vibration et chocs,” 1990.
- [25] MOREL Jaques, “ *Vibrations des machines et diagnostic de leur état mécanique* ”, Edition Eyrolles. Paris, 1992.
- [26] ZWINGELSTEIN Gilles, *Diagnostic des défaillances : théorie et pratique pour les systèmes industriels. Traité des Nouvelles technologies, série Diagnostic et Maintenance*. Editions de Hermès, Paris, 1995.
- [27] ARQUES Philippe, *Diagnostic prédictif de l’état des machines*. Edition Masson, Paris, 1996.
- [28] LANDOLSI Foued, *Surveillance Des Machines Par Analyse Vibratoire*. 2015.
- [29] P. F. Albrecht, J. C. Appiarius, R. M. McCoy, E. L. Owen, and D. K. Sharma, “Assessment of the reliability of motors in utility applications — updated,” *IEEE Trans. Energy Convers.*, vol. EC-1, no. 1, pp. 39–46, 1986, doi: 10.1109/TEC.1986.4765668.

- [30] O. V. Thorsen and M. Dalva, "Failure identification and analysis for high-voltage induction motors in the petrochemical industry," *IEEE Trans. Ind. Appl.*, vol. 35, no. 4, pp. 810–818, 1999, doi: 10.1109/28.777188.
- [31] A. H. Bonnett and C. Yung, "Increased efficiency versus increased reliability," *IEEE Ind. Appl. Mag.*, vol. 14, no. 1, pp. 29–36, 2008, doi: 10.1109/MIA.2007.909802.
- [32] MACHADO Charles, "Modélisation et Simulation Electromécaniques par la MED des Systèmes Multi-Contacts : Application à la Surveillance des Roulements par une Mesure Electrique," Thèse de Doctorat, Université de Picardie Jules Verne, 2015.
- [33] R. Kostek and B. Zóltowski, "Rolling bearing defect detection and diagnostics," *Vibroengineering Procedia*, vol. 6, pp. 139–144, 2015.
- [34] J. Dron, "Elaboration et Adaptation d'Outils pour l'Etude et le Suivi de l'Endommagement de Composants Mécaniques par Analyse Vibratoire. Application à la Maintenance Conditionnelle des Paliers à Roulement," Thèse de Doctorat, Université de Reims, 1995.
- [35] Y. Zhang, H. Zuo, and F. Bai, "Classification of Fault Location and Performance Degradation of a Roller Bearing," *Meas. J. Int. Meas. Confed.*, vol. 46, no. 3, pp. 1178–1189, 2013, doi: 10.1016/j.measurement.2012.11.025.
- [36] M. S. Safizadeh, "Diagnostic des Machines dans le Plan Temps-Fréquence," Thèse de Doctorat, Ecole Polytechnique de Montréal, 1999.
- [37] P. Stepanic, I. V. Latinovic, and Z. Djurovic, "A New Approach to Detection of Defects in Rolling Element Bearings Based on Statistical Pattern Recognition," *Int. J. Adv. Manuf. Technol.*, vol. 45, no. 1–2, pp. 91–100, 2009, doi: 10.1007/s00170-009-1953-7.
- [38] N. Tandon, "A comparison of some vibration parameters for the condition monitoring of rolling element bearings," *Measurement*, vol. 12, no. 3, pp. 285–289, 1994, doi: 10.1016/0263-2241(94)90033-7.
- [39] P. Gupta and M. K. Pradhan, "Fault detection analysis in rolling element bearing: A review," *Mater. Today Proc.*, vol. 4, no. 2, pp. 2085–2094, 2017, doi: 10.1016/j.matpr.2017.02.054.
- [40] N. Tandon and A. Choudhury, "Review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings," *Tribol. Int.*, vol. 32, no. 8, pp. 469–480, 1999, doi: 10.1016/S0301-679X(99)00077-8.
- [41] Y. Ren, W. Li, B. Zhang, Z. Zhu, and F. Jiang, "Fault diagnosis of rolling bearings based on improved kurtogram in varying speed conditions," *Appl. Sci.*, vol. 9, no. 6, 2019, doi: 10.3390/app9061157.
- [42] B. B. and M. T. SADOK SASSI, "'TALAF' AND 'THIKAT' AS INNOVATIVE TIME DOMAIN INDICATORS FOR TRACKING BALL BEARINGS," *Proc. 24th Semin. Mach. Vib. Can. Mach. Vib. Assoc. éditeur M.*, vol. 2, no. 1, pp. 404–419, 2004.
- [43] S. Priya, M. R. Ramesh, and V. Naidu, "Bearing Health Condition Monitoring: Frequency Domain Analysis Multi-sensor Data Fusion," *Int. J. Adv. Res. Electr. Electron. Instrum. Eng. (An ISO Certif. Organ.)*, vol. 3, no. 5, pp. 260–268, 2014.
- [44] S. R. Qin and Y. M. Zhong, "Research on the unified mathematical model for FT, STFT and WT and its applications," *Mech. Syst. Signal Process.*, vol. 18, no. 6, pp. 1335–1347,

- 2004, doi: 10.1016/j.ymsp.2003.12.002.
- [45] L. M. Rogers, “The Application of Vibration Signature Analysis and Acoustic Emission Source Location to On-Line Condition Monitoring of Anti-Friction Bearings,” *Tribol. Int.*, vol. 12, no. 2, pp. 51–58, 1979, doi: 10.1016/0301-679X(79)90001-X.
- [46] R. B. Randall, “Cepstrum Analysis and Gearbox Fault Diagnosis.,” *Maint. Manag. Int.*, vol. 3, no. 3, pp. 183–208, 1982.
- [47] R. B. Randall, “A history of cepstrum analysis and its application to mechanical problems,” *Mech. Syst. Signal Process.*, vol. 97, pp. 3–19, 2017, doi: 10.1016/j.ymsp.2016.12.026.
- [48] R. H. Lyon and A. Ordubadı, “Use of cepstra in acoustical signal analysis,” *J. Mech. Des. Trans. ASME*, vol. 104, no. 2, pp. 303–306, 1982, doi: 10.1115/1.3256340.
- [49] O. Cousinard, “Contribution à l’étude et au développement d’un système intégré de suivi de l’endommagement des composants mécaniques sur les machines tournantes : Application au développement et au choix des outils d’analyse et de mesure vibratoire,” Thèse de Doctorat, Université de Reims.
- [50] C. BRENEUR, “Eléments de maintenance préventive de machine tournante dans le cas de défauts combinés d’engrenages et de roulements,” Thèse de doctorat, Institut Nationale des Sciences Appliquées de Lyon, 2002.
- [51] R. F. Dwyer, “Detection of Non-Gaussian Signals By Frequency Domain Kurtosis Estimation.,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2, pp. 607–610, 1983, doi: 10.1109/icassp.1983.1172264.
- [52] J. Antoni and L. Ks, “Calcul Rapide du Kurtogramme et Applications Du KS au kurtogramme”.
- [53] J. Antoni and R. B. Randall, “The spectral kurtosis : Application to the vibratory surveillance and diagnostics of rotating machines,” *Mech. Syst. Signal Process.*, vol. 20, no. 2, pp. 308–331, 2006, doi: 10.1016/j.ymsp.2004.09.002.
- [54] M. T. Nabti, “Etude de l’évolution des indicateurs spectraux et cepstraux dans la détection des défauts mécaniques,” Mémoire de Magister, Université Ferhat Abbas-Sétif, 2011.
- [55] Obeid and Ziad, “Mise au point d’algorithmes pour la détection de dégradations deroulements d’actionneurs synchrones à aimants permanents. Application dans le domaine aéronautique sur des ventilateurs embarqués,” Thèse de Doctorat, Université de Toulouse, France, 2012.
- [56] J. Antoni, “Fast computation of the kurtogram for the detection of transient faults,” *Mech. Syst. Signal Process.*, vol. 21, no. 1, pp. 108–124, 2007, doi: 10.1016/j.ymsp.2005.12.002.
- [57] S. K. Mishra, P. Shakya, V. Babureddy, and S. Ajay Vignesh, “An approach to improve high-frequency resonance technique for bearing fault diagnosis,” *Meas. J. Int. Meas. Confed.*, vol. 178, no. November 2020, p. 109318, 2021, doi: 10.1016/j.measurement.2021.109318.
- [58] Y. Xu, K. Zhang, C. Ma, L. Cui, and W. Tian, “Adaptive Kurtogram and its applications in rolling bearing fault diagnosis,” *Mech. Syst. Signal Process.*, vol. 130, pp. 87–107,

- 2019, doi: 10.1016/j.ymsp.2019.05.003.
- [59] Y. Hong, M. Kim, H. Lee, J. J. Park, and D. Lee, “Early Fault Diagnosis and Classification of Ball Bearing Using Enhanced Kurtogram and Gaussian Mixture Model,” *IEEE Trans. Instrum. Meas.*, vol. 68, no. 12, pp. 4746–4755, 2019, doi: 10.1109/TIM.2019.2898050.
- [60] OULMANE Abdelhak, “Surveillance et diagnostic des défauts des machines tournantes dans le domaine temps-fréquences utilisant les réseaux de neurones et la logique floue,” Thèse de Doctorat, Université de Montréal, 2014.
- [61] B. Yazici, G. B. Kliman, W. J. Premerlani, R. A. Koegl, G. B. Robinson, and A. Abdel-Malek, “Adaptive, on-line, statistical method for bearing fault detection using stator current,” *Conf. Rec. - IAS Annu. Meet. (IEEE Ind. Appl. Soc.)*, vol. 1, pp. 213–220, 1997, doi: 10.1109/ias.1997.643030.
- [62] T. P. Banerjee, S. Das, J. Roychoudhury, and A. Abraham, “Implementation of a New Hybrid Methodology for Fault Signal Classification Using Short -Time Fourier Transform and Support Vector Machines,” pp. 219–225, 2010, doi: 10.1007/978-3-642-13161-5_28.
- [63] M. Cocconcelli, R. Zimroz, R. Rubini, and W. Bartelmus, “STFT Based Approach for Ball Bearing Fault Detection in a Varying Speed Motor,” *Cond. Monit. Mach. Non-Stationary Oper.*, pp. 41–50, 2012, doi: 10.1007/978-3-642-28768-8_5.
- [64] M. T. Pham, J. M. Kim, and C. H. Kim, “Accurate bearing fault diagnosis under variable shaft speed using convolutional neural networks and vibration spectrogram,” *Appl. Sci.*, vol. 10, no. 18, 2020, doi: 10.3390/APP10186385.
- [65] R. B. Pachori and P. Sircar, “Time-frequency analysis using time-order representation and Wigner distribution,” *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, 2008, doi: 10.1109/TENCON.2008.4766782.
- [66] J. Luis and F. Chacon, “Fault Detection in Rotating Machinery Using Acoustic Emission,” Thèse de Doctorat, Université de Brunel London, 2015. doi: 10.13140/RG.2.1.2369.5444.
- [67] E. J. Anderson, “Limitations of Short-Time Fourier Transforms in Polyphonic Pitch Recognition,” University of Washington, 1997.
- [68] N. E. Huang *et al.*, “The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis,” *Proc. R. Soc. A Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903–995, 1998, doi: 10.1098/rspa.1998.0193.
- [69] K. Dragomiretskiy and D. Zosso, “Variational mode decomposition,” *IEEE Trans. Signal Process.*, vol. 62, no. 3, pp. 531–544, 2014, doi: 10.1109/TSP.2013.2288675.
- [70] J. Zhu, C. Wang, Z. Hu, F. Kong, and X. Liu, “Adaptive variational mode decomposition based on artificial fish swarm algorithm for fault diagnosis of rolling bearings,” *Proc. Inst. Mech. Eng. Part C J. Mech. Eng. Sci.*, vol. 231, no. 4, pp. 635–654, 2017, doi: 10.1177/0954406215623311.
- [71] C. Li, Y. Liu, and Y. Liao, “An Improved Parameter-Adaptive Variational Mode Decomposition Method and Its Application in Fault Diagnosis of Rolling Bearings,” *Shock Vib.*, vol. 2021, no. Lmd, 2021, doi: 10.1155/2021/2968488.

- [72] C. J. Li and J. Ma, “Wavelet decomposition of vibrations for detection of bearing-localized defects,” *NDT E Int.*, vol. 30, no. 3, pp. 143–149, 1997, doi: 10.1016/s0963-8695(96)00052-7.
- [73] S. Abbasion, A. Rafsanjani, A. Farshidianfar, and N. Irani, “Rolling element bearings multi-fault classification based on the wavelet denoising and support vector machine,” *Mech. Syst. Signal Process.*, vol. 21, no. 7, pp. 2933–2945, 2007, doi: 10.1016/j.ymsp.2007.02.003.
- [74] Zahra KHAWAJA, “Analyse des états de surfaces en science des matériaux : Caractérisation multi-échelles par ondelette et détermination de l’anisotropie des surfaces,” Thèse de Doctorat, Université de Technologie Compiègne, 2014.
- [75] J. S. R. Nkuna, “Vibration Condition Monitoring and Fault Classification of Rolling Element Bearings Utilising Kohonen’s Self-Organising Maps,” Thèse de Doctorat, Université de Vaal de Technologie, Afrique de Sud, 2006.
- [76] B. Smail, “Contribution à la Détection et au Diagnostic des Défauts dans un Système Machine à Induction-Convertisseur,” Thèse de Doctorat, Université de Batna, 2016.
- [77] J. Ben Ali, N. Fnaiech, L. Saidi, B. Chebel-Morello, and F. Fnaiech, “Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals,” *Appl. Acoust.*, vol. 89, pp. 16–27, 2015, doi: 10.1016/j.apacoust.2014.08.016.
- [78] C. Malla, A. Rai, V. Kaul, and I. Panigrahi, “Rolling element bearing fault detection based on the complex Morlet wavelet transform and performance evaluation using artificial neural network and support vector machine,” *Noise Vib. Worldw.*, vol. 50, no. 9–11, pp. 313–327, 2019, doi: 10.1177/0957456519883280.
- [79] S. E. Pandarakone, Y. Mizuno, and H. Nakamura, “A comparative study between machine learning algorithm and artificial intelligence neural network in detecting minor bearing fault of induction motors,” *Energies*, vol. 12, no. 11, 2019, doi: 10.3390/en12112105.
- [80] V. T. Tran, F. Althobiani, and A. Ball, “An approach to fault diagnosis of reciprocating compressor valves using Teager-Kaiser energy operator and deep belief networks,” *Expert Syst. Appl.*, vol. 41, no. 9, pp. 4113–4122, 2014, doi: 10.1016/j.eswa.2013.12.026.
- [81] H. Shao, H. Jiang, F. Wang, and H. Zhao, “An enhancement deep feature fusion method for rotating machinery fault diagnosis,” *Knowledge-Based Syst.*, vol. 119, pp. 200–220, 2017, doi: 10.1016/j.knosys.2016.12.012.
- [82] J. Ma, C. Li, and G. Zhang, “Rolling bearing fault diagnosis based on deep learning and autoencoder information fusion,” *Symmetry (Basel)*, vol. 14, no. 1, 2022, doi: 10.3390/sym14010013.
- [83] J. Guo, X. Liu, S. Li, and Z. Wang, “Bearing Intelligent Fault Diagnosis Based on Wavelet Transform and Convolutional Neural Network,” *Shock Vib.*, vol. 2020, 2020, doi: 10.1155/2020/6380486.
- [84] Aida Rezaei, “Fault detection and diagnosis on the rolling element bearing,” Thèse de Doctorat, Ottawa Ontario, Carleton University, 2007.
- [85] H. HOTAÏT, “Contribution au processus de surveillance intelligente des machines tournantes : cas des roulements à billes,” Thèse de Doctorat, Université de Reims, 2020.

- [86] T. Ishak, “Extraction d’indicateurs robustes pour le diagnostic des défauts mécaniques : Comparaison de L’EMD et des ondelettes (WT)”, Thèse de Mgister, Université de Sétif, 2012.
- [87] A. Ibrahim, “Contribution au diagnostic de machines électromécaniques : Exploitation des signaux électriques et de la vitesse instantanée,” Thèse de Doctorat, Université Jean Monnet, France, 2009.
- [88] Y. T. Sheen, “A complex filter for vibration signal demodulation in bearing defect diagnosis,” *J. Sound Vib.*, vol. 276, no. 1–2, pp. 105–119, 2004, doi: 10.1016/j.jsv.2003.08.007.
- [89] Meunier Vincent, Cousinard Olivier and J. D. Bolaers, “Mise en place d’une procédure de surveillance vibratoire de roulements sur une presse transfert du secteur automobile,” in *19ème Congrès Français de Mécanique*, 2009.
- [90] H. Cao, L. Niu, and Z. He, “Method for vibration response simulation and sensor placement optimization of a machine tool spindle system with a bearing defect,” *Sensors (Switzerland)*, vol. 12, no. 7, pp. 8732–8754, 2012, doi: 10.3390/s120708732.
- [91] Y. T. Sheen, “An envelope analysis based on the resonance modes of the mechanical system for the bearing defect diagnosis,” *Meas. J. Int. Meas. Confed.*, vol. 43, no. 7, pp. 912–934, 2010, doi: 10.1016/j.measurement.2010.03.011.
- [92] Bearing Data Center - Case Western Reserve university, “<http://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-university>.”
- [93] L. A. Conraria and M. J. Soares, “The continuous wavelet transform : a primer,” *NIPE Work. Pap.*, vol. 16, pp. 1–43, 2011.
- [94] Christopher E. HEIL and David F. Walnut, “Continuous And Discrete Wavelet Transforms,” vol. 31, no. 4, pp. 628–666, 1989.
- [95] O. Rioul and P. Duhamel, “Fast Algorithms for Discrete and Continuous Wavelet Transforms,” *IEEE Trans. Inf. Theory*, vol. 38, no. 2, pp. 569–586, 1992, doi: 10.1109/18.119724.
- [96] I. Daubechies, “The wavelet transform, time-frequency localization and signal analysis,” *Fundam. Pap. Wavelet Theory*, no. 5, pp. 442–486, 2009, doi: 10.1515/9781400827268.442.
- [97] A. B. Patil, J. A. Gaikwad, and J. V. Kulkarni, “Bearing fault diagnosis using discrete Wavelet Transform and Artificial Neural Network,” *Proc. 2016 2nd Int. Conf. Appl. Theor. Comput. Commun. Technol. iCATccT 2016*, pp. 399–405, 2017, doi: 10.1109/ICATCCT.2016.7912031.
- [98] G P Nason and B. W. Silverman, “The Discrete Wavelet Transform in S,” vol. 3, no. 2, pp. 163–191, 1994.
- [99] J. Lin and L. Qu, “Feature extraction based on morlet wavelet and its application for mechanical fault diagnosis,” *J. Sound Vib.*, vol. 234, no. 1, pp. 135–148, 2000, doi: 10.1006/jsvi.2000.2864.
- [100] J. Antoine and L. Jacques, “Traitement de l’image : de l’équation de la chaleur aux ondelettes,” pp. 1–20.

- [101] J.F. Rasolomanana and P.A. Randriamitantoa, “Ondelettes de Haar et ses transformées,” vol. 2, no. 2220–0673, 2015.
- [102] C. Vonesch, T. Blu, and M. Unser, “Generalized daubechies wavelet families,” *IEEE Trans. Signal Process.*, vol. 55, no. 9, pp. 4415–4429, 2007, doi: 10.1109/TSP.2007.896255.
- [103] A. Deckmyn and L. Berre, “A wavelet approach to representing background error covariances in a limited-area model,” *Mon. Weather Rev.*, vol. 133, no. 5, pp. 1279–1294, 2005, doi: 10.1175/MWR2929.1.
- [104] MEZIANI Fadia, “Analyse du degré de sévérité pathologique des signaux phono cardiogrammes (PCGs) par application des transformées d’ondelettes,” Thèse de Doctorat, Université de Tlemcen, 2013.
- [105] R. N. Toma and J. M. Kim, “bearing fault classification of induction motors using discrete wavelet transform and ensemble machine learning algorithms,” *Appl. Sci.*, vol. 10, no. 15, 2020, doi: 10.3390/APP10155251.
- [106] J. Ma, J. Wu, X. Wang, Y. Fan, and T. Leng, “A fault detection method of rolling bearing based on wavelet packet-cepstrum,” *Res. J. Appl. Sci. Eng. Technol.*, vol. 5, no. 12, pp. 3402–3406, 2013, doi: 10.19026/rjaset.5.4586.
- [107] A. Djebala, N. Ouelaa, and N. H. S. Guenfoud, “Application de la Transformée en Ondelettes Discrète dans la Détection des Défauts de Roulements”.
- [108] M. Defdaf, F. Berrabah, A. Chebabhi, and B. D. E. Cherif, “A new transform discrete wavelet technique based on artificial neural network for induction motor broken rotor bar faults diagnosis,” *Int. Trans. Electr. Energy Syst.*, vol. 31, no. 4, pp. 1–13, 2021, doi: 10.1002/2050-7038.12807.
- [109] A. DJEBALA, “Application de la Transformée par Ondelettes à l’Etude et l’Analyse Vibratoire des Systèmes Mécaniques,” Thèse de Doctorat, Université Université Badji Mokhtar, Annaba, 2008.
- [110] A. Djebala, N. Ouelaa, and N. Hamzaoui, “Detection of rolling bearing defects using discrete wavelet analysis,” *Meccanica*, vol. 43, no. 3, pp. 339–348, 2008, doi: 10.1007/s11012-007-9098-y.
- [111] M. Zare and N. M. Nouri, “End-effects mitigation in empirical mode decomposition using a new correlation-based expansion model,” *Mech. Syst. Signal Process.*, vol. 194, no. January, p. 110205, 2023, doi: 10.1016/j.ymsp.2023.110205.
- [112] P. C. Chu, C. Fan, and N. Huang, “Derivative-optimized empirical mode decomposition for the Hilbert – Huang transform,” *J. Comput. Appl. Math.*, vol. 259, pp. 57–64, 2014, doi: 10.1016/j.cam.2013.03.046.
- [113] D. Zhang, L. Qian, B. Mao, C. Huang, B. Huang, and Y. Si, “A Data-Driven Design for Fault Detection of Wind Turbines Using Random Forests and XGboost,” *IEEE Access*, vol. 6, no. c, pp. 21020–21031, 2018, doi: 10.1109/ACCESS.2018.2818678.
- [114] P. Ewert, “Application of Neural Networks to Detect Eccentricity of Induction Motors,” vol. 2, no. 2, pp. 18–20, 2017, doi: 10.5277/PED170209.
- [115] Z. Gao, S. Member, C. Cecati, F. Ieee, and S. X. Ding, “Effectiveness Analysis of PMSM Motor Rolling Bearing Fault Detectors Based on Vibration Analysis and Shallow Neural

- Networks,” vol. 62, pp. 3757–3767, 2015.
- [116] R. Costache *et al.*, “Flash-flood susceptibility assessment using multi-criteria decision making and machine learning supported by remote sensing and GIS techniques,” *Remote Sens.*, vol. 12, no. 1, 2020, doi: 10.3390/RS12010106.
- [117] R. Patgiri, H. Katari, R. Kumar, and D. Sharma, *Empirical study on malicious URL detection using machine learning*, vol. 11319 LNCS. Springer International Publishing, 2019. doi: 10.1007/978-3-030-05366-6_31.

Résumé : Dans l'industrie, l'analyse des vibrations est un outil essentiel pour la maintenance préventive conditionnelle. Les signaux vibratoires captés, collectés et analysés peuvent fournir des informations sur l'état d'un moteur à induction. Un traitement approprié de ces signaux vibratoires permet de définir un état normal ou anormal de l'ensemble de la machine tournante, ou en particulier de l'un de ses composants. L'objectif principal de cette thèse est de proposer une méthode de surveillance automatique de l'état des composants du roulement d'un moteur à induction. La méthode proposée est basée sur deux approches, l'une basée sur le traitement du signal en utilisant la transformée en ondelettes discrètes et la décomposition en modes empiriques et l'autre approche utilise l'apprentissage automatique basé sur la random forest (RF) et le perceptron multicouche (MLP). L'enveloppe spectrale de Hilbert permet d'extraire des fréquences caractéristiques qui sont considérées comme de nouvelles signatures entrant dans ces classificateurs. Les fréquences choisies comme signatures sont déterminées à partir d'une variation proportionnelle de leurs amplitudes avec la variation du couple de charge et du diamètre du défaut. En outre, une classification basée sur la RF et le MLP peut valider l'efficacité des caractéristiques de fréquence extraites en tant que nouvelles caractéristiques pour traiter la détection des défauts de roulements tout en localisant automatiquement le composant défectueux avec un taux de classification exceptionnel. Les résultats obtenus avec la méthode proposée ont été validés expérimentalement à l'aide d'un banc d'essai.

Mots clés : Moteur à induction ; roulement ; défaut ; bague intérieure ; bague extérieure ; éléments du roulement ; TOD ; EMD ; MLP ; RF.

Abstract: Vibration analysis for conditional preventive maintenance is an essential tool for the industry. The vibration signals sensed, collected and analyzed can provide information about the state of an induction motor. Appropriate processing of these vibratory signals leads to define a normal or abnormal state of the whole rotating machinery, or in particular, one of its components. The main objective of this thesis is to propose a method for automatic monitoring of bearing components condition of an induction motor. The proposed method is based on two approaches with one based on signal processing using the DWT and EMD and the other approach uses machine learning based on random forests and MLP. The Hilbert spectral envelope allows the extraction of frequency characteristics that are considered as new features entering the classifier. The frequencies chosen as features are determined from a proportional variation of their amplitudes with the variation of the load torque and the fault diameter. Furthermore, a random forest and MLP based classifier can validate the effectiveness of extracted frequency characteristics as novel features to deal with bearing fault detection while automatically locating the faulty component with an exceptional classification rate. The results obtained with the proposed method have been validated experimentally using a test rig.

Key words: Induction motor; bearing; fault; inner race; outer race; rolling elements; DWT; EMD; MLP; RF.

المخلص: يعد تحليل الاهتزاز من اجل الصيانة الوقائية المشروطة أداة أساسية للصناعة. يمكن أن توفر إشارات الاهتزاز التي يتم استشعارها وجمعها وتحليلها معلومات حول حالة المحرك الحثي. وتؤدي المعالجة المناسبة لهذه الإشارات الاهتزازية إلى تحديد الحالة الطبيعية أو غير الطبيعية للدواة الدوارة بأكملها، أو على وجه الخصوص، أحد مكوناتها. الهدف الرئيسي من هذه الأطروحة هو اقتراح طريقة للمراقبة التلقائية لحالة مكونات مدرجة المحرك الحثي. تعتمد الطريقة المقترحة على نهجين أحدهما يعتمد على معالجة الإشارات باستخدام تحليل الموجات المتعددة (TOD) والتحليل إلى أنماط تجريبية (EMD) والنهج الآخر يستخدم التعلم الآلي القائم على الغابات العشوائية والمدرک متعدد الطبقات (MLP) ويسمح غلاف هيلبرت الطيفي باستخراج خصائص التردد التي تُعتبر ميزات جديدة تدخل في المصنف. يتم تحديد الترددات المختارة كسمات من التباين التناسبي لسعاتها مع تباين عزم الحمل وقطر العطل. علاوة على ذلك، يمكن للمصنف القائم على الغابة العشوائية و MLP التحقق من فعالية خصائص التردد المستخرجة كسمات جديدة للتعامل مع اكتشاف العطل في المحمل مع تحديد موقع المكون المعيب تلقائيًا بمعدل تصنيف استثنائي. تم التحقق من صحة النتائج التي تم الحصول عليها بالطريقة المقترحة تجريبياً باستخدام جهاز اختبار.

الكلمات المفتاحية: المحرك الحثي؛ المحمل؛ العطل؛ الحلقة الداخلية؛ الحلقة الخارجية؛ مكونات المحمل؛ تحليل الموجات المتعددة؛ التحليل إلى أنماط تجريبية؛ المدرک متعدد الطبقات؛ الغابات العشوائية.