

وزارة التعليم العالي والبحث العلمي

BADJI MOKHTAR – ANNABA UNIVERSITY

UNIVERSITE BADJI MOKHTAR – ANNABA



جامعة باجي مختار - عنابة

Faculté des Sciences de l'Ingéniorat

Année : 2020

Département de Génie Mécanique

THESE

Présenté en vue de l'obtention du diplôme de DOCTORAT 3^{ème} CYCLE

Intitulé

Contribution au diagnostic de défauts dans un système électro énergétique

Spécialité: Mécanique avancée

Option: Commande et diagnostic des systèmes

Par

Abdelraouf Youcef Khodja

DIRECTEUR DE THESE : Pr GUERCI Nouredine

CO-DIRECTEUR DE THESE: Dr SAADI Mohamed

Devant le jury

Président :	Pr.	BOUSSAID Ouzine	Pr U-Annaba
Rapporteur :	Pr.	GUERCI Nouredine	Pr U-Annaba
Co-rapporteur :	Dr.	SAADI Mohamed Nacer	MCB U-Annaba
Examineur :	Pr.	LACHOURI Abderezak	Pr Université de Skikda
Examineur :	Dr.	ATTOUI Issam	MRA URMA/CRTI

Résumé

Contribution au diagnostic de défauts dans un système électro énergétique.

De nos jours, les installations industrielles deviennent de plus en plus complexes, et avec l'augmentation de cette complexité la recherche de nouvelles méthodes performantes et innovantes de surveillance et de diagnostic de défauts pour la protection de ces installations est de plus en plus extensive.

Dans ce contexte, l'objectif de ce travail est de développer une nouvelle approche de diagnostic de défauts de roulements dans les systèmes électro-énergétiques, qui soit bien appropriée et qui présenterait une robustesse et une bonne efficacité de détection.

La nouvelle méthode de classification des défauts que nous présentons est basée sur les réseaux neuronaux convolutifs (CNN) ayant comme entrée l'imagerie des spectres vibratoires (VSI). Dans cette méthode les amplitudes normalisées du contenu spectral extrait des signaux vibratoires temporels en utilisant une fenêtre glissante sont transformés en images spectrales pour l'apprentissage et le test du Classifieur CNN. Des données expérimentales relevées de plusieurs campagnes d'essais sous forme de signaux vibratoires de roulements sont utilisées pour étudier et montrer l'efficacité de la méthode proposée comparativement à d'autres techniques intelligentes de classification existantes.

Mots-clés : Systèmes électro-énergétiques ; diagnostic de défauts ; Réseaux de neurones convolutifs (CNN) ; analyse vibratoire ; Imagerie du spectre de vibration (VSI).

Abstract

Contribution to fault diagnosis in an electro energetic system.

A nowadays industrial installation is becoming more and more complex, and with the increase of this complexity the search for new efficient and innovative methods of monitoring and diagnosis of faults for the protection of these installations is more and more extensive.

In this context, the objective of this work is to develop a new approach for detection and diagnosis of bearing faults in electro-energy systems, which is well suited and which would exhibit robustness and good detection efficiency.

The new faults classification method that we present is based on convolutional neural networks (CNN) having as input vibrational spectral imagery (VSI). In this method, the normalized amplitudes of the spectral content extracted from the temporal vibrational signals using a sliding window are transformed into spectral images for learning and testing the CNN classifier. Experimental data from several test campaigns in the form of bearing vibration signals are used to study and demonstrate the effectiveness of the proposed method compared to other existing intelligent classification techniques.

Keywords: Electro-energy systems; fault diagnosis; Convolutional neural networks (CNN); vibration analysis; Vibration spectrum imaging (VSI).

ملخص

المساهمة في تشخيص الأعطال في نظام الطاقة الكهربائية

في الوقت الحاضر أصبحت المنشآت الصناعية أكثر تعقيداً، ومع زيادة هذا التعقيد، أصبح البحث عن طرق جديدة فعالة ومبتكرة لرصد وتشخيص الأعطال لحماية هذه المنشآت أكثر اتساعاً

في هذا السياق، الهدف من هذا العمل هو تطوير نهج جديد لتشخيص العيوب الحاملة في أنظمة الطاقة الكهربائية، وهو مناسب تماماً ويظهر قوة وكفاءة كشف جيدة

تعتمد طريقة تصنيف العيوب الجديدة التي نقدمها على الشبكات العصبية التلافيفية التي تحتوي على صور طيفية اهتزازية للدخل (VSI).

في هذه الرسالة تم تطبيق البيانات التجريبية من العديد من قواعد الاختبار في شكل إشارات اهتزازية للمدحرجات من أجل تطبيق النهج المقترح. أعطت أداء تصنيف العيوب في هذه التجارب باستخدام هذا النهج نتائج أفضل مقارنة بالطرق المعيارية الأخرى مثل جهاز ناقل الدعم والشبكة العصبية الاصطناعية ونظام الاستدلال الضبابي التكميلي.

الكلمات المفتاحية أنظمة الطاقة الكهربائية، تشخيص الأعطال، الشبكة العصبية التلافيفية، تحليل الاهتزاز، تصوير طيف الاهتزاز.

Dédicaces

À mes parents et mes frères,

À ma femme et mes enfants

À tout ma famille,

À tous mes amis,

Remerciements

En premier lieu, je remercie Dieu le Tout Puissant de m'avoir donné la volonté, la santé et le courage pour réaliser ce travail.

Je tiens à remercier mon encadrant Professeur Nouredine GUERCI de l'université Badji Mokhtar Annaba, et mon co-encadrant Docteur Mohamed Nacer SAADI de l'université Badji Mokhtar Annaba, qui ont en commun conduit mes recherches et m'ont accompagné tout au long de ces années de recherche, de façon subtile. Merci pour votre soutien sans faille, votre confiance et votre disponibilité.

Je remercie particulièrement Professeur Ouzzine BOUSSAID du laboratoire de recherche en risques, contrôle et sûreté du département de génie mécanique de l'université Badji Mokhtar Annaba pour ses précieux conseils, et je tiens à remercier très vivement de son enthousiasme envers mon travail.

Je suis très honoré que Monsieur Ouzzine BOUSSAID, Professeur à l'université de Annaba, ait accepté de présider le jury de cette thèse. Je remercie également Messieurs Slimane BOURAS, Professeur à l'université de Annaba, Abderezak LAACHOURI, Professeur à l'université de Skikda et Issam ATTOUI, Maître de recherche à l'URMA/CRTI, d'avoir accepté de participer à ce jury.

Je remercie vivement Monsieur Nadir BOUTASSETA, Attaché de recherche à l'URMA/CRTI qui m'a aidé à la préparation de cette thèse.

Je remercie également Monsieur Adel DJELLAL Docteur à l'Ecole supérieure des technologies industrielles – Annaba pour ses recommandations bien ciblées.

Un remerciement assez spécial à tout le personnel de l'URASM, en particulier :Nadir Fergani, Issam Atoui ...

Enfin, je remercie toutes les personnes qui mon aidé de près ou de loin.

Acronymes & Abréviations

IA	Intelligence artificielle
STFT	Transformée de Fourier à court terme
CWT	Transformée en ondelettes continue
DWT	Transformée en ondelettes discrète
RELU	Unité linéaire rectifiée
FFT	Transformation de Fourier rapide
DFT	Transformation de Fourier discrète
RBF	Fonction de base radiale
EDM	Usinage par décharge électrique
ANN	Réseau neuronal artificiel
SVM	Machine à vecteur de support
ANFIS	Système neuro-flou adaptatif
KNN	Méthode des k plus proches voisins
RMS	Moyenne quadratique
CNN	Réseau de neurone convolutionnel
SNR	Rapport signal sur bruit
VSI	Imagerie du spectre vibratoire
BP	rétro propagation

Table des matières

Résumé	ii
Abstract	iii
ملخص	iv
Dédicaces	v
Remerciements	vi
Acronymes & Abréviations.....	vii
Table des matières	viii
Liste des Figures.....	xi
Liste des Tableaux.....	xiii
Introduction	2
Chapitre I. Systèmes électro-énergétiques : Défaillances et méthodes de diagnostic	6
I.1. Introduction	6
I.2. Systèmes électro-énergétiques.....	6
I.3. Technique de la surveillance des Systèmes électro-énergétiques	6
I.3.1. La thermographie infrarouge.....	7
I.3.2. L'analyse des huiles	7
I.3.3. L'analyse vibratoire	7
I.3.4. L'analyse par Ultrasons.....	7
I.3.5. Choix d'outils de surveillance.....	7
I.4. Activités de l'analyse vibratoire	8
I.4.1. La surveillance	8
I.4.2. La détection	9
I.4.3. Le diagnostic	9
I.5. Les outils du diagnostic et de la surveillance par l'analyse vibratoire	9
I.5.1. Les indicateurs scalaires.....	10
I.5.2. Les indicateurs spectraux	11
I.5.3. Le Cepstre	13
I.5.4. Analyse d'enveloppe	14
I.5.5. Analyse par ondelettes	14
I.6. Défaillances des Systèmes électro-énergétiques	16
I.6.1. Engrenage.....	16

I.6.2.	Roulement	16
I.6.3.	Arbres	17
I.7.	Chaîne de mesure.....	17
I.7.1.	Accéléromètres.....	20
I.7.2.	Capteur de vitesse.....	21
I.7.3.	Capteur de déplacement	21
I.8.	Etat de l'art	22
I.9.	Conclusion	24
Chapitre II.	Diagnostic de défaut basé sur les méthodes de l'intelligence artificielle	26
II.1.	Introduction :	26
II.2.	Méthodes de diagnostic des défauts basées sur l'intelligence artificielle	26
II.2.1.	Diagnostic de défaut basé sur le SVM (machines à vecteurs de support).....	28
II.2.2.	ANFIS	32
II.2.3.	Réseau neuronal artificiel (ANN)	34
II.3.	Etat de l'art	35
II.3.1.	SVM dans le diagnostic de panne :	35
II.3.2.	ANN dans le diagnostic de panne :	36
II.3.3.	ANFIS dans le diagnostic de panne :	36
II.4.	Conclusion	36
Chapitre III.	Diagnostic de défaut basé sur les Réseaux neuronaux convolutifs	39
III.1.	Introduction.....	39
III.2.	Intérêts de l'utilisation des réseaux neuronaux convolutifs.....	39
III.3.	Réseau neuronal convolutif (CNN)	40
III.4.	L'approche proposée	42
III.4.1.	Segmentation temporelle	42
III.4.2.	Image spectrale	43
III.5.	Classification de défauts basés sur CNN avec le signal temporelle	44
III.5.1.	Segmentation temporelle	45
III.5.2.	Construction de l'image vibratoire.....	45
III.6.	Etat de l'art.....	45
III.7.	Conclusion	47
Chapitre IV.	Applications des approches intelligentes au diagnostic des défauts de roulements	50

IV.1.	Introduction.....	50
IV.2.	Défauts de roulement	50
IV.3.	Première partie : Classification des données relevées sur le banc d'essai URMA / CRTI	52
IV.4.	Diagnostic de défauts par les techniques de l'intelligence artificielle.....	55
IV.4.1.	Classification de défauts de roulement en utilisant l'ANN :.....	56
IV.4.2.	Classification de défauts de roulement en utilisant l'SVM :.....	58
IV.4.3.	Classification de défauts de roulement en utilisant L'ANFIS :.....	59
IV.4.4.	Effet de la vitesse :.....	60
IV.4.5.	Effets de la taille du segment :.....	61
IV.4.6.	Effet de la nature et nombre des entrées :.....	61
IV.5.	CNN avec signal temporelle :.....	62
IV.6.	Méthode proposée.....	65
IV.6.1.	Apprentissage du modèle CNN.....	68
IV.6.2.	Test à vitesse unique.....	68
IV.6.3.	Test à plusieurs vitesses.....	71
IV.6.4.	Etude de robustesse	71
IV.7.	Étude de cas 2 : banc d'essai CWRU	73
IV.7.1.	Configuration expérimentale et description des données	73
IV.7.2.	Évaluation en condition de charge unique :.....	75
IV.7.3.	Évaluation sous différentes conditions de charges:.....	76
IV.7.4.	Évaluation dans des conditions de bruit	77
IV.8.	Conclusion	78
	Conclusion	81
	Références bibliographiques	83
Annexe A.	Les caractéristiques des roulements DATA BEARING CENTER.....	89
	Les fréquences caractéristiques des défauts du roulement coté entraînement	91
Annexe B.	Publications et Communications	92
	Articles de revue.....	92
	Article de conférence	92

Liste des Figures

Figure I-1: Différentes techniques de la surveillance des systèmes électro-énergétiques.	6
Figure I-2. Schéma présentatif des activités de l'analyse vibratoire.	9
Figure I-3. (a) Signal composé de (03) sinusoïdes : 50 Hz, 100 Hz et 150 Hz, (b) son spectre par FFT.	12
Figure I-4. Propriétés de dilatation et translation des ondelettes.	15
Figure I-5. Exemple d'une chaîne de mesure munie d'un accéléromètre [Boulenger 07].	19
Figure I-6. Construction interne d'un accéléromètre piézoélectrique [Agnes 05].	20
Figure I-7. Construction interne d'un capteur de vitesse électromagnétique. [Pachaud 97]. ...	21
Figure I-8. Principe du capteur de déplacement. [Agnes 05].	22
Figure II-1. Organigramme de diagnostic de défauts basé sur l'intelligence artificielle	27
Figure II-2. Illustration d'un modèle de machine à vecteur de support de 2 classes	28
Figure II-3. Illustration du modèle de machine à vecteur de support avec noyau.	30
Figure II-4. Organigramme de diagnostic utilisant les SVMs.	32
Figure II-5. Structure de l'ANFIS [Alavandar 08].	34
Figure II-6. Neurone humain et MLP avec deux couches cachées[Ruonan 18].	34
Figure III-1. Architecture du réseau neuronal convolutif (CNN).	40
Figure III-2. Structure du réseau neuronal convolutif utilisé dans ce travail.	41
Figure III-3. Organigramme de l'algorithme de classification proposé.	42
Figure III-4. Spectres et images FFT correspondantes des signaux de vibration après conversion sous la vitesse 30 Hz	44
Figure III-5. Organigramme de l'algorithme de classification.	45
Figure IV-1. Les diamètres PD, BD, et l'angle de contact d'un élément roulant.	51
Figure IV-2. Les signaux vibratoires de défauts de roulement et les spectres correspondants	52
Figure IV-3. Configuration expérimentale d'acquisition de données.	53
Figure IV-4. Banc d'essai expérimental utilisé dans ce travail.	53
Figure IV-5. Roulements défectueux utilisés dans ce travail	54
Figure IV-6. Signaux de vibration temporelle des roulements sains et défectueux sous différentes vitesses de fonctionnement.	55
Figure IV-7. Données de vibration temporelle à 45 Hz:	55
Figure IV-8. les tracés des indicateurs extraits des signaux de vibration pour les cinq classes de défauts (pour la vitesse 45hz avec une taille du segment n=1500 échantillons).	56
Figure IV-9. Les paramètres du réseau de neurone utilisé dans cette étude a la vitesse 45Hz.	57

Figure IV-10. Le résultat de classification par ANN pour la vitesse 45Hz. 58

Figure IV-11. Résultat du Classifieur SVM pour la vitesse 45Hz. 59

Figure IV-12. Performance d'apprentissage du Classifieur ANFIS. 60

Figure IV-13. Données des signaux de vibration temporelle 62

Figure IV-14. Les images de vibration pour différentes conditions 63

Figure IV-15. Résultats de classification de l'ensemble de données de test pour la vitesse 45Hz. 64

Figure IV-16. Matrice de confusion des résultats obtenus du Classifieur CNN avec signal temporelle pour la vitesse 45Hz. 65

Figure IV-17. Spectres de différentes conditions de fonctionnement à différentes vitesses.... 67

Figure IV-18. Spectrogrammes des données de vibration brutes pour différentes conditions de fonctionnement à différentes vitesses. 67

Figure IV-19. Images spectrales pour différentes conditions de fonctionnement à différentes vitesses 67

Figure IV-20. Structure du réseau neuronal convolutif utilisé dans notre travail. 68

Figure IV-21. Résultats de la classification de l'ensemble de données d'essai pour différentes vitesses. 69

Figure IV-22. Matrices de confusion pour différentes vitesses de fonctionnement..... 70

Figure IV-23. Résultats de la méthode de classification proposée pour le test à plusieurs vitesses. 71

Figure IV-24. Matrice de confusion pour test à plusieurs vitesses. 71

Figure IV-25. Résultats de la méthode de classification proposée pour le test de la variation de vitesse. 72

Figure IV-26. Matrice de confusion de la méthode de classification proposée pour le test de la variation de vitesse. 72

Figure IV-27. Courbe de précision par rapport au taux de bruit ajouté. 73

Figure IV-28. Matrice de confusion à la vitesse de 45 Hz avec -4 dB de bruit ajouté. 73

Figure IV-29. Configuration expérimentale de l'ensemble de données CWRU. 74

Figure IV-30. Résultats de la classification de l'algorithme proposé pour différentes charges. 76

Figure IV-31. Résultats de la classification de l'ensemble de l'algorithme proposé pour toutes les conditions de chargement 77

Figure IV-32. Résultats de la classification de l'algorithme proposé avec un bruit ajouté de -10 dB. 78

Liste des Tableaux

Tableau I-1 : Choix de l’outil de surveillance [Moubray 00, Lyons 04].....	8
Tableau I-2. Fréquences caractéristiques des principales défaillances affectant les machines tournantes [Khelf 14]	12
Tableau IV-1. Spécifications techniques des roulements.....	54
Tableau IV-2. Description des conditions de fonctionnement des roulements sains et défectueux.	54
Tableau IV-3. Résultats de précision pour chaque vitesse de fonctionnement du Classifieur ANN	58
Tableau IV-4. Résultats de précision pour chaque vitesse de fonctionnement du Classifieur SVM.	58
Tableau IV-5. Résultats de précision pour chaque vitesse de fonctionnement du Classifieur ANFIS.	60
Tableau IV-6. Précision de classification des trois Classifieurs selon la taille des segments n=1500, 1000,500 échantillons pour la vitesse 45hz.	61
Tableau IV-7. Précision de classification des trois Classifieurs selon le nombre et la nature des indicateurs avec la taille des segments n=1500 échantillons pour la vitesse 45hz.	61
Tableau IV-8. Description des ensembles de données pour l’apprentissage et le test des classes sain et défectuantes.	62
Tableau IV-9. L'architecture du réseau CNN conçu et paramètres d'apprentissage utilisés dans cette partie.	64
Tableau IV-10. Structure du réseau neuronal convolutionnel et paramètres d'apprentissage utilisés dans cette partie.....	64
Tableau IV-11. Description des ensembles de données d’apprentissage et test des roulements sain et défectueux.	66
Tableau IV-12. Résultats de précision pour chaque vitesse de fonctionnement.....	69
Tableau IV-13. Variations de la précision par rapport au taux de bruit ajouté.	72
Tableau IV-14. conditions du relèvement dans l'ensemble de données	74
Tableau IV-15. Ensemble de données des images vibratoires.	74
Tableau IV-16. Structure du réseau neuronal convolutionnel et paramètres d'apprentissage utilisés dans cette section.	75
Tableau IV-17. Résultats de précision pour chaque condition de charge.	76
Tableau IV-18. Comparaison de classification du VSI-CNN proposé avec celui de [Xia 18]	76

Tableau IV-19. Comparaison de la méthode de classification VSI-CNN à SNR = -10db avec celle de [Amar15]	78
Tableau A-1. Les défauts unique du coté accouplement (12kHz).	89
Tableau A-2. Les défauts uniques de côté accouplement (48kHz).	89
Tableau A-3. Caractéristiques des défauts des roulements.	90
Tableau A-4. Caractéristique du roulement coté entraînement.	90
Tableau A-5. Caractéristique du roulement coté ventilateur.....	90
Tableau A-6. Fréquences caractéristiques d'un défaut de bague intérieure.	91
Tableau A-7. Fréquences caractéristiques d'un défaut de bague extérieure.	91
Tableau A-8. Fréquences caractéristiques d'un défaut de bille.....	91
Tableau A-9. Fréquences caractéristiques d'un défaut de cage.	91

Introduction

Introduction

Les systèmes électro-énergétiques comme les ventilateurs industriels, pompes centrifuges, moteurs électriques, réducteurs de vitesse et les machines tournantes, sont inhérents comme étant une partie importante des installations industrielles.

Le diagnostic des défauts des systèmes électro-énergétiques est crucial pour la réduction des coûts de maintenance. Un diagnostic de défaut incorrect peut entraîner une défaillance grave du système et des pertes financières supplémentaires et conduire à la baisse technico-économique de l'entreprise.

Le diagnostic et la surveillance de ces machines sont basés sur l'analyse des signaux des grandeurs physiques (vibrations, bruits, vitesses, etc.) issues des capteurs implantés sur la machine à surveiller.

Il existe plusieurs techniques pour surveiller l'état des systèmes électro-énergétique. On peut citer, par exemple, l'analyse vibratoire, l'analyse d'huile, l'analyse thermique, etc.

L'utilisation des méthodes de diagnostic des pannes basées sur l'analyse de signaux vibratoires a prouvé son efficacité pour plusieurs dysfonctionnements mécaniques, son principe est basé sur la traduction des efforts que subit la machine par des signaux vibratoires.

En plaçant des accéléromètres aux endroits où se transmettent ces efforts, on peut détecter l'apparition des défauts dans l'équipement. Ces signaux contiennent des informations de diagnostic utiles qui sont extraites par le calcul d'indicateurs qui sont ensuite sélectionnés en fonction de leur sensibilité aux défauts considérés et sont fournis comme entrées dans un système de classification.

Afin d'assurer un diagnostic automatique de défauts des systèmes électro-énergétiques, les méthodes de classification intelligentes telles que les réseaux de neurones artificiels (ANN) et les machines à vecteurs de support (SVM), et les systèmes neuro-flou adaptatif (ANFIS) se sont avérées très efficaces. Cependant, ces méthodes présentent certains inconvénients :

- La performance de la procédure de diagnostic de la plupart de ces méthodes dépend fortement de la qualité des indicateurs sélectionnés. De plus, les défauts non stationnaires comme les défauts de roulement ou engrenage présentent souvent non seulement un défaut unique mais également des défauts combinés. Ainsi, des techniques avancées de traitement du signal doivent être mises en œuvre pour une reconnaissance ou une classification efficace des défauts.
- Dans la plupart des cas, la sélection des indicateurs dépend largement de l'expérience technique des experts en diagnostic.
- Les Classifieurs ANN, SVM et ANFIS appartiennent à des modèles d'apprentissage de haut niveau, ce qui rend les relations complexes non linéaires difficiles à apprendre.
- Le signal vibratoire brut est ignoré après la phase de calcul des indicateurs alors qu'il a masqué des informations immergées.

Par conséquent, il s'avère nécessaire de construire des architectures profondes pour effectuer un diagnostic de panne intelligent et efficace.

L'Apprentissage profond (Deep Learning) est une méthode d'apprentissage automatique récente qui a la capacité d'apprendre à partir de données brutes. Les modèles d'apprentissage profond ont la capacité d'éliminer la dépendance à l'égard des connaissances antérieures des techniques avancées de traitement du signal pour le calcul et la sélection des indicateurs. Les techniques de l'intelligence artificielles se présentent aujourd'hui comme une solution, permettant de résoudre un grand nombre de ces problèmes.

Récemment, différents modèles d'apprentissage en profondeur ont été progressivement appliqués au diagnostic intelligent des défauts.

Le réseau neuronal convolutif (CNN) est un réseau neuronal structuré en profondeur qui est principalement utilisé dans les applications de traitement d'image. Comme d'autres structures de réseaux de neurones, le CNN est construit en utilisant un certain nombre de neurones, qui sont organisés en tant que reflet de différents chevauchements à travers le champ.

Le diagnostic de défauts utilisant CNN est basé sur la normalisation du signal vibratoire brut et sa conversion en image 2D, l'apprentissage du réseau est supervisé et il est réalisé par l'introduction des images en entrée avec les classes souhaitées correspondantes. Cette méthode ne nécessite pas l'extraction des indicateurs ni le processus de sélection et donne une bonne précision dans la classification de défauts.

Dans ce travail de thèse, diverses méthodes de classification intelligentes, ont été explorées et expérimentées, sur des données issues de plusieurs campagnes d'essais.

Les travaux menés dans cette thèse ont été scindés en quatre chapitres.

Le premier chapitre, introductif, présente les systèmes électro-énergétiques, les techniques de la surveillance des systèmes électro-énergétiques, les différentes défaillances pouvant altérer leur fonctionnement, les méthodes de traitement de signal appliquées pour la surveillance et le diagnostic des défauts des systèmes électro-énergétiques. A la fin de ce chapitre, une synthèse bibliographique est présentée sur l'application de quelques outils dans le domaine de la détection des défauts de ce genre de systèmes.

Nous étudions au chapitre 2, la procédure de diagnostic des défauts basée sur les méthodes de l'intelligence artificielle. Le diagnostic à base de ces méthodes nécessite le passage par plusieurs étapes. La première étape dans ces procédures est l'extraction de l'information complète à partir des signaux acquis sur les machines. Cette information nécessite un traitement afin de la rendre exploitable par les techniques de classification et d'intelligence artificielle, l'étape suivante est la phase de décision. Ceci peut être effectué par le biais de nombreuses techniques, notamment les ANN, les Classifieurs SVM, et l'ANFIS, et à la fin de ce chapitre on présentera une revue des travaux de recherches exploitant les différentes méthodes et techniques abordées, démontrant l'intérêt d'appliquer ces techniques de l'intelligence artificielle, et de les coupler avec les connaissances acquises en traitement du signal, pour la réalisation d'outils puissants et fiables de diagnostic des défauts.

Dans le chapitre 3, nous présentons, dans une première étape, les inconvénients des Classifieurs basés sur l'intelligence artificielle, et l'intérêt de l'utilisation des Réseaux Neuronals Convolutifs (CNN) dans le processus de classification des défauts. Dans la seconde étape, une nouvelle méthode de classification de défauts basés sur le réseau neuronal convolutif (CNN) et l'imagerie du spectre vibratoire (VSI) est proposée. Cette méthode, basée sur la normalisation des amplitudes du contenu spectral extrait des signaux vibratoires temporels en utilisant une fenêtre glissante. Les spectres normalisés sont convertis en images puis appliqués à l'entrée du le CNN pour l'apprentissage et le test du Classifieur. A la fin de ce chapitre, une étude bibliographique utilisant les méthodes de classification basées sur le réseau de neurone convolutionnel est présentée.

Finalement, dans le chapitre 4, nous appliquons la méthode proposée auparavant dans le chapitre3, sur des données expérimentales prélevées sous forme de signaux vibratoires de roulements sur le banc d'essai du laboratoire URMA/CRTI, ainsi que sur les données fournies par la banque de données « **Case Western Reserve University** » (CWRU) sous forme de signaux vibratoires de roulements. En fin de ce chapitre, on appliquera, à titre comparatif, les différentes techniques de classification intelligentes présentées au chapitre 2 et en particulier celle basée sur le Classifieur CNN.

Chapitre I. Système Electro- énergétique : Défaillances et Méthodes de Diagnostic

Chapitre I. Systèmes électro-énergétiques : Défaillances et méthodes de diagnostic

I.1. Introduction

Ce chapitre expose une présentation sur les systèmes électro-énergétiques, les techniques de la surveillance des systèmes électro-énergétiques, les différentes défaillances pouvant provoquer leur fonctionnement, les méthodes de traitement de signal appliquées pour la surveillance et le diagnostic des défauts des systèmes électro-énergétiques. Une synthèse bibliographique sur l'application de quelque outil dans le domaine de la détection des défauts des systèmes électro-énergétiques sera brièvement présentée.

I.2. Systèmes électro-énergétiques

On appelle un système électro-énergétique un ensemble d'équipement d'installations électriques destinées à produire, transporter et à la fois distribuer l'énergie électrique aux consommateurs.

Les ventilateurs industriels, pompes centrifuges, moteurs électriques, réducteurs de vitesse, et les machines tournantes font partie intégrante des systèmes électro-énergétique.

I.3. Technique de la surveillance des Systèmes électro-énergétiques

Récemment, il existe plusieurs techniques pour surveiller l'état des systèmes électro-énergétique par exemple l'analyse vibratoire, analyse d'huile, analyse thermique, etc. [Bensana 08, Rahmoune 11].

Les différentes techniques de la surveillance sont illustrées sur la Figure I-1




Figure I-1: Différentes techniques de la surveillance des systèmes électro-énergétiques.

1.3.1.La thermographie infrarouge

La méthode thermographie permet de détecter rapidement les défauts d'échauffement anormal sur la surface de l'équipement. Cette méthode permet de faire des mesures à distance pour obtenir des images thermiques sur les zones inspectées.

1.3.2.L'analyse des huiles

Cette méthode est basée sur l'analyse d'un échantillon du lubrifiant (huile ou graisse) afin de détecter l'état de l'équipement et permet de déterminer l'usure anormale de l'un des composants de la machine, le mauvais état d'un filtre, ou encore la dégradation du lubrifiant. On peut appliquer cette méthode a toute machine contiennent un fluide.

1.3.3.L'analyse vibratoire

La méthode de surveillance de défauts basés sur l'analyse des signaux de vibration s'est avérée efficace dans plusieurs défauts mécaniques [Immovilli 09, Lin 03]. Par conséquent, l'analyse des signaux de vibration est considérée comme une approche importante pour le diagnostic et la classification des défauts [Henriquez 14], son principe est basé sur la traduction des efforts qui subit la machine par des signaux vibratoire.

En plaçant des accéléromètres aux endroits où se transmettent ces efforts, on peut détecter l'apparition des défauts dans l'équipement.

Ces signaux contiennent des informations de diagnostic utiles qui sont extraites par le calcul d'indicateurs qui sont ensuite sélectionnés en fonction de leur sensibilité aux défauts considérés, et sont fournis comme entrées dans un système de classification [Wang 16, Zhang 11]. Parmi les avantages de l'analyse vibratoire : détection défauts a un stade précoce, et la surveillance continu de la machine.

1.3.4.L'analyse par Ultrasons

Elle permet de réaliser la surveillance continue de la machine pour détecter l'apparition de bruit anormal à l'aide des capteurs audible qui sont placé à distance de l'équipement.

1.3.5.Choix d'outils de surveillance

Pour pouvoir assurer une meilleure surveillance des machines, il faut utiliser la mesure pertinente qui dépend de leur fonctionnement. Cette mesure est extraite à partir des grandeurs physiques entourant la machine à surveiller « vibrations, bruits, vitesses, etc. ».

La sélection d'une source d'information et d'une technique d'analyse adéquate est une étape primordiale quant à la réussite de la campagne de surveillance d'une machine. Ce choix est fait en tenant compte des caractéristiques cinématiques de la machine à surveiller, de son environnement et de la nature des défauts qui peuvent l'atteindre [Khelf 14]

Marie-Line Zani [Zani 03] a montré que l'analyse vibratoire, l'analyse d'huiles, la thermographie infrarouge et l'analyse acoustique sont les principales méthodes de surveillance des machines tournantes, en suite, il a donné quelques critères de choix entre telle méthode ou technique et leur domaine d'application.

Le Tableau I-1 résume les principales sources d'information et leur champs d'utilisation.

Tableau I-1 : Choix de l'outil de surveillance [Moubray 00, Lyons 04]

	Principaux avantages	Principales Limitations	Champs d'application privilégié
Analyse Vibratoire	<ul style="list-style-type: none"> -Détection de défauts à un stade précoce -Possibilité de réaliser un diagnostic approfondi -Autorise une surveillance continue -Permet de surveiller l'équipement à distance (télémaintenance) 	<ul style="list-style-type: none"> -Spectres parfois difficiles à interpréter -Dans le cas de la surveillance continue, installations relativement coûteuses. 	<ul style="list-style-type: none"> -Détection des défauts de tous les organes cinématiques de la machine (balourd, défauts d'alignement, jeux, etc.) et de sa structure.
Analyse d'huiles	<ul style="list-style-type: none"> -Détection d'une pollution anormale du lubrifiant, avant que celle-ci n'entraîne une usure ou un échauffement -Possibilité de connaître l'origine de l'anomalie par analyse des particules 	<ul style="list-style-type: none"> -Ne permet pas de localiser précisément le défaut -Nécessite de prendre de nombreuses précautions dans le prélèvement de l'échantillon 	<ul style="list-style-type: none"> -Contrôle des propriétés physico-chimiques du lubrifiant, détection d'un manque de lubrification, analyse des éléments d'usure, analyse de contamination par le process (étanchéité), etc.
Thermographie IR	<ul style="list-style-type: none"> -Permet de réaliser un contrôle rapide de l'installation -Interprétation souvent immédiate des résultats. 	<ul style="list-style-type: none"> -Détection de défauts à un stade moins précoce que l'analyse vibratoire -Contrôle limité à ce que « voit » la caméra (échauffement de la surface) -Ne permet pas de réaliser un diagnostic approfondi 	<ul style="list-style-type: none"> -Détection de tous les défauts engendrant un échauffement (manque de lubrification en particulier)
Analyse acoustique	<ul style="list-style-type: none"> -Permet de détecter l'apparition de défauts audibles -Autorise une surveillance continue 	<ul style="list-style-type: none"> - Sensibilité au bruit ambiant - Diagnostic souvent difficile à réaliser -Problèmes de répétabilité des mesures 	<ul style="list-style-type: none"> -Détection d'un bruit inhabituel pouvant ensuite être analysé par analyse vibratoire

Parmi les techniques citées au-dessus, la plus importante, la plus fiable et performante surtout pour les phénomènes d'usure et de fatigue est l'analyse vibratoire. On distingue communément deux principales activités pour cette technique d'analyse qui sont : la surveillance « la détection » et le diagnostic.

I.4. Activités de l'analyse vibratoire

I.4.1. La surveillance

Le but est de suivre l'évolution d'une machine par comparaison des relevés successifs de ses vibrations. Une tendance à la hausse de certains indicateurs par rapport à des valeurs de référence constituant la signature alerte généralement le technicien ou l'ingénieur de maintenance, sur un dysfonctionnement probable. La signature est établie à partir d'une

première campagne de mesures sur la machine neuve ou révisée. D'après [Bouzouane 03], on distingue deux types de surveillance : surveillance « On line », les mesures des indicateurs soit de manière continue, et soit d'une manière périodique qui est la surveillance « Off line ».

1.4.2. La détection

Pour détecter les défaillances d'un système, il faut être capable de classer les situations observables comme étant normales ou anormales. Cette classification n'est pas triviale, étant donné le manque d'information qui caractérise généralement les situations anormales, amené à une simplification communément adaptée, qui consiste à considérer comme anormale toute situation qui n'est pas normale.

1.4.3. Le diagnostic

Il permet de désigner l'élément de la machine défectueux suite à une évolution anormale des vibrations constatée lors de la surveillance (mesures). Le diagnostic n'est réalisé que lorsque la surveillance a permis de détecter une anomalie ou une évolution dangereuse du signal vibratoire, la Figure I-2 montre un Schéma présentatif des activités de l'analyse vibratoire [El Badaoui 97].

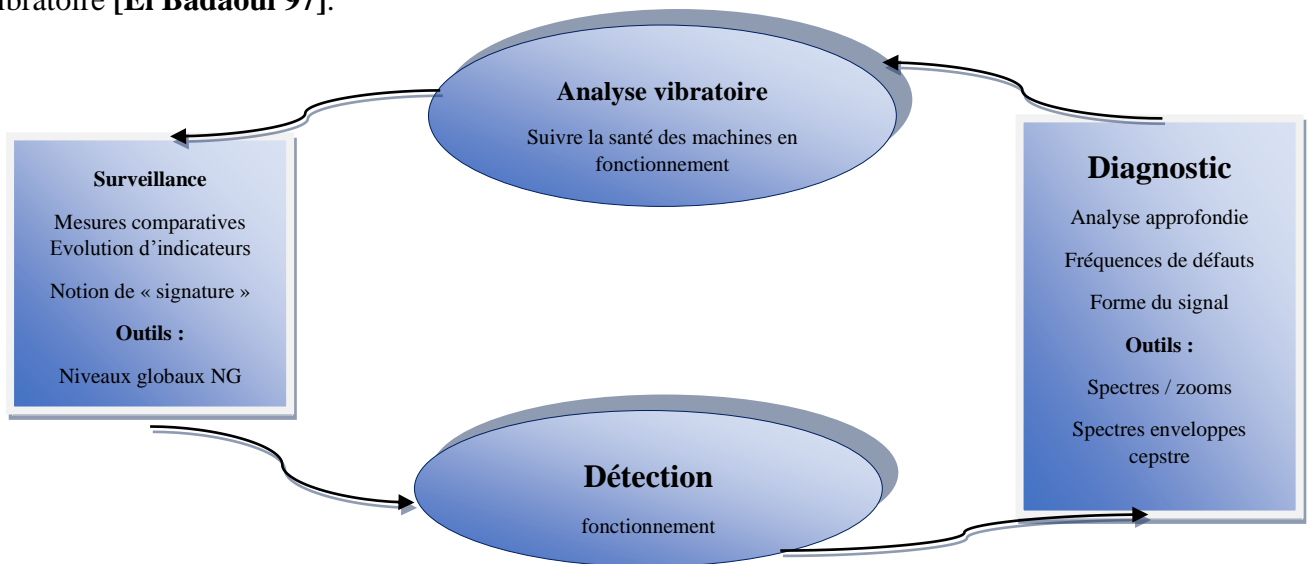


Figure I-2. Schéma présentatif des activités de l'analyse vibratoire.

I.5. Les outils du diagnostic et de la surveillance par l'analyse vibratoire

L'utilisation des méthodes de diagnostic de panne basées sur l'analyse de signaux vibratoires a prouvé son efficacité dans plusieurs défauts mécaniques. Par conséquent, l'analyse des signaux de vibration est considérée comme une approche importante pour le diagnostic et la surveillance des défauts [Wang 16, Zhang 11]. Ces signaux contiennent des informations utiles pour le diagnostic qui sont extraites par le calcul d'indicateurs qui sont

ensuite sélectionnés en fonction de leur sensibilité et ont considéré comme entrées dans un système de classification [Kang 16, He 12].

Les techniques existantes pour l'analyse vibratoire en vue de détecter d'éventuels défauts peuvent être classées selon le domaine dans lequel elles sont développées. Les indicateurs scalaires sont dans la plupart du temps utilisés dans le domaine temporel, par une évaluation quantitative de l'état du signal qui peut être la valeur efficace ou valeur crête du signal, ou bien la combinaison des deux. Le facteur crête et le kurtosis sont les facteurs les plus utilisés pour la détection de défauts dans le domaine temporel, un filtrage est généralement réalisé pour éliminer le bruit de mesure. Dans le domaine fréquentiel, la transformée de Fourier est utilisée pour mettre en évidence l'aspect périodique du signal vibratoire et permettre de prendre une décision sur l'état du signal suivant ses fréquences caractéristiques. La limitation de cette technique dans le traitement des signaux transitoires a initié le développement de la transformation en ondelette. Cette dernière technique est présente sous plusieurs formes et permet d'avoir un diagnostic efficace basé sur le signal vibratoire issu de l'équipement en défaut [Khelf 14].

1.5.1. Les indicateurs scalaires

➤ **Facteur crête**

Le facteur crête d'un signal périodique $x(t)$ est le rapport entre son amplitude pic et sa valeur efficace :

$$F_c = \frac{\sup[|x(t), T|]}{\sqrt{\frac{1}{T} \int_0^T x^2(t) dt}} \quad (I-1)$$

Ou bien dans le temps discret :

$$F_c = \frac{\sup[|x(k)|]}{\sqrt{\frac{1}{Ne} \sum_{k=1}^N x(k)^2}} \quad (I-2)$$

Où $1 \leq k \leq N$, avec N le nombre d'échantillons.

Dans le cas d'une distribution gaussienne : $3 < F_c < 6$.

➤ **Le kurtosis**

Cette grandeur introduite par le mathématicien Pearson en 1905 pour la comparaison d'une distribution donnée à une distribution normale. Le kurtosis se définit par le rapport suivant :

$$Kurt = \frac{M_4[x(t)]}{M_2[x(t)]^2} = \frac{\frac{1}{T} \int_0^\infty x^4(t) dt}{\left[\frac{1}{T} \int_0^\infty x^2(t) dt \right]^2} \quad (I-3)$$

Dans le cas discret :

$$Kurt = \frac{\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^4}{\left[\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^2 \right]^2} \quad (I-4)$$

Où \bar{x} est la valeur moyenne de x .

Les propriétés du kurtosis et du facteur crête ainsi que l'effet du choix du filtre passe-bande sur la sensibilité des deux indicateurs ont été démontrés dans la référence [Pachaud 97]. Le kurtosis est plus sensible que le facteur de crête aux variations de la vitesse de rotation. Une réduction d'un facteur de 2 de la vitesse de rotation, divise par 2 la valeur du kurtosis et par $\sqrt{2}$ le facteur de crête [Boulenger 98]

1.5.2. Les indicateurs spectraux

La surveillance basée sur l'évolution d'indicateurs scalaire présente trois inconvénients [Boulenger 98] :

- Les défauts qui n'ont pas été pris en charge dans l'élaboration des indicateurs scalaires ne peuvent pas être détectés.
- La surveillance des équipements dont le fonctionnement normal génère des impulsions périodiques n'est pas possible.
- La détection des défauts dans des installations qui génèrent un signal vibratoire à faible amplitude n'est pas prise en charge.

Les indicateurs spectraux sont alors introduits pour résoudre les problèmes rencontrés avec l'utilisation des indicateurs scalaire. Ils sont capables de détecter non seulement l'augmentation de la puissance du signal, mais aussi l'évolution des différentes composantes de ce signal.

➤ La transformée de Fourier

La transformée de Fourier permet le passage entre le domaine temporel vers le domaine fréquentiel. Ces deux domaines sont complémentaires car l'information qui se trouve dans l'espace temporel n'est pas accessible en fréquentiel et vis-versa. Le passage du temporel vers le fréquentiel s'effectue en appliquant la transformation suivante :

$$TF(x(t)) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \quad (I-5)$$

La version discrète de cette transformation appelée aussi DFT (Discrete Fourier Transform) s'écrit comme suit :

$$TFD(x(nT_e)) = X(k\Delta f) = \frac{1}{N} \sum_{n=0}^N x(nT_e) e^{-j2\pi k \frac{n}{N}} \quad (I-6)$$

T_e est le pas d'échantillonnage de $x(t)$, n le numéro de l'échantillon, k le numéro de la ligne fréquentielle.

L'implémentation pratique de cette transformation est réalisée en utilisant une version accélérée de l'algorithme appelée Transformation de Fourier Rapide ou bien FFT (Fast Fourier Transform) [Bingham 67].

La Figure I-3 montre un Signal composé de (03) sinusoïdes avec son spectre en utilisant la Transformation de Fourier Rapide FFT




Figure I-3. (a) Signal composé de (03) sinusoïdes : 50 Hz, 100 Hz et 150 Hz, (b) son spectre par FFT.

Tableau I-2. Fréquences caractéristiques des principales défaillances affectant les machines tournantes [Khelf 14]

Défaut	Fréquences caractéristiques
Balourd	Fréquence de rotation (FR)
Désalignement	FR, 2FR, Généralement 2FR est plus élevée que FR, et les vibrations axiales sont plus élevées que les radiales.
Défaut de fixation	0.5FR, FR et plusieurs de leurs harmoniques
Tourbillons d'huile	40-50% de FR
Roulements	Fréquences Correspondantes aux passages des éléments roulants données par les équations suivantes

$$Baque\ externe = \frac{FR}{2} N_b \left(1 - \frac{D_b \cos \theta}{D_p} \right)$$

$$Baque\ interne = \frac{FR}{2} N_b \left(1 + \frac{D_b \cos \theta}{D_p} \right)$$

$$Cage = \frac{FR}{2} \left(1 - \frac{D_b \cos \theta}{D_p} \right)$$

$$Bille = \frac{FR D_p}{2 D_b} \left[1 - \left(\frac{D_b \cos \theta}{D_p} \right)^2 \right]$$

N : Nombre d'éléments roulants

	D_b : Diamètre des éléments roulants
	D_p : Le diamètre moyen du roulement
	θ : L'angle de contact.

Engrenage	Donné par
	$Engrenage = N FR \pm k FR$
	N= Nombre de dents
	k= 0,1,2,3...

Le tableau I-2 illustre les fréquences caractéristiques de quelque défaut mécanique.

➤ **Transformée de Fourier à court terme**

La transformée de Fourier à court terme STFT (Short Time Fourier Transform) permet de déterminer l'allure local du contenu fréquentiel du signal. La transformation est réalisée par la multiplication du signal source avec une fenêtre choisie :

$$X(\omega, s) = \int_{-\infty}^{+\infty} x(t)g(t - s)e^{-j\omega t} dt \quad (I-7)$$

Le contenu fréquentiel est alors analysé par le passage de la fenêtre glissante. La taille fixe de la fenêtre ne permet pas d'affiner l'analyse pour l'instant transitoire. Cet inconvénient sera résolu avec l'introduction de la transformation en ondelette.

1.5.3. Le Cepstre

Le cepstre [**Childers 77**] Permet d'identifier et quantifier toutes les structures périodiques contenues dans un spectre. Cette méthode est particulièrement utile pour l'analyse des signaux vibratoires issues des machines tournantes caractérisées par la présence de peignes de raies (écaillages de roulements, jeux de paliers) et les familles de bandes latérales de modulation (excentricité, jeu angulaire) qui sont centrées entre des fréquences de fonctionnement normal de la machine (fréquence d'engrenage, passage des encoches, passage d'aubes, etc.) [**Boulenger 98**]

Deux principales définitions sont données :

$$C[x(t)] = C(\tau) = TF^{-1}[\log TF[x(t)]] \quad (I-8)$$

Ou bien :

$$C[x(t)] = C(\tau) = TF^{-1}[\log |TF[x(t)]|^2] \quad (I-9)$$

Le cepstre défini dans l'équation (1.8) est appelé « cepstre complexe » et celui de l'équation (I-9) « cepstre de puissance ».

I.5.4. Analyse d'enveloppe

L'analyse d'enveloppe est utile lorsque le spectre fréquentiel présente des bandes latérales causées par des chocs réguliers avec une durée très courte ce qui provoque la formation des bandes à la suite de l'excitation des fréquences de résonance de l'équipement [Tandon 99].

L'analyse est réalisée par le filtrage du signal avec un filtre passe-bande autour des modes résonant. La transformation de Hilbert est alors appliquée pour décrire l'enveloppe complexe du signal. La transformation FFT est finalement appliquée pour avoir le spectre de l'enveloppe.

L'inconvénient majeur de cette méthode étant le filtre passe-bande qui sera fixé autour des fréquences de résonances de l'équipement. Or les modes résonants du système ne sont pas connus d'avance.

I.5.5. Analyse par ondelettes

La transformation en ondelette est basée sur l'utilisation des fonctions en ondelette au lieu des sinusoides présentes dans la transformation de Fourier. Ces ondelettes sont caractérisées par des caractéristiques de dilatation et de translation lui permettant de bien s'adapter aux signaux de nature non stationnaire. La famille d'ondelette se définit par la fonction suivante :

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (\text{I-10})$$

Avec a un paramètre de dilatation, et b paramètre de translation.

La transformation en ondelette continue (Continuous Wavelet Transform) est alors défini par :

$$cwt(x(t)) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (\text{I-11})$$

Avec ψ^* la conjuguée de ψ , $\frac{1}{\sqrt{a}}$ est un facteur de normalisation, $a > 0$.

La dilatation et translation des ondelettes sont représentées dans la Figure I-4.




Figure I-4. Propriétés de dilatation et translation des ondelettes.

La *cwt* a été utilisée dans [Sun 02] pour la détection des singularités, sous forme de défauts de roulement par l'analyse du signal vibratoire.

La succession logique du développement de la transformée en ondelette est la version discrète. L'expression de la DWT (Discrete Wavelet Transform) est donnée comme suit :

$$dwt(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t - 2^j k}{2^j} \right) dt \quad (I-12)$$

Pratiquement, la *dwt* peut être implémentée par le moyen de deux filtres passe-bas et passe-haut, notés $h(k)$ et $g(k) = (-1)^k h(1 - k)$ respectivement. Ces filtres sont construits depuis une fonction ondelette choisie $\psi(t)$ et son facteur d'échelle $\phi(t)$ comme suit :

$$\begin{cases} \phi(t) = \sqrt{2} \sum_k h(k) \phi(2t - k) \\ \psi(t) = \sqrt{2} \sum_k g(k) \phi(2t - k) \end{cases} \quad (I-13)$$

Avec $\sum_k h(k) = \sqrt{2}$ et $\sum_k g(k) = 0$. Le signal est alors décomposé en deux coefficients d'approximation [Yan 14] :

$$\begin{cases} a_{j,k} = \sum_m h(2k - m) a_{j-1,m} \\ d_{j,k} = \sum_m g(2k - m) a_{j-1,m} \end{cases} \quad (I-14)$$

Les coefficients $a_{j,k}$ et $d_{j,k}$ sont appelés coefficient de détail et d'approximation respectivement.

L'insuffisance de la transformation en ondelette classique dans le cas des défauts qui évoluent graduellement a lancé des tentatives d'amélioration sur l'architecture classique. Le

passage a été fait vers la transformation en ondelette de deuxième génération caractérisé par des ondelettes adaptatives, ce qui résolu le problème du choix de la bonne ondelette mère lors de l'analyse [Sun 14].

I.6. Défaillances des Systèmes électro-énergétiques

I.6.1. Engrenage

Les transmissions par engrenages sont d'une grande utilité lorsqu'il s'agit de transmettre des couples importants, de produire de grandes vitesses de rotation, d'effectuer un changement de direction du mouvement de rotation, etc. Puisqu'elles travaillent dans des conditions sévères, elles sont soumises à une détérioration progressive de leur état ce qui implique des défauts. On classe généralement les défauts d'engrenages en trois catégories [Chari 06] :

- Les défauts de fabrication (erreurs de profil des dents, excentricité des roues);
- Les défauts de montage (défauts de parallélisme, d'entraxe) ;
- Les défauts apparaissant lors du fonctionnement (usure ou fissuration des dents, en général, la détérioration de dentures d'engrenages).

I.6.2. Roulement

Les roulements sont les composants les plus fondamentaux et les plus importants des machines tournantes. Les défauts de roulement sont considérés comme la source de défaillance la plus courante dans les machines tournantes, leur pourcentage varie entre 40% et 90% [Immovilli 09].

Selon la référence [SNR 04] il y a 11 types de défauts de roulements :

- Ecaillage par fatigue : Présent sous forme de fissuration et enlèvement de fragment de matière ;
- Ecaillage superficiel : Taches en surface provenant d'arrachement superficiel de métal;
- Grippage : Echauffement violent, déformation des corps roulants, laminage du métal ;
- Empreintes par déformation : Empreintes sur les pistes et les corps roulants;
- Faux effet Brinell : Enlèvement de matière par abrasion au niveau des points de contact internes du roulement ;
- Usure : Usure généralisée des corps roulants, des pistes et des cages, teinte grise ;
- Cratères et cannelures : Piqûres à bord net ou succession de plages étroites parallèles, liées à un passage de courant électrique ;
- Coups, fissures, cassures : Chocs violent, enlèvement de matière en surface, fissures, rupture des bagues ;
- Corrosion de contact : Coloration rouge ou noire sur les surfaces d'appui du roulement, dans l'alésage et sur le diamètre extérieur ;
- Corrosion : Oxydation localisée ou généralisée, à l'extérieur ou à l'intérieur du roulement ;
- Détérioration des cages : Déformation, usure, rupture [Khelf 14].

I.6.3. Arbres

L'arbre dans une machine tournante est un organe de transmission assurant le mouvement de rotation, supporté par un ou plusieurs paliers selon la configuration de la ligne d'arbre [Morel 05].

L'arbre sert de soutien et d'élément de liaison pour les autres organes de la machine. L'ensemble des éléments tournants, assemblés sur l'arbre est appelé rotor. Les défauts d'arbres tournants, et plus globalement de rotors sont assez courants dans les machines tournantes.

En réalité, il est pratiquement impossible de réaliser un centrage parfait de tous les éléments d'un rotor, ce qui est en cause d'une des plus récurrentes défaillances sur une machine tournantes, le balourd.

Un balourd peut avoir comme initiateur plusieurs origines ; défauts d'usinage, d'assemblage des rotors ou de montage. Les rotors peuvent aussi se déformer sous l'influence d'un échauffement dissymétrique.

I.7. Chaîne de mesure

Une chaîne de mesure de vibrations doit remplir les fonctions suivantes :

- 1) **Transformer la vibration mécanique en un signal électrique.** C'est le rôle du capteur. La grandeur électrique délivrée peut être :
 - Une tension comme dans le cas d'un signal issu d'un accéléromètre à électronique incorporée (ICP) ou d'un vélocimètre inductif. La sensibilité du capteur s'exprime alors en mV (millivolts) par unité physique,
 - Une charge électrique comme dans le cas d'un accéléromètre piézoélectrique dont la sensibilité s'exprime en pico-coulomb par g ou en m/s^2 (mètres par seconde carrée).
- 2) **Conditionner le signal de sortie du capteur pour le rendre exploitable et transportable.** C'est le rôle du préamplificateur. Indispensable pour les accéléromètres piézoélectriques, le préamplificateur peut être ou non incorporé au capteur et il permet soit une simple amplification de la tension de sortie du capteur (amplificateur de tension), soit une transformation de la charge électrique en tension avant son amplification (convertisseur charge tension improprement appelé préamplificateur de charge).
- 3) **Intégrer le signal.** Cette opération permet de transformer si nécessaire le signal délivré par un accéléromètre en un signal représentant la vitesse ou le déplacement du mouvement vibratoire (ou encore, pour un vélocimètre, en un signal représentant le déplacement).
- 4) **Limiter la plage de fréquences du signal.** C'est le rôle des filtres passe haut, passe-bas, ou passe-bande, à fréquences de coupure fixes ou réglables par l'utilisateur. Cette opération permet de réduire l'influence des composantes hautes ou basses fréquences du signal jugées indésirables, de concentrer l'analyse du signal dans une plage de fréquences définies ou d'effectuer des mesures selon les spécifications d'une norme.

- 5) **Amplifier de nouveau le signal obtenu.** Cette amplification permet d'adapter la gamme dynamique d'entrée du convertisseur pour avoir la meilleure qualité de signal sans le tronquer.
- 6) **Numériser le signal.** C'est le rôle du convertisseur analogique/numérique (CAN) qui transforme le signal en données numériques avant de les transmettre :
 - À une unité de mesure de grandeurs scalaires (amplitudes crête, crête à crête et efficace),
 - À un collecteur de données informatisées ou à un analyseur,
 - À une éventuelle unité de conservation du signal temporel pour un traitement différé des signaux (post-traitement).

La Figure I-5 donne un exemple de chaîne fonctionnelle type équipée d'un capteur d'accélération (accéléromètre).

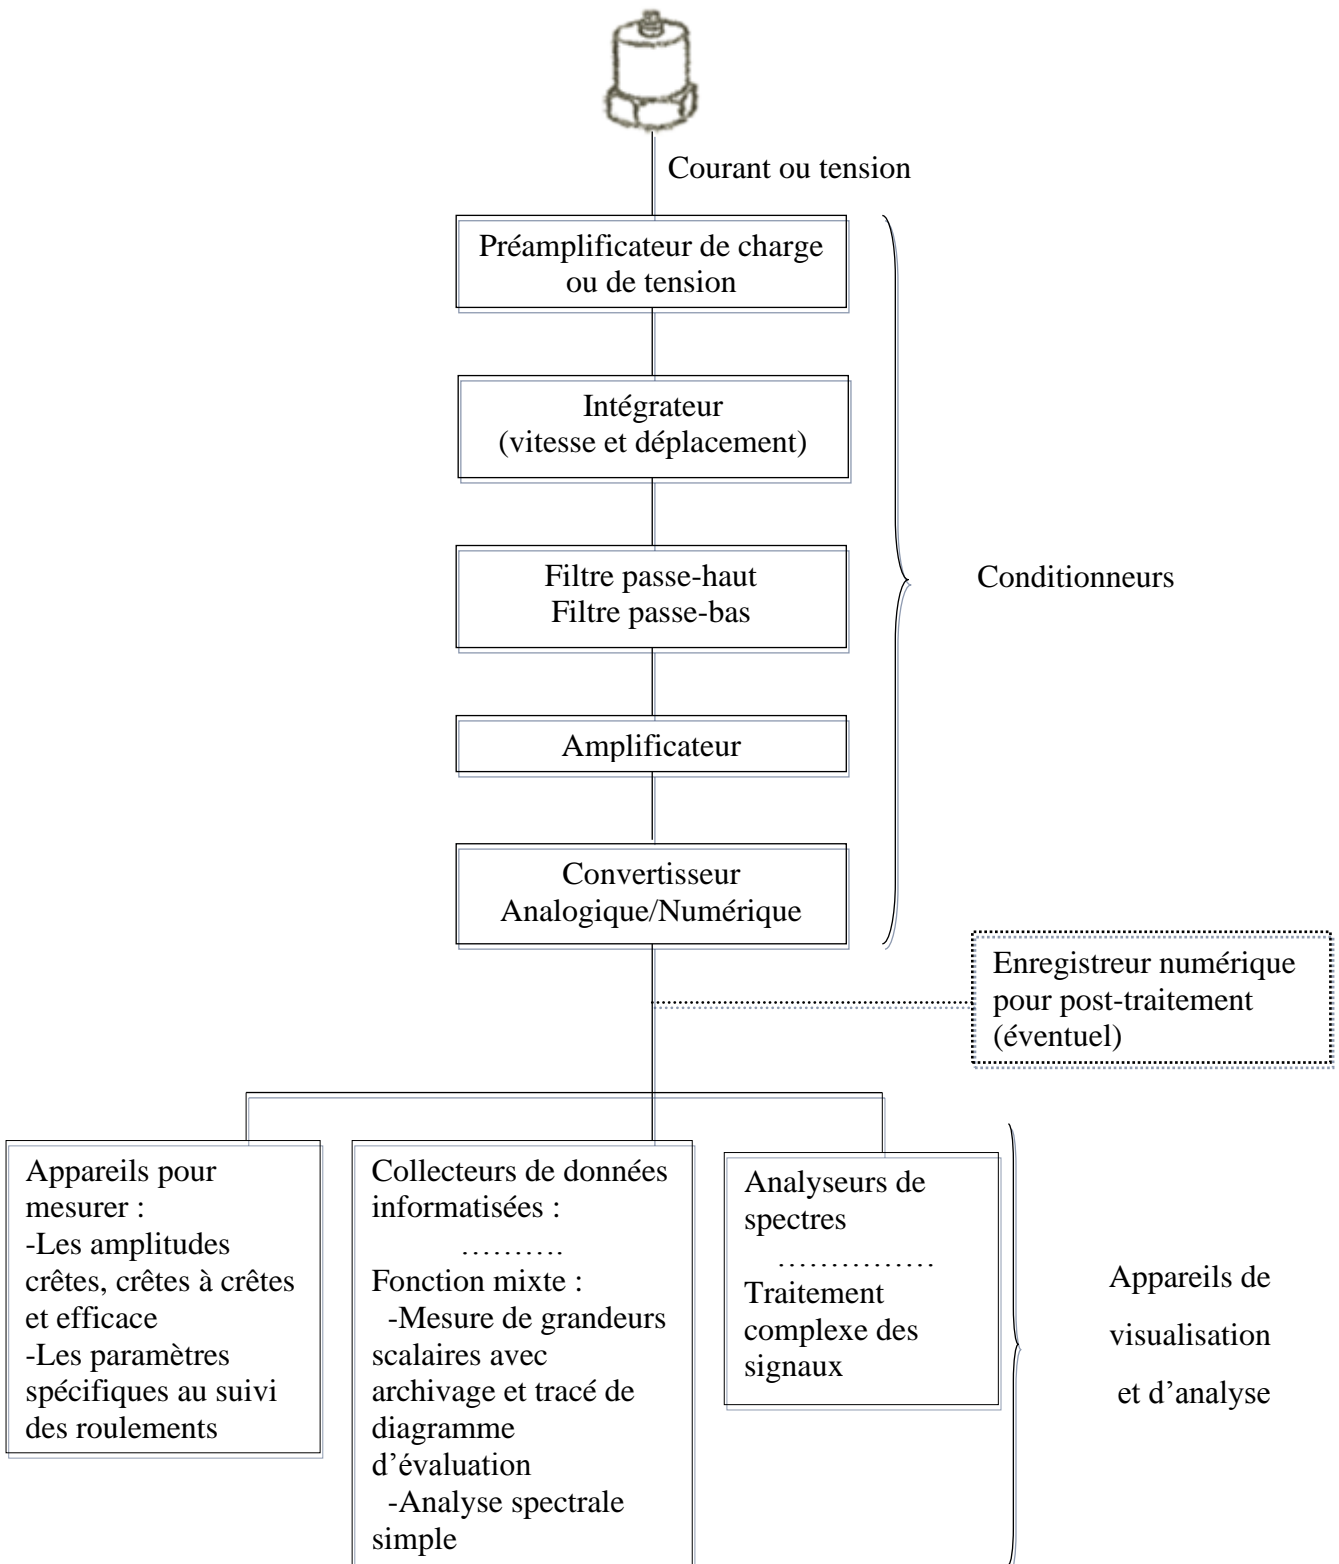


Figure I-5. Exemple d'une chaîne de mesure munie d'un accéléromètre [Boulenger 07].

1.7.1. Accéléromètres

Les accéléromètres mesurent les signaux vibratoires mécaniques en termes d'accélération. L'accéléromètre le plus populaire consiste en une masse montée sur un capteur de force (comme un Crystal piézoélectrique) (Figure I-6. Construction interne d'un accéléromètre piézoélectrique). Ce dernier produit une sortie proportionnelle à la force exercée sur la masse, qui est, par son tour proportionnelle à l'accélération d'un composant de la machine dans lequel le capteur est monté. La sensibilité typique d'un accéléromètre est de $1V/g$. Les accéléromètres sont petits et légers dont les intervalles d'opération en fréquence et en température sont larges. Les accéléromètres ne nécessitent pas une alimentation et sont installés à l'extérieur. Ils sont par contre sensibles à la méthode de raccordement et à l'état de surface de l'équipement.




Figure I-6. Construction interne d'un accéléromètre piézoélectrique [Agnes 05].

Les accéléromètres sont sensibles aux bruits (certains modèles contiennent un amplificateur intégré pour diminuer cet effet). L'intervalle de fonctionnement d'un accéléromètre est souvent de 1500 tr/mn jusqu'à 1200 ktr/mn .

L'accéléromètre est le capteur traditionnel pour la mesure des vibrations structurelles.

Robuste, relativement moins cher, et facile à l'utilisation grâce au montage externe à la structure ou au châssis de la machine, il est l'outil parfait pour avoir l'accès aux vibrations hautes fréquences.

Dans la surveillance des vibrations des machines, les accéléromètres sont indispensables pour le diagnostic des problèmes dues aux : dents d'engrenages, roulements à billes, etc. [Agnes 05]

1.7.2. Capteur de vitesse

Le principe de fonctionnement du capteur de vitesse le plus utilisé est basé sur la propriété sismique d'une masse suspendue par des ressorts dans un corps vibrant. Dans le cas d'un transducteur électromagnétique, la masse porte une bobine et elle est suspendue par des ressorts dans un corps contenant au milieu un aimant permanent. Le mouvement relatif entre la bobine et l'aimant génère une tension de sortie proportionnelle à la vitesse instantanée des vibrations [Agnes 05].




Figure I-7. Construction interne d'un capteur de vitesse électromagnétique. [Pachaud 97].

Le capteur ne nécessite pas une alimentation électrique externe. Ces capteurs possèdent une sensibilité acceptable (4 à 40mV/mm/s), l'intervalle de fréquence est de 500 tr/mn jusqu'à 1000 ktr/mn .

Les capteurs de vitesse sont installés à l'extérieur et servent pour la mesure des vibrations dans les machines et structures. Les inconvénients de ces capteurs incluent : difficulté de vérification du calibrage, sensibilité à l'orientation du montage, les vibrations axiales.

Les parties mobiles augmentent le risque d'endommagement par un choc brusque ou par un processus de fatigue. Les capteurs de vitesse moderne qui ne contiennent pas de parties mobiles sont basés sur le même principe qu'un accéléromètre et incluent un circuit d'intégration électronique.

1.7.3. Capteur de déplacement

Les capteurs de proximité basés sur les courants d'Eddy sont les meilleurs outils pour accomplir cette tâche.

Le principe de ces capteurs est la modification du champ électromagnétique dû aux courants d'Eddy induits dans un matériau conducteur solide à la proximité du capteur. La tension de sortie est proportionnelle à l'écart entre le capteur et la surface du matériau à surveiller. La valeur typique de sensibilité de ces capteurs est de $8\text{mV}/\mu\text{m}$.

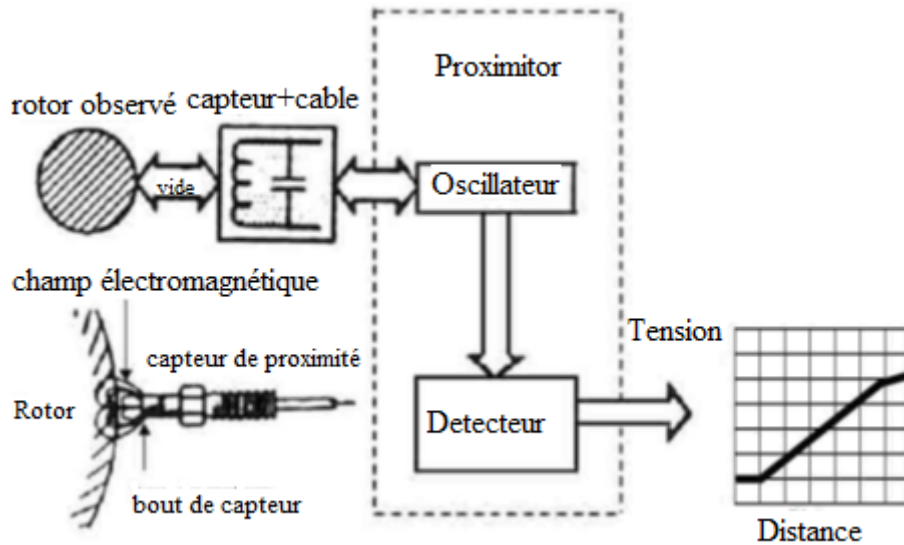


Figure I-8. Principe du capteur de déplacement. [Agnes 05].

Les capteurs de proximité ne fournissent pas uniquement les composantes dynamiques du mouvement de rotation (vibrations), mais aussi les données quasi-statiques et statiques et la position à fréquence nulle (DC gap). Ces capteurs couvrent l'intervalle de 0 jusqu'à 600

ktr/mn. Le capteur de proximité nécessite une alimentation externe (-18 jusqu'à -24Vdc), et la surface du rotor doit être conditionnée pour avoir un signal de précision.

Le capteur de proximité est considéré le meilleur capteur pour mesurer les vibrations latérales et axiales ainsi que les positions correspondantes pour les rotors des machines tournantes.

Dans certaines machines, il n'est pas possible de placer les capteurs en position orthogonale, dans ce cas il est possible de les placer dans n'importe quelle position (la plus proche de 90°) à l'exception de 180°, une correction d'angle doit être effectuée au niveau software.

Les capteurs de proximité, montés en orthogonale donnent deux signaux latéraux de vibrations, avec un traitement approprié donnent une image amplifiée du centre du rotor [Agnes 05].

I.8. Etat de l'art

De nombreux travaux de recherches ont été réalisés dans le domaine de la surveillance des systèmes électro-énergétique, Dans cette partie, nous présentons une synthèse de quelques travaux de recherches, en présentant les différentes méthodes utilisées et les outils de diagnostic des défauts par analyse vibratoire, et les différentes défaillances des systèmes électro-énergétique.

La hauteur dans [Dowson 70] montre l'approche par l'analyse des lubrifiants. Dans un autre travail les auteurs [Cardone 98] prouvent que la thermographie infrarouge est capable de détecter des phénomènes particuliers liés à la configuration de l'écoulement du fluide dans

les machines tournantes. La technique thermographie infrarouge, et analyse ultrasonore sont utilisés et comparés pour la détection de l'usure des roulements dans les machines tournantes dans [Abou El Anouar 16].

L'utilisation des méthodes de diagnostic de défaut basées sur l'analyse de signaux vibratoires a prouvé son efficacité dans plusieurs défauts mécaniques. L'extraction d'indicateurs tels que le facteur de crête, le Kurtosis, et le RMS à partir des signaux temporels pour la surveillance de plusieurs défauts mécaniques sont exploités ; ils sont généralement faciles à calculer et permettent une exécution rapide de la procédure de classification, et ont été expérimentés dans plusieurs travaux [Sreejith 08, Samanta 03].

Lors de la mise en œuvre de la transformée de Fourier dans les outils de diagnostic, l'analyse des signaux de vibration a pleinement exploité la conversion des signaux dans le domaine fréquentiel pour diagnostiquer les défauts des machines. L'utilisation d'indicateurs basés sur la fréquence permet d'extraire de nouvelles informations cachées dans les signaux vibratoires bruts qui ont un caractère non linéaire et non stationnaire [Weixing 13].

D'autre part, la transformée de Fourier (FT) a l'avantage de représenter directement les signaux de vibration temporelle sous forme de spectre invariant par translation.

Les techniques classiques basées sur la transformée de Fourier montrent leurs limites dans le cas où les signaux sont transitoires et variable au cours du temps d'acquisition et comme la FT ne s'applique pas à un signal vibratoire non stationnaire, pour traiter ces phénomènes elle est appliquée à une fenêtre glissante dans le signal qui est considérée comme stationnaire.

Les techniques Temps Fréquence sont exploités pour analyser les fluctuations fréquentielles qui existent au cours du temps. Parmi lesquelles nous trouvons, la Transformée de Fourier à Court Terme.

Plusieurs travaux ont été menés par exploitation des techniques temps – fréquence pour la détection de défauts [Xiao-Yi 08, Safizadeh 05].

Parmi les inconvénients majeurs de l'analyse de Fourier ; est qu'elle accepte seulement les signaux stationnaires, ce qui signifie que l'intervalle de temps dans lequel elle se produit ne peut pas être lié à une signature de fréquence.

L'analyse d'enveloppe est relativement facile à mettre en œuvre. Elle est beaucoup utilisée pour le diagnostic des machines tournantes (dont les signaux sont typiquement non-stationnaires) ainsi qu'en contrôle non destructif (émission acoustique). L'idée de cette technique est d'analyser le signal temporel d'une harmonique sur une fréquence donnée [Antoni 04].

L'auteur dans [Patel 12] a utilisé l'analyse d'enveloppe des signaux de vibration pour la détection des défauts de roulement.

La transformée en ondelettes est une représentation temps-fréquence du signal. La transformée en ondelettes a été développée pour surmonter la transformée de Fourier à court terme (TFCT) Cette analyse nous permet d'examiner les caractéristiques d'un signal à

différentes bandes de fréquence, qui peut également être utilisée pour analyser les signaux non-stationnaires.

L'auteur dans [Konar 15] a prouvé la capacité d'extraction d'informations à partir de la transformé en ondelette (WT), et la transformé de Hilbert (HT) pour faire un diagnostic de défaut d'un moteur à induction en utilisant les signaux de vibration.

I.9. Conclusion

Dans ce chapitre, nous avons présenté une étude théorique sur la surveillance des systèmes électro-énergétiques, les outils du diagnostic et de la surveillance par l'analyse vibratoire, et la chaîne de mesure. Aussi, nous avons étudié les différents défauts des Systèmes électro-énergétiques. Et à la fin de ce chapitre une synthèse bibliographique a été présentée, montrant un état de l'art du diagnostic des systèmes électro-énergétiques.

Chapitre II. Diagnostic de défauts basé sur les méthodes de l'intelligence artificielle

Chapitre II. Diagnostic de défaut basé sur les méthodes de l'intelligence artificielle

II.1. Introduction :

Les techniques d'intelligence artificielle (IA) ont reçu une attention croissante dans le milieu industrielle. Ce chapitre présente les algorithmes d'IA dans le diagnostic des pannes. Une brève introduction sur les différents algorithmes d'IA est présentée en premier, y compris les méthodes suivantes : machine à vecteurs de support SVM, le réseau de neurones artificiels ANN et le système d'inférence neuro-floue adaptatif ANFIS. En fin de ce chapitre, une étude bibliographique de ces algorithmes d'IA dans le diagnostic de défauts est présentée.

II.2. Méthodes de diagnostic des défauts basés sur l'intelligence artificielle

Les méthodes classiques de détection des défauts consistent à vérifier les variables mesurables d'un système par rapport à une certaine tolérance des valeurs normales et déclencher des messages d'alarme si les tolérances sont dépassées ou prennent les mesures appropriées lorsqu'ils dépassent une valeur limite qui signifie un processus dangereux.

Dans cette étude, nous veulent présenter des systèmes intelligent de diagnostic des défauts afin qu'il nous aide de prendre une décision rapide sur l'état de la machine, sans besoin d'une analyse experte.

Le diagnostic de défaut peut être considéré comme un problème de reconnaissance des formes concernant l'état des machines.

En tant qu'outil puissant de reconnaissance des formes, l'intelligence artificielle (IA) a attiré une grande attention de la part de nombreux chercheurs dans les applications de reconnaissance de défauts des machines.

Par conséquent, un système commun de diagnostic des défauts se compose principalement souvent de deux étapes : traitement des données (extraction des indicateurs), reconnaissance des défauts (classification). Les systèmes de diagnostic de pannes intelligents les plus courants sont construits sur la base du prétraitement par les algorithmes d'extraction des indicateurs pour transformer les modèles d'entrée afin qu'ils puissent être représentés par des vecteurs de caractéristiques(indicateurs) de faible dimension pour faciliter la comparaison des différentes classes.

Ensuite, les vecteurs de caractéristiques (indicateurs) sont utilisés comme entrée des techniques d'IA pour la reconnaissance des défauts. L'étape de la reconnaissance des défauts est utilisée pour classer les informations obtenues dans l'espace des caractéristiques aux défauts de la machine dans l'espace des défauts.

De nombreux outils ou techniques d'IA ont été utilisés, y compris l'optimisation convexe, l'optimisation mathématique, ainsi que la classification. Plus précisément, les Classifieurs et les méthodes d'apprentissage statistique ont été largement utilisés.

Les systèmes de diagnostic des défauts sont principalement construits comme la combinaison de pièces individuelles, telles que la collecte de données (acquisition de données), prétraitement du signal, Extraction des caractéristiques, et classification des défauts, comme le montre la Figure II-1.

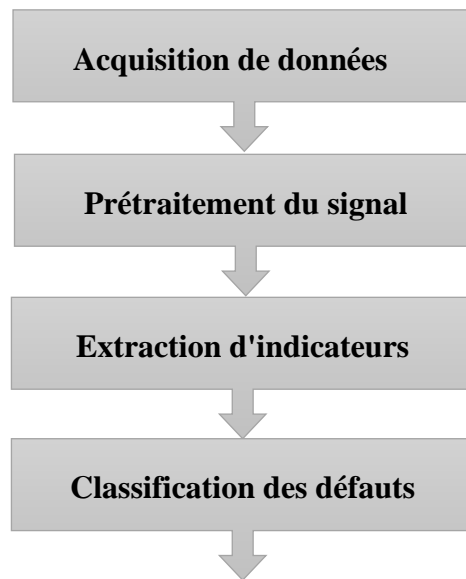


Figure II-1. Organigramme de diagnostic de défauts basé sur l'intelligence artificielle

Le rôle récapitulatif de chaque procédure est décrit comme suit :

- **Acquisition de données** : cette procédure est utilisée pour collecter les signaux vibratoires.
- **Prétraitement du signal** : cela inclut le transfert de données à partir du domaine temporel en domaine fréquentiel.
- **Extraction d'indicateurs** : les entités les plus importantes sont calculées en utilisant certains paramètres des indicateurs dans le domaine temporel ou dans le domaine fréquentiel.
- **Classification des défauts** : les données obtenues à partir de l'extraction d'indicateurs est introduite dans le Classifieur [Ebrahimi 10].

2.3. Contexte théorique des approches de l'IA :

Dans cette section, nous présentons un système de diagnostic intelligent basé sur l'apprentissage automatique, qui peut apprendre automatiquement à partir de données empiriques et identifier la cause probable d'un défaut. Utiliser un tel système de diagnostic pour éliminer les difficultés liées à l'acquisition de connaissances traditionnelles. Les machines à vecteurs de support SVM et les réseaux de neurone ANN, et l'ANFIS ont été utilisées au diagnostic pour fournir une isolation précise des causes profondes.

II.2.1. Diagnostic de défaut basé sur le SVM (machines à vecteurs de support)

Le SVM est un algorithme d'apprentissage automatique supervisé proposé par Vapnik en 1995 [Vapnik 95]. Le but des SVM est de définir un hyperplan de séparation optimal en anglais **Optimal Separating Hyperplane (OSH)** pour séparer deux classes ou plusieurs classes. Les vecteurs de la même classe tombent du même côté de la séparation optimale de l'hyperplan, et la distance des vecteurs les plus proches à la séparation optimale de l'hyperplan est le maximum parmi pour tous les hyperplans de séparation. Une importance de cette approche est que la solution est uniquement basée sur ces vecteurs qui sont les plus proches de la **OSH**, qui est calculées de la manière suivante.

Soit (x_i, y_i) , $i = 1, 2, \dots, n$ est un ensemble d'exemples de formation, et $x_i \in R_d$, $y_i \in \{-1, +1\}$.

La Figure II-2 illustre un modèle SVM à deux classes. Le vecteur x_i est considéré comme entrée, et d est la dimension des vecteurs d'entrée. Chaque vecteur d'entrée appartient à l'un des deux classes. L'un est étiqueté par $y = +1$; et l'autre est étiqueté par $y = -1$.

Si l'ensemble peut être séparé linéairement, il doit y avoir un hyperplan satisfaisant à la formule (II-1) :

$$f(x) = \text{sgn}(\omega^T x + b) \tag{II-1}$$

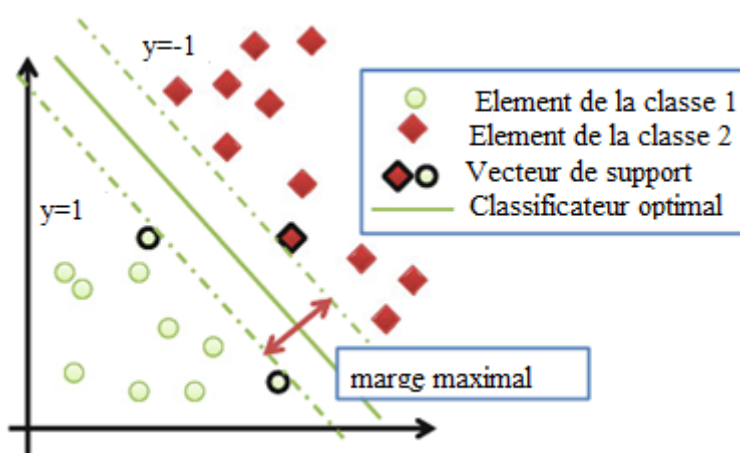


Figure II-2. Illustration d'un modèle de machine à vecteur de support de 2 classes

Où sgn le signe de $(\omega^T x + b)$, ω est un vecteur dimensionnel et b est un scalaire.

Les vecteurs x_i pour lesquels $f(x_i)$ est positif sont placés dans une classe, tandis que les vecteurs x_i pour lequel $f(x_i)$ est négatif sont placés dans une autre classe. Sur la base de [Vapnik 95], nous définissons la marge ; elle est deux fois la distance du Classifieur au vecteur de données le plus proche, à savoir le vecteur de soutien. La marge est une mesure de la capacité à générer un Classifieur. De plus la marge est grande, la génération du Classifieur est meilleure. Les SVM maximisent la marge entre deux classes.

Puisque la largeur de la marge est égale à $2/\sqrt{\omega^T \omega}$, la solution de la marge maximale est trouvée par résoudre le problème de minimisation suivant:

$$\text{Minimize } W = \frac{1}{2} \|\omega\|^p + C \sum_i^s \xi_i \quad (\text{II-2})$$

$$\|y_i (\omega \cdot x_i + b)\| \leq 1 - \xi_i, \forall_i \quad (\text{II-3})$$

$$\xi_i > 0, \forall_i \quad (\text{II-4})$$

Où ξ_i la variable élastique est introduite pour mesurer le degré de mauvaise classification des données x_i et C représentent la pénalité d'erreur. Nous pouvons régler C pour ajuster le modèle SVM formé. Le paramètre p est utilisé pour la régularisation des poids dans le modèle SVM. La plupart des solveurs SVM utilisent la régularisation standard, c'est-à-dire $p=2$. Nous supposons donc $p = 2$ dans la plupart des cas.

Afin de résoudre le problème d'optimisation décrit dans (2.2), un ensemble de multiplicateurs de Lagrange α_i , où $\alpha_i \geq 0$, est utilisé. Chaque multiplicateur α_i correspond à une contrainte en (2.3) sur les vecteurs de supports. Le problème d'optimisation de (2.2) peut maintenant être exprimé sous la forme :

$$\text{Minimize } W_1 = \frac{1}{2} \sum_{i,j=1}^s \alpha_i Q_{ij} \alpha_j - \sum_{i=1}^s \alpha_i + b \sum_{i=1}^s y_i \alpha_i \quad (\text{II-5})$$

Où $Q_{ij} = y_i y_j K(x_i, x_j)$ et K est la fonction du noyau décrite dans la section suivante. Des détails mathématiques supplémentaires sont omis ici mais ils peuvent être trouvés dans [Vapnik 95]. Les poids et les offsets (décalages) sont les suivants :

$$\omega = \sum_{i=1}^s \alpha_i y_i x_i \quad (\text{II-6})$$

$$b = \frac{1}{N_s} \sum_{i=1}^s (y_i - \omega \cdot x_i) \quad (\text{II-7})$$

À l'origine, les SVMs étaient conçus pour résoudre les problèmes de classification linéaire binaire. En pratique, les problèmes de classification ne sont pas limités par deux classes. Dans le diagnostic de défaut, le nombre des classes est généralement supérieur à deux. Dans [Vapnik 95], une conception modifiée des SVM a été proposée afin d'incorporer l'apprentissage multi classe. En plus de cela, une approche alternative pour gérer un grand nombre de classes consiste à combiner plusieurs SVM binaires. « Un contre un » fournit des comparaisons par paires entre les classes. « Un contre tous » compare une classe de donnée à toutes les autres classes. Selon une étude de comparaison dans [Vapnik 95], les précisions de ces méthodes sont presque les mêmes. Par conséquent, nous choisissons le « un contre tous » dans notre problème, qui a la plus faible complexité de calcul.

➤ **Machines vectorielles de support multi-noyau**

Les SVM classiques sont efficaces pour la classification linéaire, comme discuté dans la section 2.2.1. Cependant, dans de nombreux cas pratiques, y compris le diagnostic des défauts, les SVM classiques ne parviennent pas à trouver un Classifieur linéaire optimal pour séparer les classes. Par conséquent, dans de tels cas, les SVM doivent être étendus pour gérer

les problèmes de classification non linéaire. Une solution est de transformer le problème en un espace d'entités de dimension supérieure par le biais d'un mappage non linéaire, également appelé noyau, et le Classifieur est construit dans le nouvel espace d'entités. L'avantage de cette transformation est qu'il n'est pas nécessaire d'implémenter explicitement la transformation et de déterminer l'hyperplan de séparation dans un espace d'entités de dimension supérieure.

Kernel (Noyau)

Dans les méthodes de transformation basées sur le noyau, la représentation des données est implicitement choisie via un noyau $K(x_i, x_j)$, où x_i et x_j sont deux vecteurs d'entrée dans l'espace des caractéristiques de dimension inférieure. La Figure II-3 illustre la transformation d'un espace d'entités de dimension inférieure en un espace d'entités de haute dimension. Le problème d'optimisation de (2.5) peut maintenant être exprimé comme suit :

$$\text{Minimize } W_2 = \frac{1}{2} \sum_{i,j=1}^s \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^s \alpha_i + b \sum_{i=1}^s y_i \alpha_i \quad (\text{II-8})$$

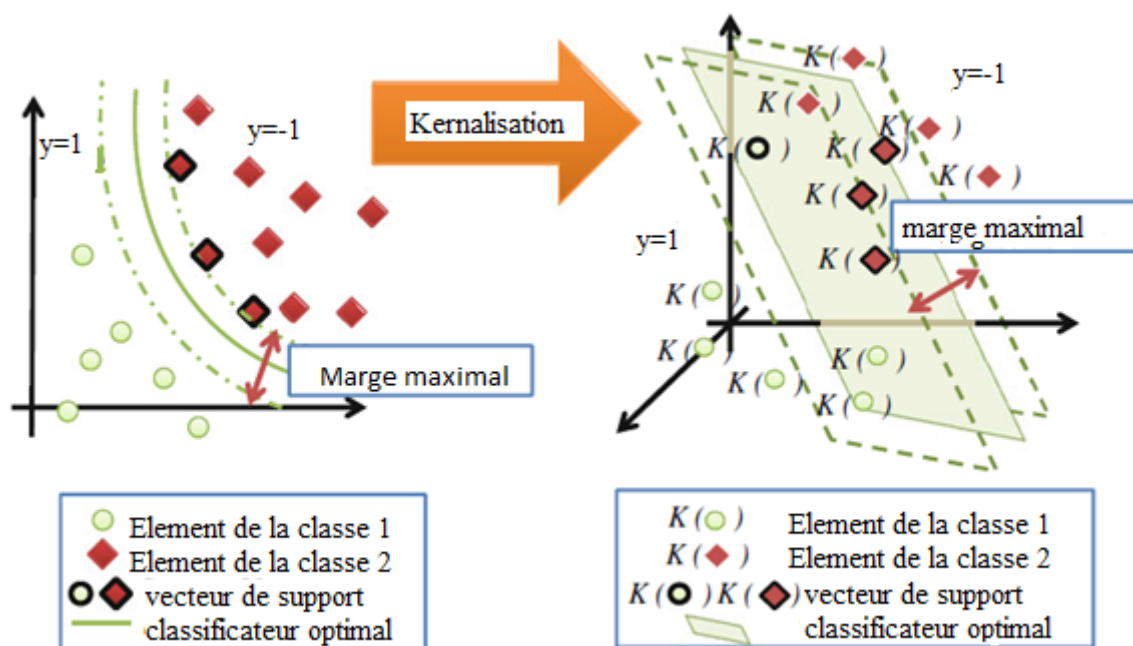


Figure II-3. Illustration du modèle de machine à vecteur de support avec noyau.

Avec des fonctions de contrainte similaires à celles des SVM non noyaux (non Kernel).

$$b = \frac{1}{N_s} \sum_{i=1}^s \left(y_i - \sum_{j=1}^s \alpha_j y_j \cdot K(x_i, x_j) \right) \quad (\text{II-9})$$

La fonction décision (II-1) est exprimée maintenant comme suit :

$$f(x) = \text{sgn} \left(\sum_{i=1}^s \alpha_i y_i K(x, x_i) + b \right) \quad (\text{II-10})$$

Le choix de la fonction du noyau est important pour le succès du modèle basé sur SVM. Il existe plusieurs fonctions du noyau qui sont largement utilisées [Vapnik 95] :

- Noyau Polynomial Homogène : $K(x_i, x_j) = (x_i, x_j)^d$, où : $d \geq 1$. Le noyau linéaire (d=1) est considéré comme une représentation noyautée des SVMs linéaires.
- Le noyau polynomial : $K(x_i, x_j) = (x_i, x_j + 1)^d$, où $d \geq 1$.
- Le noyau Gaussien : $K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}$, ou $\gamma = \frac{1}{2\sigma^2}$ et σ peut être interprétée comme la déviation standard de la distribution Gaussienne.
- Le noyau exponentiel : $K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|}$.

➤ **Machines vectorielles de support multi-noyau :**

Des applications récentes ont montré que l'utilisation de plusieurs noyaux au lieu d'un seul peut conduire à une meilleure classification. L'idée est de représenter le noyau $K(x_i, x_j)$ comme une combinaison linéaire de M noyaux de base :

$$K(x_i, x_j) = \sum_{k=1}^M \mu_k K_k(x_i, x_j) \quad (\text{II-11})$$

Où $\mu_k \geq 0$ et $\sum_{k=1}^M \mu_k = 1$. Chaque noyau à base K_k peut être un des types de noyaux listés dans la Sect.2.3. Donc le problème d'optimisation pourrait être déclaré comme suit :

$$\text{Minimize } W_3 = \frac{1}{2} \sum_{i,j=1}^S \alpha_i \alpha_j y_i y_j k \sum_{k=1}^M \mu_k K_k(x_i, x_j) - \sum_{i=1}^S \alpha_i + b \sum_{i=1}^S y_i \alpha_i, \quad (\text{II-12})$$

Le problème d'optimisation de l'équation. (2.14) est résolu en utilisant une méthode à gradient descend. Le mécanisme d'apprentissage d'un système de diagnostic multi-noyau basé sur SVM, le système de diagnostic basé sur SVM exploite des noyaux uniques de manière heuristique. Cependant, en raison de la corrélation entre les syndromes, nous ne pouvons pas déterminer arbitrairement un seul noyau pour chaque système de diagnostic. Un système de diagnostic nécessite un noyau adaptatif afin d'obtenir une précision de prédiction plus élevée. Une telle adaptation peut s'étendre d'un seul noyau à plusieurs noyaux. Sans connaissance du noyau exact à utiliser, les poids des différents noyaux peuvent être configurés de manière appropriée pour s'adapter aux données de formation et générer une meilleure prédiction pour le système de diagnostic.

➤ **Organigramme de diagnostic par SVM :**

Le diagnostic basé sur SVM se compose de quatre étapes décrites dans la Figure IV-4

Étape 1 : L'étape de préparation des données suit également la description de la section. 3.1. Les syndromes extraits et les composants remplacés sont utilisés comme entrées et sorties pour la formation des SVM.

Étape 2 : La fonction de noyau appropriée et le paramètre de pénalité sont choisis pour déterminer la contrainte SVM. Le choix de ces deux paramètres affecte la performance des SVM. Cependant, il n'y a pas de règles génériques pour sélectionner le meilleur noyau et

d'autres paramètres de l'SVM pour un problème spécifique. Dans notre travail, nous déterminons la meilleure conception des SVM de manière heuristique. Selon des résultats expérimentaux approfondis, nous constatons que les SVM avec un noyau linéaire et un paramètre de pénalité relativement important fournissent la précision de diagnostic la plus élevée dans le diagnostic de défaut.

Étape 3 : La détermination de l'OHS peut être considérée comme la formation des SVM. L'OHS est déterminée en résolvant le problème d'optimisation quadratique décrit dans les équations. (2.7) et (2.6). Les valeurs de w et b peuvent être calculées à l'aide de MATLAB. Les valeurs w et b sont déterminées après l'entraînement.

Étape 4 : Étant donné un nouveau vecteur d'entrée, nous pouvons calculer la sortie du SVM en utilisant la fonction de décision dans Eq. (2.1). Dans l'étape de diagnostic, nous classons la sortie de tous les SVM et sélectionnons le composant représenté par le SVM avec la plus grande sortie.

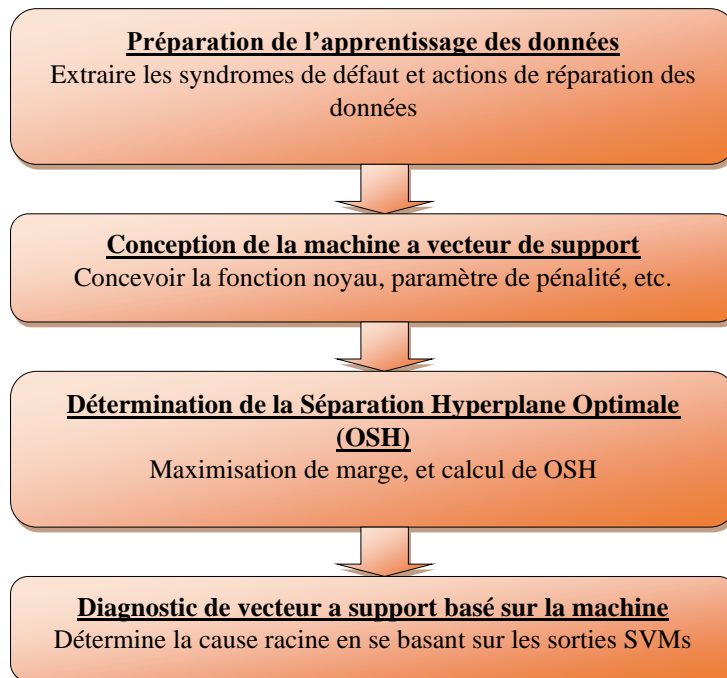


Figure II-4. Organigramme de diagnostic utilisant les SVMs.

II.2.2. ANFIS

Le système neuro-flou combine les capacités d'apprentissage des réseaux de neurones avec l'interprétation des règles linguistiques d'un système d'inférence floue. Les systèmes flous conviennent à une représentation incertaine des connaissances, tandis que les réseaux de neurones sont des structures efficaces capables d'apprendre à partir d'exemples. Cette technique hybride apporte la capacité d'apprentissage des réseaux de neurones au système d'inférence floue.

Les paramètres associés aux fonctions d'appartenance d'un FIS de type Sugeno changeront à travers l'algorithme d'apprentissage du réseau neuronal. Le calcul et l'ajustement

de ces paramètres sont facilités par un vecteur de gradient, qui fournit une mesure de façon que le FIS modélise les données d'entrée / sortie pour un ensemble donné de paramètres.

Du point de vue de la topologie, ANFIS est une implémentation d'un système d'inférence floue représentatif en utilisant une structure de type réseau de neurones à propagation arrière (en anglais Back Propagation). La Figure II-5 montre la topologie d'ANFIS avec le nœud q pour chaque entrée, qui se compose de cinq couches. La description de chaque couche est comme suit :

- **Couche 1** - Dans la première couche, chaque nœud correspond à un terme linguistique. Le nombre des termes linguistiques est déterminé par l'expert du domaine problématique. Dans cette couche pour $i = 1, 2, 3, \dots, P$; x_i désigne la i ème entrée d'ANFIS et O_i^1 est la sortie du nœud i . Ici, il existe une fonction de nœud où sa règle est égale à celle des fonctions d'appartenance floue. ANFIS utilise soit l'algorithme rétropropagation ou une combinaison d'estimation des moindres carrés avec l'algorithme de rétropropagation pour l'estimation des paramètres de la fonction d'appartenance:

$$O_i^1 = M_i(X_i) \quad (\text{II-13})$$

- **Couche 2** - La sortie de chaque nœud de cette couche, est le produit de tous les signaux entrants, représente la puissance de tir de la règle de raisonnement. Chaque règle représente une règle de logique floue. Ici, pour calculer la sortie de la couche, l'opérateur AND (min) est utilisée :

$$O_i^2 = M_i(x_i) \text{AND} M_j(x_j) \quad (\text{II-13})$$

- **Couche 3** - La comparaison entre la force de tir des règles et la somme de toutes les forces de tir est effectuée dans cette couche. La sortie de cette couche est la force de tir normalisée :

$$O_i^3 = \frac{O_i^2}{\sum_i O_i^2} \quad (\text{II-14})$$

- **Couche 4** - Cette couche est une couche conséquente et implémente le système d'inférence de type Sugeno, c'est-à-dire une combinaison linéaire des variables d'entrée ANFIS (x_1, x_2, \dots, x_p) plus un terme constant (c_1, c_2, \dots, c_p) de la sortie de chaque règle floue. La sortie du nœud est une somme pondérée de ces sorties intermédiaires. Dans la sortie suivante, les paramètres p_1, p_2, \dots, p_p et c_1, c_2, \dots, c_p sont appelés paramètres conséquents:

$$O_i^4 = O_i^3 \sum_{j=1}^P P_j X_j + C_j \quad (\text{II-15})$$

- **Couche 5** - Le processus de défuzzification a lieu dans cette couche et les sorties de la couche 4 sont agrégées :

$$O_i^5 = \sum_i O_i^4 \quad (\text{II-16})$$




Figure II-5. Structure de l'ANFIS [Alavandar 08].

II.2.3. Réseau neuronal artificiel (ANN)

ANN est considérée comme l'algorithme le plus couramment utilisée. Pour sa forme la plus populaire, il y a trois composants dans un ANN : couche d'entrée, couche cachée et couche de sortie. Les unités dans la couche cachée sont appelées unités cachées, car leurs valeurs ne sont pas observées. ANN est une technique d'intelligence basée sur un certain nombre neurones simples, comme le montre la figure II-6.




Figure II-6. Neurone humain et MLP avec deux couches cachées[Ruonan 18].

Les cercles étiquetés « +1 » sont des termes d'interception et sont appelés unités de biais. La figure II-6(a) est un neurone humain et la figure II-6(b) est un modèle simple d'ANN.

a_{ij} représente la $j^{\text{ième}}$ unité neuronale de la $i^{\text{ème}}$ couche.

Le « neurone » dans ANN est une unité de calcul qui prend en entrée x_1 ; x_2 ; x_3 et un terme d'interception. La sortie y peut être obtenu par :

$$y = f(W^T x) = f\left(\sum_{i=1}^3 W_i x_i + b\right) \quad (\text{II-17})$$

Où f est appelée fonction d'activation, souvent elle est choisie par la fonction sigmoïde ; W sont les paramètres du modèle ANN (ou les poids); b est un scalaire.

Un ANN interconnecte de nombreux « neurones » et la sortie d'un neurone peut être l'entrée d'un autre. Les poids W sont obtenus par une procédure d'apprentissage itérative,

Les RNA mettent en œuvre des algorithmes qui tentent d'atteindre une performance liée à la neurologie, tels que l'apprentissage par l'algorithme de retro-propagation.

II.3. Etat de l'art

II.3.1. SVM dans le diagnostic de panne :

La SVM est généralement utilisé en combinaison avec les techniques de traitement du signal pour l'extraction des indicateurs. De plus, en raison du manque de capacité d'extraction des indicateurs, la sélection du noyau est très importante sur la séparation des échantillons et les performances de classification.

Pour différents problèmes, plusieurs architectures et algorithmes SVM ont été développé dans la littérature.

Wu et Meng [Fengqi 07] ont appliqué SVM pour analyser les données expérimentales du spectre complet pour le diagnostic des dysfonctionnements du rotor, Le spectre complet peut également donner des indicateurs utiles pour SVM.

pour déterminer l'état des machines tournantes. Avec la transformée en ondelettes continue (CWT), SVM est Utilisé pour détecter les défauts de roulement des moteurs à induction [Konar 11] . Banerjee et Das [Banerjee 12] étudient une méthode hybride de classification des signaux de défaut basée sur la fusion des données des capteurs en utilisant les techniques SVM et STFT. Soualhi et al.[Soualhi 15] utilisent le HHT pour extraire les indicateurs des signaux de vibration des roulements; ensuite, les états de dégradation sont détectés par SVM.

L'efficacité de SVM a également été comparée à d'autres méthodes d'IA appliquées aux mêmes problèmes pratiques. En utilisant les caractéristiques du domaine temporel comme entrées, B. Samanta [Samanta 04] compare les performances de la détection des défauts d'engrenage en utilisant ANN et SVM : les résultats donnent la précision de classification de SVM par rapport à celle d'ANN.

Kankar et al. [Kankar 11] comparent l'efficacité d'ANN et de SVM pour le diagnostic des défauts des roulements, sur la base des caractéristiques statistiques. Avec la méthode de sélection des caractéristiques des ensembles approximatifs de voisinage du noyau.

II.3.2. ANN dans le diagnostic de panne :

De nombreux travaux de recherche ont montré que l'ANN possède une meilleure capacité de classification et de reconnaissance de formes. En conséquence, l'ANN est l'un des Classifieurs les plus couramment utilisés dans le diagnostic intelligent des défauts. Comme l'SVM, l'application d'ANN est également accompagnée d'extraction des indicateurs appropriés. Le perceptron multicouche (MLP) est un ANN constitué d'unités disposées en couches avec des connexions directes avec les unités des couches suivantes [Hu 01] qui a été utilisé dans plusieurs applications. Rafiee et al. [Rafiee 07] adoptent un réseau MLP avec une structure 16: 20: 5 de couches d'entrée-sortie-cachée pour la détection des défauts des boîtes de vitesses. L'écart type de signaux prétraités des ondelettes sont utilisés comme vecteurs d'indicateurs.

Sadeghian et al. [Sadeghian 09] Présentent un algorithme pour la détection de rupture barre de rotor d'un moteurs à induction, basée sur la combinaison de la décomposition en paquets d'ondelettes (WPD) et ANN. Bin et al. [Bin 12] utilisent les indicateurs extraits par WPT et EMD, en tant qu'entrées d'un réseau neuronal à trois couches de rétro propagation (BP) classique pour identifier la fissure latérale du rotor dans les machines tournantes.

Kankar et al. [Kankar 12] ont comparés les performances d'ANN et de l'SVM pour le diagnostic des défauts de roulement du rotor: les résultats expérimentaux indiquent que l'ANN a une précision de classification plus élevée que l' SVM dans les cas considérés dans cette étude.

II.3.3. ANFIS dans le diagnostic de panne :

Mahmood Moghadasian et al [Moghadasianet 17] utilisent les signaux de vibration d'un moteur à induction défectueux pour établir un système intelligent de diagnostic des défauts à l'aide du système d'inférence neuro-floue adaptatif (ANFIS).

El Ebrahimi et K Mollazade [Ebrahimi 10] étudient une méthode de Diagnostic des défauts du démarreur d'un tracteur agricole, basée sur des signaux de vibration et un système d'inférence neuro-floue adaptatif (ANFIS). Les conditions du démarreur à considérer étaient saines, fissure dans le corps du rotor, déséquilibre dans l'arbre et usure dans le roulement. Trente-trois paramètres statistiques des signaux de vibration dans les domaines temporel et fréquentiel ont été sélectionnés comme source des indicateurs pour le diagnostic des défauts, La performance du système a été validée en appliquant l'ensemble de données de test au modèle ANFIS formé. Selon le résultat, la précision totale de la classification était de 86,67.

II.4. Conclusion

Dans ce chapitre nous avons présenté la procédure de diagnostic des défauts basées sur les méthodes de l'intelligence artificielle.

Le diagnostic à base de ces méthodes nécessite le passage par plusieurs étapes, ses dernières ont été présenté, au cours de ce chapitre.

La première étape dans ces procédures est l'extraction de l'information complète à partir des signaux acquis sur les machines. Cette information nécessite un traitement afin de la

rendre exploitable par les techniques de classification et d'intelligence artificielle, l'étape suivante est la phase de décision. Ceci peut être fait par le biais de nombreuses techniques, notamment les ANN, les Classifieurs SVM, et l'ANFIS, ont été abordées.

Pour finir, une revue des travaux de recherches exploitant les différentes méthodes et techniques abordées ont été présentée, démontrant l'intérêt d'appliquer ces techniques de l'intelligence artificielle, et de les coupler avec les connaissances acquises en traitement du signal, pour la réalisation d'outils puissants et fiables de diagnostic des défauts.

Chapitre III. Diagnostic de défaut basé sur les Réseaux neuronaux convolutifs

Chapitre III. Diagnostic de défaut basé sur les Réseaux neuronaux convolutifs

III.1. Introduction

Ce chapitre présente la nouvelle technique développée pour la détection des défauts de roulements basé sur le réseau neuronal convolutif et l'imagerie du spectre du signal vibratoire, avec la technique de détection basé sur le réseau neuronal convolutif et le signal vibratoire temporelle. Le but de l'étude est d'examiner ces techniques et en explorer les capacités, avantages par rapport aux techniques basé sur l'intelligence artificielle.

Et à la fin de ce chapitre, nous allons présenter une étude bibliographique sur la surveillance des défauts basés sur les réseaux neuronaux convolutifs.

III.2. Intérêt de l'utilisation des réseaux neuronaux convolutifs

Afin d'assurer un diagnostic automatique de défauts des machines tournantes, les méthodes de classification intelligentes telles que les réseaux de neurones artificiels (ANN) et les machines à vecteurs de support (SVM) sont avérées efficaces. Cependant, ces méthodes présentent des inconvénients inhérents [Shao 18] :

- La performance de la procédure de diagnostic de la plupart de ces méthodes traditionnelles dépend fortement de la qualité des indicateurs sélectionnés. De plus, les défauts non stationnaires comme les défauts de roulements et engrenages présentent souvent non seulement un défaut unique mais également des défauts combinés. Ainsi, les techniques avancées de traitement du signal doivent être mises en œuvre pour une reconnaissance ou une classification efficace des défauts.
- Dans la plupart des cas, la sélection des indicateurs dépend largement de l'expérience technique des experts en diagnostic.
- Les Classifieurs ANN et SVM appartiennent à des modèles d'apprentissage ce qui rend les relations complexes non linéaires difficiles à apprendre.
- Le signal vibratoire brut est ignoré après la phase de calcul des indicateurs alors qu'il a masqué des informations immergées.

Par conséquent, il est urgent de construire des architectures profondes pour effectuer un diagnostic de panne intelligent et efficace.

Le Deep Learning est une méthode d'apprentissage automatique récente qui a la capacité d'apprendre à partir des données brutes. Les modèles d'apprentissage profond ont la capacité d'éliminer la dépendance à l'égard des connaissances antérieures des techniques avancées de traitement du signal pour le calcul et la sélection des indicateurs.

III.3. Réseau neuronal convolutif (CNN)

Le CNN est un type de réseau de neurones profonds qui se caractérise par une structure de neurones dont les poids et les biais sont ajustables par apprentissage. Un certain nombre de structures CNN ont été développées dans plusieurs applications telles que le traitement d'image, la reconnaissance de forme et l'analyse vidéo qui ont démontré l'efficacité du modèle CNN [Matsugu 03, Xie 17, Dekhane 20].

Une structure CNN se compose de trois types principaux de couches : (i) couches convolutionnelles, (ii) couches de sous-échantillonnage, et (iii) une couche de sortie avec une fonction de perte telle que SVM ou *softmax* Classifieur. Les couches du réseau sont disposées selon une structure à action directe, chaque couche de convolution est suivie d'une couche de sous-échantillonnage et la dernière couche de convolution est suivie de la couche de sortie (voir Figure III-1).

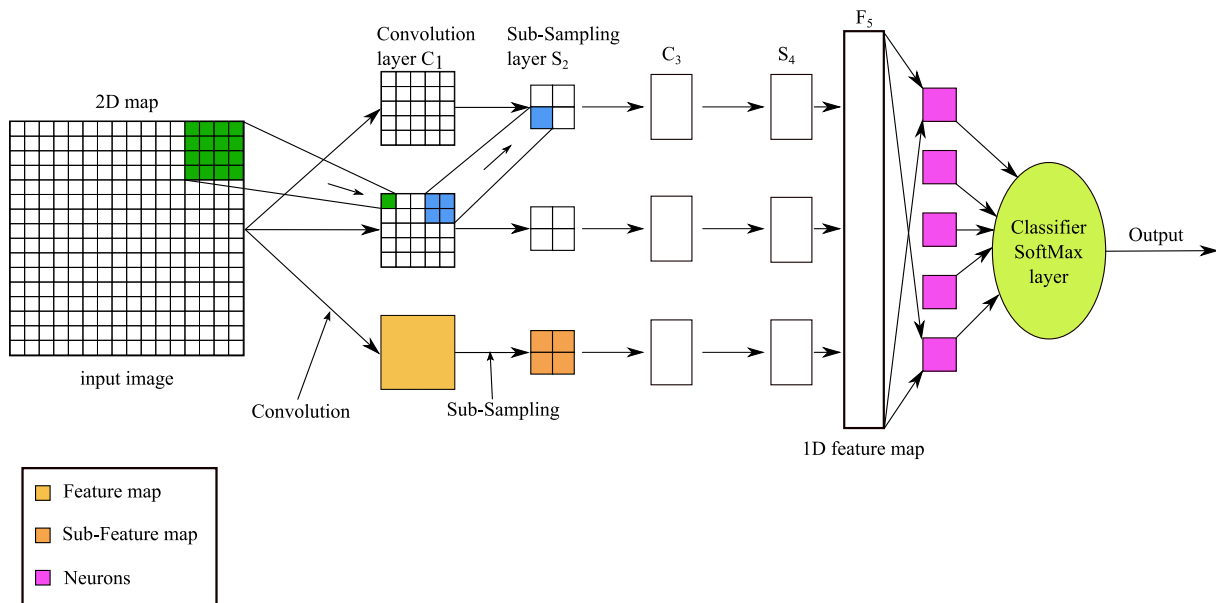


Figure III-1. Architecture du réseau neuronal convolutif (CNN).

Le signal d'entrée d'une couche convolutionnelle a une taille de $M \times N \times r$, où M est la hauteur et N est la largeur du signal d'entrée, et r le nombre d'images. Une couche convolutive a k noyaux de taille $n \times n$ où n est généralement beaucoup plus petit que la taille du signal d'entrée. Les noyaux sont convolutés en utilisant le signal et on obtient des cartes de k indicateurs (features) avec une taille de $M-n + 1$. Il existe principalement deux types de couches de mise en commun (pooling layers) qui sont la couche de la mise en commun maximale et la couche de la mise en commun moyenne. Une couche de sous-échantillonnage (sub-sampling) opère dans $p \times p$ régions voisines des cartes des caractéristiques de la couche convolutionnelle et réduit ainsi les calculs.

Un réseau neuronal convolutif CNN utilise des algorithmes de propagation en avant ou en arrière comme dans les structures des réseaux de neurones.

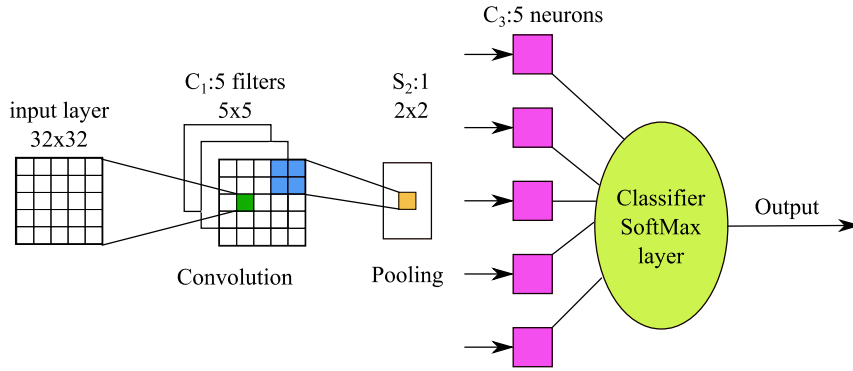


Figure III-2. Structure du réseau neuronal convolutif utilisé dans ce travail.

Dans la couche de convolution, les cartes d'indicateurs peuvent être obtenues en utilisant différents noyaux. Les sous-cartes d'indicateurs sont obtenues par convolution de plusieurs cartes d'indicateurs en entrée. Le processus de calcul est indiqué comme suit :

$$x_j^l = f \left(\sum_{i \in M_j} x_i^{l-1} * w_{ij}^l + b_j^l \right) \quad (\text{III-1})$$

Où M_j représente la sélection des cartes d'indicateurs en entrée; l est la $l^{\text{ième}}$ couche du réseau, w est le filtre convolutionnel reliant la $(l-1)^{\text{ième}}$ couche à la $l^{\text{ième}}$ couche, et x_i^{l-1} représente la carte d'indicateurs générée à partir de la $(l-1)^{\text{ième}}$ couche. b est un biais additif donné à chaque carte de sortie. f est une fonction d'activation non linéaire. La fonction d'activation non linéaire traditionnelle d'un réseau neuronal est la fonction sigmoïde ($f(x) = 1 / (1 + e^{-x})$), mais en raison de ses inconvénients, une nouvelle fonction d'activation appelée fonction Relu (unités linéaires rectifiées) est généralement utilisée. Dans les méthodes d'apprentissage en profondeur, l'expression de la fonction Relu est donnée par $f(x) = \max(0, x)$. En plus pour résoudre le problème de l'élimination du gradient lors des étapes de propagation pendant l'apprentissage du réseau neuronal, la quantité de calculs serait beaucoup moins importante en utilisant la fonction Relu [LeCun 15]. Les sorties de certains neurones seraient nulles à l'aide de la fonction Relu, ce qui conduit à une faible densité du réseau et évite le problème de surajustement.

Une couche de sous-échantillonnage est calculée comme suit :

$$x_j^l = f(\beta_j^l \cdot \text{down}(x_j^{l-1}) + b_j^l) \quad (\text{III-2})$$

Où les biais β et b sont les biais multiplicatifs et additifs respectivement, avec $\text{down}(\cdot)$ Représente une fonction de sous-échantillonnage. Dans l'étape de rétropropagation, le gradient de la fonction de perte de tous les poids dans toutes les couches est calculé en utilisant l'algorithme de rétropropagation.

L'erreur quadratique moyenne (MSE) de la couche de sortie est exprimée comme suit :

$$E^n = \sum_{k=1}^m (l_k^n - y_k^n)^2 \quad (\text{III-3})$$

L'objectif est de minimiser l'erreur en réduisant les paramètres du réseau. Dans notre approche, la structure CNN se compose de couches convolutives et de couches de sous-échantillonnage (voir Figure III-2).

III.4. L'approche proposée

Dans cette partie on a proposé une nouvelle méthode de classification de défauts basés sur le réseau neuronal convolutif (CNN) et l'imagerie du spectre vibratoire (VSI).

Dans la méthode proposée, le signal de vibration temporelle est divisé en segments de taille fixe W afin de calculer le contenu spectral en utilisant la transformée de Fourier rapide (FFT) de chaque fenêtre segmentée.

Le contenu spectral de chaque segment temporel est ensuite normalisé et converti pour former les images spectrales utilisées comme données d'apprentissage et de test du Classifieur CNN (Convolutional Neural Network).

Cette approche comprend les étapes suivantes:

- **Étape 1** : collecte des données de vibration.
- **Étape 2** : Segmentation du signal vibratoire temporelle en segments de taille fixe W .
- **Étape 3** : Construction des images spectrales en utilisant la FFT du signal segmenté.
- **Étape 4** : Faire l'apprentissage du Classifieur CNN et le test à l'aide des données sélectionnées.

Les étapes sont illustrées à la Figure III-3.




Figure III-3. Organigramme de l'algorithme de classification proposé.

III.4.1. Segmentation temporelle

Dans la deuxième étape, le signal de vibration brut est segmenté dans le temps. Le signal de vibration est divisé en segments temporels à l'aide d'une fenêtre rectangulaire fixe W . Ces signaux de vibration segmentés dans le temps sont ensuite utilisés pour obtenir le contenu spectral.

Pour un signal X de longueur L, avec une taille de fenêtre d'échantillons W, il existe r exemples d'images pour l'apprentissage et le test, la formule de segmentation est donnée par :

$$r = \frac{L}{W} \quad (\text{III-4})$$

III.4.2. Image spectrale

La transformée de Fourier rapide (FFT) est appliquée aux données de vibration de chaque segment dans le temps, le contenu spectral de chaque segment d'échantillon est normalisé entre 0 et 1 et l'amplitude normalisée devient l'intensité correspondante pour chaque pixel de l'image spectrale avec une taille de $M \times N$. La conversion de l'amplitude normalisée de chaque échantillon et du pixel correspondant est décrite par l'équation (3.5) [Nguyen 13] suivante :

$$P[i, j] = A[(i - 1) * M + j], \text{ où } i = 1:N; j = 1:M \quad (\text{III-5})$$

Où P [i, j] est l'intensité de gris (niveau de gris) du pixel (i, j) de l'image spectrale qui est convertie à partir du signal vibratoire de taille $M \times N$ et A [.] est l'amplitude normalisée pour chaque échantillon de la FFT du signal vibratoire.

Le nombre de pixels de l'image spectrale est égal au nombre d'échantillons de la FFT du signal vibratoire.

Chaque image spectrale contient $M \times N$ pixels et le nombre de pixels pour chaque image est égal au nombre d'échantillons de la fenêtre mobile W. La Figure III-4 montre les échantillons du spectre de différents états de fonctionnement avec les images correspondantes, on remarque une différence entre les images qui indiquent les différents modes de fonctionnement.

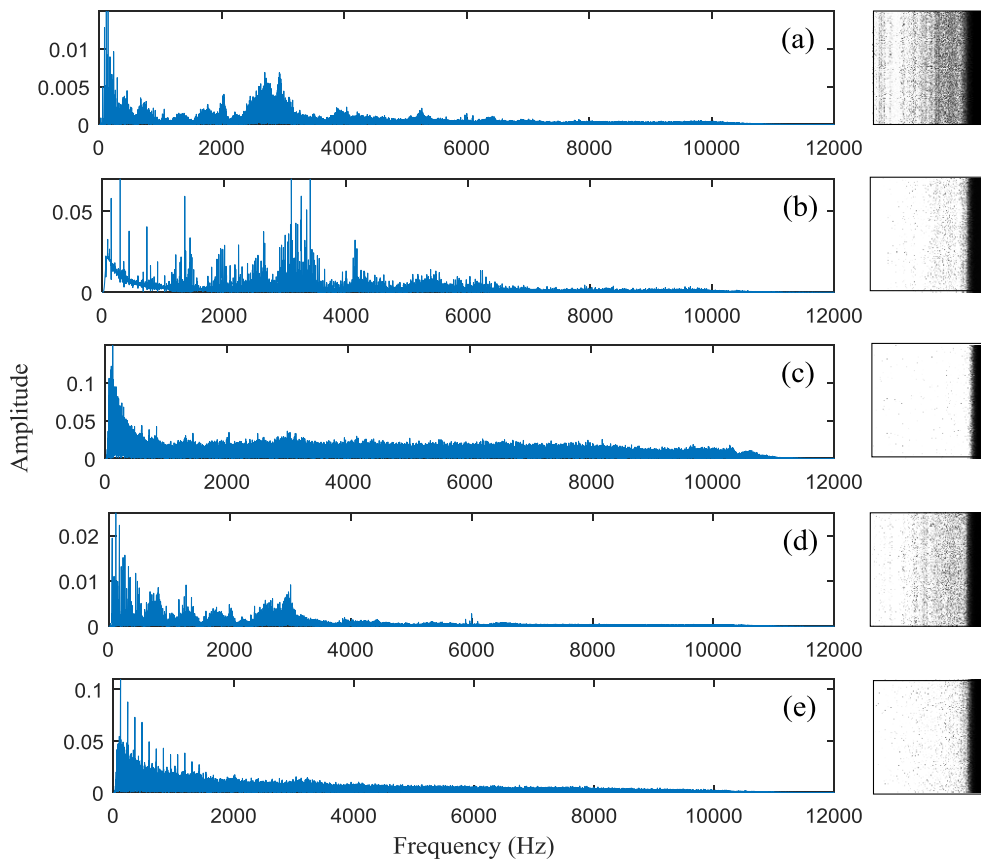


Figure III-4. Spectres et images FFT correspondantes des signaux de vibration après conversion sous la vitesse 30 Hz

(a) sain, (b) défaut de cage externe, (c) défaut de bille, (d) défaut de cage interne, (e) défaut combiné.

III.5. Classification de défauts basés sur CNN avec le signal temporele

Dans cette méthode, le signal de vibration temporelle est divisé en segments de taille fixe W afin de construire les images vibratoires de chaque fenêtre segmentée.

Le contenu des signaux de vibration de chaque segment en temps est ensuite normalisé et converti pour former les images vibratoires utilisées comme données d'apprentissage et de test d'un Classifieur CNN (Convolutional Neural Network).

Cette approche comprend les étapes suivantes :

- **Étape 1** : La collecte des données de vibration.
- **Étape 2** : Segmentation temporelle du signal de vibration brut en segments de taille fixe.
- **Étape 3** : Construction des images vibratoires du signal segmenté.
- **Étape 4** : Formation du Classifieur CNN et tests à l'aide des données de test sélectionnées.

Les étapes sont illustrées sur la Figure III-5

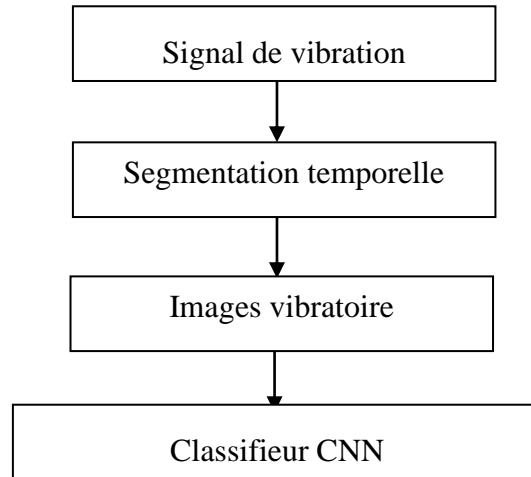


Figure III-5. Organigramme de l'algorithme de classification.

III.5.1. Segmentation temporelle

Cette partie est bien présentée dans la section 3.4.1

III.5.2. Construction de l'image vibratoire

Les signaux de vibrations de chaque segment sont normalisés entre 0 et 1 et l'amplitude normalisée devient l'intensité en pixels correspondante des images de vibrations de taille $M \times N$. La conversion en amplitude normalisée de chaque échantillon et du pixel correspondant est calculée comme suit :

$$P [i, j] = A [(i-1) * M + j], \text{ où } i = 1: N; j = 1: M \quad (\text{III-6})$$

Où $P [i, j]$ est l'intensité grise du pixel (i, j) des signaux de vibration qui est convertie à partir du signal vibratoire temporel de taille $M \times N$ et $A [.]$ et l'amplitude normalisée de chaque segment du signal vibratoire. Le nombre de pixels de l'image des signaux de vibration obtenus est égal au nombre d'échantillons du signal vibratoire.

Chaque image contient $M \times N$ pixels et le nombre de pixels pour chaque image est égal au nombre d'échantillons de la fenêtre.

III.6. Etat de l'art

Récemment, différents modèles d'apprentissage en profondeur ont été progressivement appliqués au diagnostic intelligent de défauts [Jia 16]. La technique Denoising Auto-Encoder (DAE) utilise une méthode d'apprentissage simple et purement non supervisée. Elle permet l'élimination de l'effet du bruit de fond et la reconstruction des données vibratoires originales.

Le réseau neuronal convolutif (CNN) est un réseau neuronal structuré en profondeur qui est principalement utilisé dans les applications de traitement d'image. Comme d'autres structures de réseaux de neurones, le CNN est construit en utilisant un certain nombre de neurones, qui sont organisés en tant que reflet de différents chevauchements à travers le champ.

Dans [Zhi Qiang 15] Une implémentation de l'algorithme d'apprentissage en profondeur du réseau de neurones convolutionnels (CNN) est utilisée pour l'identification et la classification des défauts dans les boîtes de vitesses ; Les signaux de vibration sont prétraités à l'aide des mesures statistiques du signal de vibration dans le domaine temporel telles que l'écart type, asymétrie et kurtosis. Dans le domaine fréquentiel, le spectre du signal vibratoire obtenu avec la FFT est divisé en plusieurs bandes, et la racine de la valeur quadratique moyenne (RMS) est calculée pour chacun afin que l'énergie conserve sa forme aux pics du spectre. La précision obtenue par cette méthode indique qu'elle est fiable et applicable au diagnostic des défauts dans les boîtes de vitesses des machines alternatives industrielles.

Dans le travail de [Janssens 16], un modèle d'apprentissage des indicateurs est proposé pour la surveillance de l'état des machines tournante basé sur les réseaux de neurones convolutionnels. Le but de cette approche est de trouver les indicateurs utiles pour détecter les défauts à partir des données elles-mêmes. Plusieurs types de défauts de roulement tels que les défauts de la cage externe, la dégradation de la lubrification, et un déséquilibre du rotor. En outre, l'approche basée sur l'apprentissage des indicateurs est comparée à une approche basée sur l'ingénierie des indicateurs utilisant les mêmes données pour quantifier leurs performances. Les résultats indiquent que le système d'apprentissage des indicateurs, basé sur les réseaux de neurones convolutionnels, surpasse considérablement l'approche classique basée sur l'ingénierie des indicateurs qui utilise des indicateurs conçues manuellement avec un Classifieur de forêt aléatoire. Le premier atteint une précision de 93,61 pour cent et ce dernier une précision de 87,25 pour cent.

Le réseau de neurone convolutionnel a été appliqué pour la classification de défauts de roulement dans le domaine temporel à l'aide de l'ensemble de données des signaux vibratoires Case Western Reserve University [Hoang 17]. Le diagnostic de défaut utilisant CNN est basé sur la normalisation du signal vibratoire brut et sa conversion en image 2D, l'apprentissage du réseau est supervisé et il est réalisé par l'introduction d'images en entrée avec les classes souhaitées correspondantes. Cette méthode ne nécessite pas l'extraction des indicateurs ni le processus de sélection et donne une bonne précision dans la classification de défauts.

Cependant, les signaux de vibration changent constamment d'emplacement dans la fenêtre du domaine temporel en raison de la taille non synchronisée de la fenêtre avec les vibrations périodiques.

Dans [Xu 19], les auteurs ont utilisé la transformation en ondelettes continue (CWT) des données vibratoires brutes avant de transformer le signal en images 2D qui sont transmises à un Classifieur d'apprentissage profond combiné à l'approche d'apprentissage d'ensemble forestier aléatoire. D'autre part, la transformée de Fourier (FFT) a l'avantage de représenter directement les signaux de vibration se déplaçant dans le temps sous forme de spectre invariant par translation. Ces modèles invariants peuvent être traités et utilisés comme entrées directes dans un Classifieur pour la formation et le test [Amar 15]. Comme la transformée de Fourier FT ne s'applique pas à un signal vibratoire non stationnaire, elle est appliquée à une fenêtre glissante dans le signal qui est considérée comme stationnaire.

Amar et al. [Amar 15] a conçu un réseau de neurones artificiels (ANN) comme Classifieur de défauts à l'aide d'images de l'amplitude normalisée calculée à partir du contenu spectral des signaux de vibration temporelle segmentés par une fenêtre mobile de taille fixe. Un filtre de moyenne 2D et une conversion d'image binaire, avec une sélection de seuil appropriée, sont utilisés pour filtrer et améliorer les images pour la formation et le test du Classifieur ANN. Cette méthode augmente la précision de la représentation visuelle des caractéristiques spectrales de vibration sous forme d'image. Ces images spectrales améliorées sont appliquées pour la formation d'un ANN et fournissent un Classifieur de défauts robuste en présence de données bruyantes.

Cependant, l'utilisation d'ANN présente plusieurs inconvénients pour le traitement d'image. La connexion totale des neurones avec la couche précédente et suivante se traduit par une croissance exponentielle du nombre de neurones aux dimensions de l'image. Les réseaux de neurones CNN permettent de résoudre un tel problème avec une réduction du nombre de paramètres à apprendre [Liu 18].

A. Youcef Khodja et al [Youcef Khodja 20] ont proposé une nouvelle méthode pour la classification des défauts de roulement en utilisant un réseau neuronal convolutionnel (CNN) et l'imagerie du spectre vibratoire (VSI). Les amplitudes normalisées du contenu spectral extrait des signaux vibratoires temporels segmentés à l'aide d'une fenêtre de segmentation à déplacement temporel sont transformées en images spectrales pour l'apprentissage et le test du Classifieur CNN. Pour montrer l'efficacité de la méthode proposée, des données vibratoires pour des roulements sains et défectueux fonctionnant à différentes vitesses sont collectées à partir d'un banc d'essai expérimental. La précision de la classification, les tests de charge et de vitesse variables, la généralisation et la robustesse en ajoutant du bruit aux données collectées à différents niveaux (SNR) sont ensuite évalués. Les résultats de classification expérimentaux obtenus montrent l'excellente performance en termes de précision et de robustesse. La segmentation temporelle avec l'application de l'FFT élimine l'effet du bruit de mesure et fournissent une classification robuste en ce qui concerne les variations de vitesse. La conversion du signal unidimensionnel en une image 2D avec la combinaison des capacités d'apprentissage en profondeur du Classifieur de réseaux neuronal CNN fournit un système de reconnaissance de modèle robuste capable de distinguer les variations dues à divers types de défauts de roulement.

III.7. Conclusion

Dans ce chapitre, nous avons présenté les inconvénients des Classifieurs basés sur l'intelligence artificielle, et les Intérêts de l'utilisation des Réseau neuronal convolutif (CNN) dans le processus de classification des défauts.

Une nouvelle méthode de classification de défauts basés sur le réseau neuronal convolutif (CNN) et l'imagerie du spectre vibratoire (VSI) ; Les amplitudes normalisées du contenu spectral extrait des signaux vibratoires temporels en utilisant une fenêtre glissante sont transformés en images spectrales pour L'apprentissage et le test du Classifieur CNN.

Ainsi, que la méthode de classification de défauts basés sur le réseau neuronal convolutif et l'imagerie des signaux vibratoire temporelle sont présentée.

A la fin de ce chapitre, une étude bibliographique sur l'utilisation des méthodes de classification basée sur le réseau de neurone convolutionnel est traitée.

Chapitre IV. Applications des approches intelligentes au diagnostic des défauts de roulements

Chapitre IV. Applications des approches intelligentes au diagnostic des défauts de roulements

IV.1. Introduction

Les roulements sont les composants les plus fondamentaux et les plus importants des machines tournantes. Les défauts de roulement sont considérés comme la source de défaillance la plus courante dans les machines tournantes, leur pourcentage varie entre 40% et 90% [Immovilli 09].

Pour montrer l'efficacité des méthodes de classification, on s'appuie sur des données réelles extraites des bancs d'essai. Ces données vibratoires sont collectées pour des roulements sains et défectueux fonctionnant à différentes vitesses et charges.

Pour nos applications, ce banc d'essai nous permet de simuler entre autres, plusieurs modes de fonctionnement correspondant aux classes étudiées, on l'occurrence, la classe en fonctionnement normal, la classe de fonctionnement avec un défaut cage interne, la classe de fonctionnement avec un défaut de billes, la classe de fonctionnement avec un défaut de la cage externe, et la classe de fonctionnement avec un défaut combiné.

Ce chapitre se compose de deux grandes parties :

Dans la première partie on traitera des données expérimentales relevées sous forme de signaux vibratoires de roulements sur le banc d'essai du laboratoire URMA/CRTI. On appliquera à titre comparatif les différentes techniques de classification intelligentes présentées au chapitre II, et en particulier celle basée sur le Classifieur CNN. Les résultats obtenus seront comparativement analysés et présentés.

Dans la deuxième partie on traitera des données fournies par la banque de données « **Case Western Reserve University** » (CWRU) sous forme de signaux vibratoires de roulements. Dans cette partie les résultats obtenus pour la classification des défauts de roulement basé sur le Deep Learning, et une comparaison avec des méthodes prises de la littérature seront présentés.

IV.2. Défauts de roulement

Les roulements sont des composants fondamentaux des machines tournantes, dont l'objectif est de supporter l'arbre rotatif.

Un roulement se compose de quatre composants de base, la bague extérieure, la bague intérieure, les éléments roulants qui sont les billes à l'intérieur de la cage et le dispositif de retenue ou la cage. Les billes sont délimitées par la cage, ce qui garantit une distance uniforme entre les billes et empêche les contacts bille à bille. Ces éléments roulants sont toujours en contact métal sur métal avec les chemins de roulement intérieur et extérieur et sont donc soumis à une usure constante. L'usure des roulements et des chemins de roulement présente initialement une rugosité générale et évolue vers la fatigue du métal, et finalement l'écaillage de la surface des éléments roulants.

➤ **Signatures de vibration des défauts de roulement :**

Classiquement ce type de défaut est diagnostiqué à partir du spectre d'une mesure acoustique ou vibratoire. Mais d'abord, nous rappelons qu'il existe quatre types de défauts de roulement à savoir un défaut de bague externe, défaut de bague interne, défaut de bille ou défaut de la cage reliant les éléments roulants. En analyse vibratoire chaque type de défaut a sa propre signature est caractérisé par une fréquence fondamentale ; il est donc possible d'observer certaines bandes de fréquences et de les identifier. Les expressions de ces fréquences caractéristiques, lorsque la piste externe est fixe, sont données par :

$$Cage F_C = \frac{1}{2} F_R \left(1 - \frac{D_b \cos \beta}{D_p} \right) \quad (4.1)$$

$$Bague\ externe\ F_O = \frac{N_B}{2} F_R \left(1 - \frac{D_b \cos \beta}{D_p} \right) \quad (4.2)$$

$$Bague\ interne\ F_I = \frac{N_B}{2} F_R \left(1 + \frac{D_b \cos \beta}{D_p} \right) \quad (4.3)$$

$$Bille\ F_B = \frac{D_p}{D_b} F_R \left[1 - \left(\frac{D_b \cos \beta}{D_p} \right)^2 \right] \quad (4.4)$$

où F_R est la fréquence mécanique du rotor, N_B est le nombre d'éléments roulants, D_p est le diamètre moyen du roulement (pitch diamètre), D_b est le diamètre de la bille, et β l'angle de contact de l'élément roulant. Voir la Figure IV-1.

Par conséquent, ces fréquences de défaut sont en fonction de la géométrie du roulement, du nombre d'éléments roulants et de la vitesse rotationnelle du roulement.




Figure IV-1. Les diamètres PD, BD, et l'angle de contact d'un élément roulant.

A titre d'exemple la Figure IV-2 présente des signaux vibratoires et les spectres correspondant relevés sur le banc d'essai URMA/CRTI.

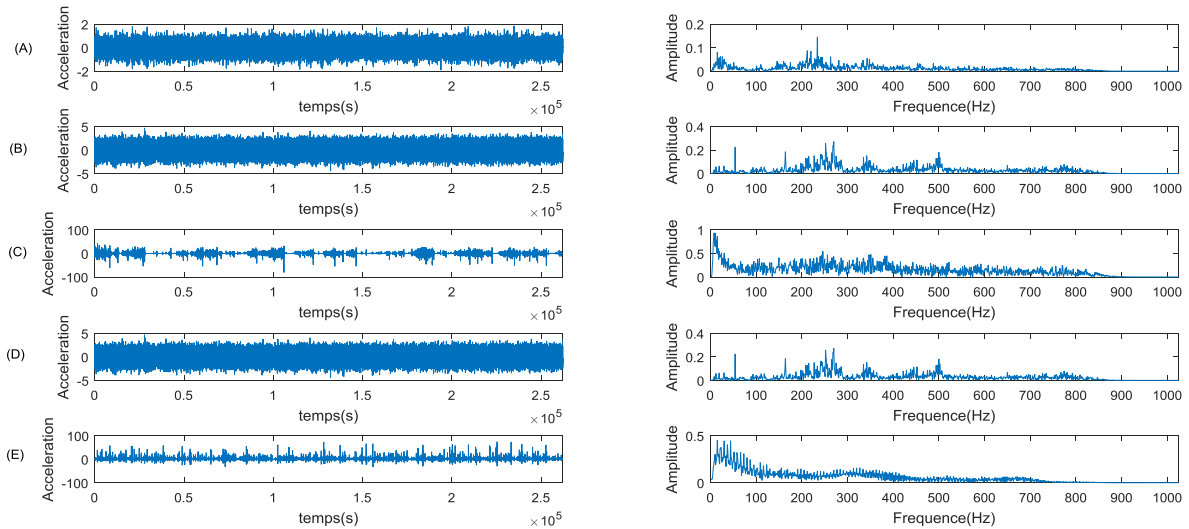


Figure IV-2. Les signaux vibratoires de défauts de roulement et les spectres correspondants

La Figure IV-2 illustre les signaux vibratoires de défauts de roulement et les spectres correspondants relevés du banc d'essai URMA/CRTI. Les figures à gauche représentent les signaux vibratoire temporel du roulement sain et en défaut, les figures à droite représentent les spectres correspondants. (A) signal vibratoire temporelle du roulement sains et son spectre, (B) signal vibratoire temporelle du défaut de cage externe et son spectre, (C) signal vibratoire temporelle du défaut de bille et son spectre, (D) signal vibratoire temporelle du défaut de cage interne et son spectre, (E) signal vibratoire temporelle du défaut combiné et son spectre.

IV.3. Première partie : Classification des données relevées sur le banc d'essai URMA / CRTI

Afin de valider l'efficacité des méthodes de classification, les données de vibrations des roulements analysés dans cette étude sont fournies par le banc d'essai de l'Unité de Recherche en Matériaux Avancés URMA / CRTI qui est présenté par les Figure IV-3, et Figure IV-4.




Figure IV-3. Configuration expérimentale d'acquisition de données.

Le banc d'essai se compose d'un moteur à induction triphasé de 0,37 kW, d'un variateur de vitesse, des roulements dans différents états. Le roulement testé est inséré sur l'arbre du moteur côté entraînement, trois accéléromètres industriels de type ICP (CTC AC 140 2D) avec une sensibilité de 100 mV / g sont utilisés. Un variateur de vitesse de marque Lenze ESV371N01SX contrôle la vitesse du moteur à courant alternatif. Le signal de vibration est acquis pour les vitesses suivantes : 30, 35, 40, 45 et 50 Hz. Les données du signal de vibration sont analysées et stockées à l'aide du logiciel VibraQuest (VQ -DT8) avec une fréquence d'échantillonnage de 25,6 kHz et un temps d'acquisition de 10 secondes pour chaque condition de fonctionnement.



Figure IV-4. Banc d'essai expérimental utilisé dans ce travail.

Les roulements de type EKR-12 3/4 pouce sont utilisés dans différentes conditions. Leurs spécifications techniques sont données dans le Tableau IV-1.

Tableau IV-1. Spécifications techniques des roulements.

Modèle du Roulement	Diamètre de la cage interne (mm)	Diamètre de la cage externe (mm)	Diamètre de la bille (mm)	L'angle du contact (degré)
ER12K-0114	29.31	47.00	7.93	0°

Les défauts de roulement considérés couvrent les défauts de la bague extérieure, de la bague intérieure, de la bille et du défaut combiné. Les défauts ont été introduits par Electrical Discharge Machining EDM. La Figure IV-5 montre les types considérés des roulements défectueux. Les conditions de fonctionnement des roulements testés sont répertoriées dans le tableau IV-2.




Figure IV-5. Roulements défectueux utilisés dans ce travail

(a) défaut de cage interne, (b) défaut de bille, (c) défaut de cage externe, (d) défaut combiné.

Tableau IV-2. Description des conditions de fonctionnement des roulements sains et défectueux.

CONDITION DES ROULEMENTS	CLASSES
SAIN	1
CAGE EXTERNE	2
BILLE	3
CAGE INTERNE	4
DEFAUT COMBINE	5




Figure IV-6. Signaux de vibration temporelle des roulements sains et défectueux sous différentes vitesses de fonctionnement.

Le signal de vibration de chaque condition est collecté sous différentes vitesses de fonctionnement. Chaque condition contient 262144 échantillons.

La Figure IV-7 montre les formes d'onde brutes des cinq conditions à différentes vitesses: 30,35,40,45,50 Hz qui sont très difficiles à classer. Cette figure montre les signaux de vibrations temporelles bruts par rapport au temps d'acquisition à la vitesse de fonctionnement de 45 Hz.

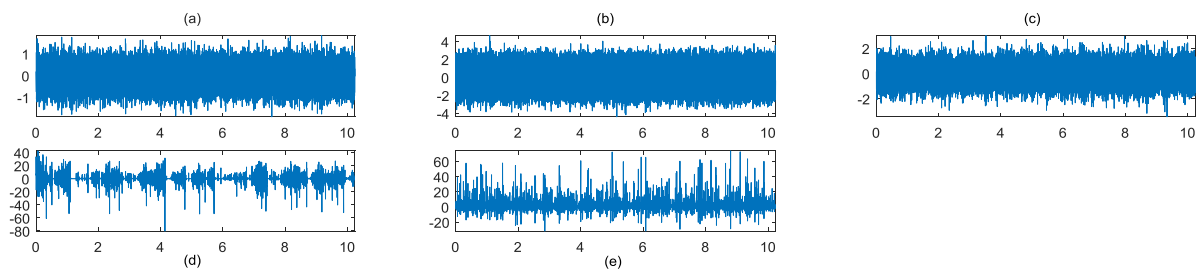


Figure IV-7. Données de vibration temporelle à 45 Hz:

(a) roulements sains, (b) défaut de cage externe, (c) défaut de bille, (d) défaut de cage interne, (e) défaut combiné.

IV.4. Diagnostic de défauts par les techniques de l'intelligence artificielle

Dans cette première étape, nous allons appliquer trois techniques de classification basées sur l'intelligence artificielle qui sont : le « Réseau neuronal artificiel » ou ANN, « Machine à vecteur de support » ou SVM, et le « Système neuro-flou adaptatif » ou ANFIS pour la classification des données relevées sur le banc d'essai présenté ci-dessus.

Le signal de vibration pour chaque condition sous différentes vitesses contient 262144 échantillons est divisé en m sous-ensembles de taille $n=1500$ échantillons pour le calcul des indicateurs.

Après la segmentation du signal vibratoire on trouve $262144/1500=174$ sous-ensembles pour le calcul des indicateurs. Pour chaque sous ensemble on calcule les six indicateurs suivants : le facteur de crête, le kurtosis, la mesure d'asymétrie (skewness), le maximum, le minimum, et la valeur efficace (RMS).

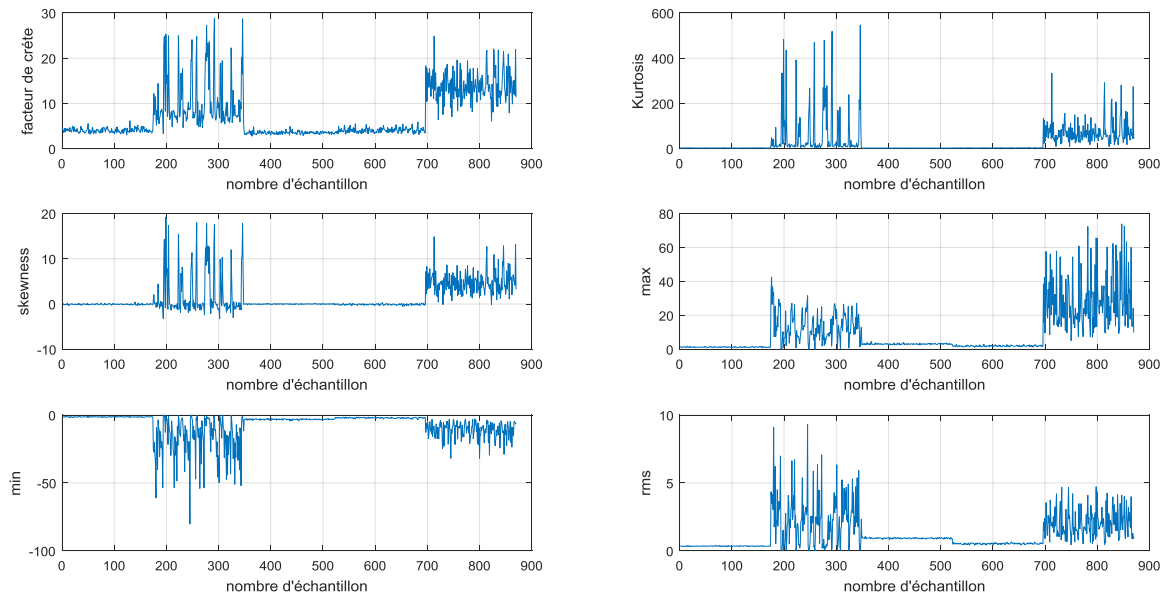


Figure IV-8. les tracés des indicateurs extraits des signaux de vibration pour les cinq classes de défauts (pour la vitesse 45hz avec une taille du segment $n=1500$ échantillons).

La **figure IV-8** montre les tracés des indicateurs extraits des signaux de vibration pour les cinq classes de défauts (pour la vitesse 45hz avec une taille $n=1500$ échantillons).

Les indicateurs extraits des différents signaux ont été utilisés pour entraîner les Classifieurs ANN, SVM, et ANFIS afin de classifier chaque défaut de roulement.

IV.4.1. Classification de défauts de roulement en utilisant l'ANN :

L'ensemble de ces 174 groupes d'indicateurs, est divisé en deux sous-ensembles l'un pour l'apprentissage, et l'autre pour le test. Le réseau neuronal se compose de couches, une couche d'entrée, deux couches cachées et une couche de sortie,

La couche d'entrée a autant de nœuds que le nombre d'indicateurs calculés.

Le nombre de neurones dans la couche cachée est varié de 50 à 60 selon la taille de la fenêtre glissante et la vitesse de rotation. Le nombre de neurones de la couche de sortie est de cinq.

La structure de l'ANN dans l'exemple de la vitesse 45hz est : 6 :60 :10 :5. Les chiffres représentent le nombre de neurones dans l'entrée, la première couche cachée, la deuxième couche cachée et la couche de sortie, respectivement.

L'ANN a été entraînée et mis en œuvre à l'aide de la boîte à outils Neural Networks de MATLAB en utilisant l'algorithme de rétropropagation de Levenberg–Marquardt.

Pour l'apprentissage, une erreur quadratique moyenne (MSE) de 0.1, avec un gradient minimum de 1.93 et un nombre maximal d'itérations (époque) de 39 à 112 ont été utilisés. Le processus d'apprentissage s'arrêterait si l'une de ces conditions était remplie. Les poids et les biais du réseau de neurone ont été générés automatiquement par le programme.

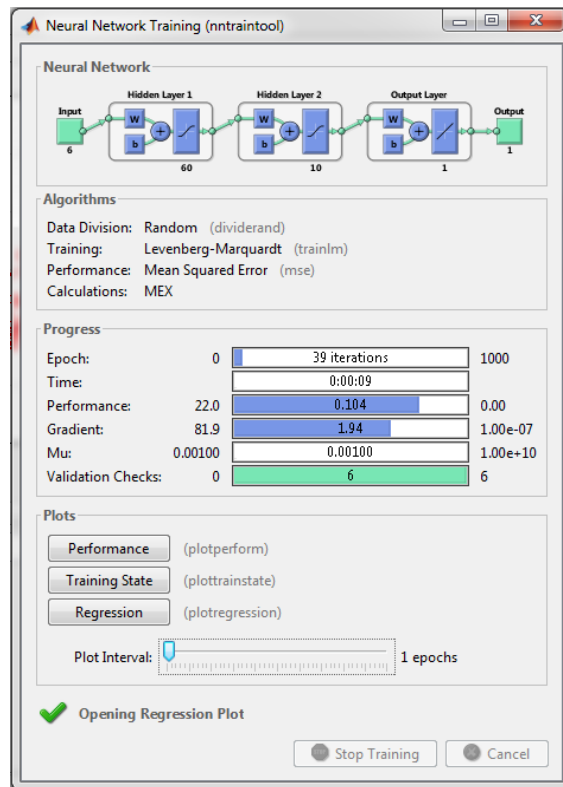
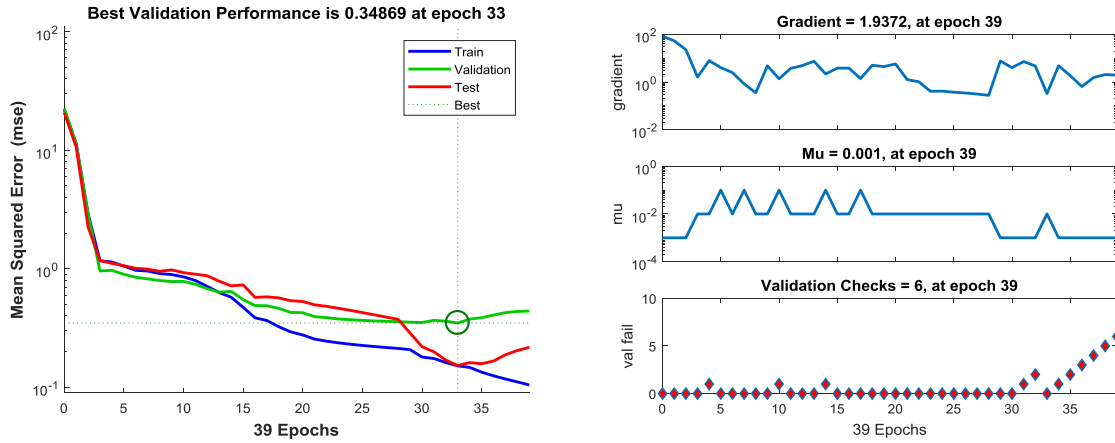


Figure IV-9. Les paramètres du réseau de neurone utilisé dans cette étude a la vitesse 45Hz.

La figure IV-9 montre les paramètres du réseau de neurone utilisé dans cette partie a la vitesse 45Hz.

Après l'apprentissage, la structure de l'ANN conçu a été testé par les signaux vibratoire sain et avec défauts pour différentes vitesses de fonctionnement 30, 35, 40, 45,50Hz.

Les résultats obtenus sont acceptables avec un taux de classification entre 71.72% à 87.81%. Les résultats sont résumés dans le Tableau IV-3 et la Figure IV-10




Figure IV-10. Le résultat de classification par ANN pour la vitesse 45Hz.

Tableau IV-3. Résultats de précision pour chaque vitesse de fonctionnement du Classifieur ANN

Vitesse(Hz)	% de classification du Classifieur (ANN)
30	71.72
35	72.18
40	82.41
45	87.12
50	87.81

IV.4.2. Classification de défauts de roulement en utilisant l'SVM :

Dans cette étude, des Fonctions Radiale de Base RBF sont utilisé comme noyau des SVM. Deux paramètres sont associés à ces noyaux : C et ξ_i . La borne supérieure C et le paramètre du noyau ξ_i , ces paramètres jouent un rôle crucial dans les performances des SVM. Par conséquent, une mauvaise sélection de ces paramètres peut provoquer un problème de surajustement ou de sous-ajustement.

Dans ce travail, nous avons choisi les paramètres de classification C = 20000 et $\xi_i = 0.5$ et nous avons utilisé des Fonctions RBF de type gaussien avec un nombre Kernel=95. Le choix de ces paramètres a été fait d'une manière heuristique.

Le processus d'apprentissage et de classification est basée sur les SVM multi-classes. Premièrement, La classification par SVM est formée par les 116 données qui sont calculé à partir des six indicateurs.

Deuxièmement, nous avons testé le Classifieur SVM par les 58 donné resté, les résultats de classification des défauts sont présentés dans le tableau 4.4 et les figures 4.11.

Dans ce tableau, nous avons obtenu un taux de classification pour les tests entre 84.48% à 96.21% selon la vitesse de fonctionnement. Le taux de classification montre les bonnes performances obtenues par les Classifieurs SVM pour ce genre de défauts.

Tableau IV-4. Résultats de précision pour chaque vitesse de fonctionnement du Classifieur SVM.

Vitesse(Hz)	% de classification du Classifieur (SVM)
30	86.21
35	84.48
40	93.10
45	96.21
50	90.00

Le meilleur taux de classification est obtenu pour la vitesse de 45 Hz.

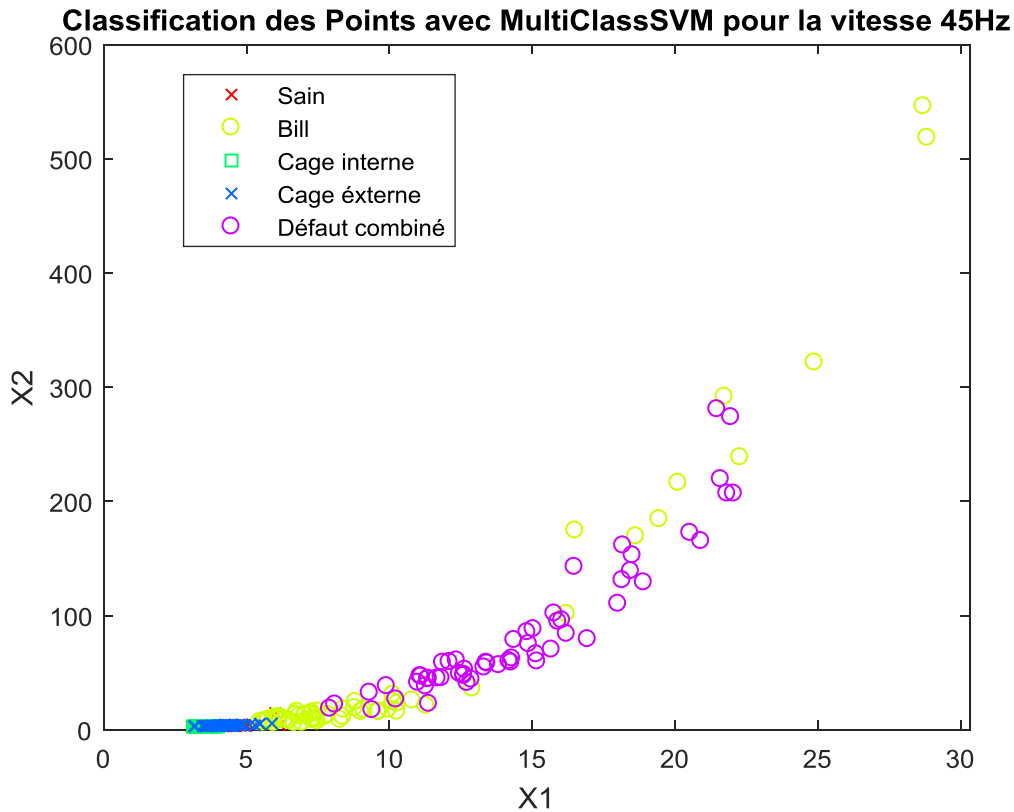


Figure IV-11. Résultat du Classifieur SVM pour la vitesse 45Hz.

IV.4.3. Classification de défauts de roulement en utilisant L'ANFIS :

Comme précédemment l'ensemble des 174 groupes d'indicateurs est divisé en deux sous-ensembles de données séparés : l'ensemble de données d'apprentissage, et l'ensemble des données pour le test.

Selon les résultats d'extraction des indicateurs mentionnés dans la section IV-4. Le Classifieur ANFIS a été implémenté en utilisant le logiciel Matlab (version Matlab R2017a avec la boîte à outils de logique floue). L'ensemble de données d'apprentissage a été utilisé pour former le modèle ANFIS, tandis que l'ensemble de données de test a été utilisé pour vérifier l'efficacité du modèle ANFIS formé pour la classification des cinq classes de défaut de roulement. On a utilisé six ensembles de données d'entrée, avec un total de 116 données d'apprentissage et 58 données pour le test. Pour l'entraînement le nombre d'époques est de 100 avec un pas d'adaptation initiale des paramètres de 0,01.

Deux types de fonctions gaussiennes ont été utilisés comme fonction d'appartenance pour les variables d'entrée.

À la fin des 100 époques d'apprentissage, la valeur de convergence finale est de 0,163.

La Figure IV-12 montre l'évolution de l'erreur d'apprentissage de l'ANFIS.

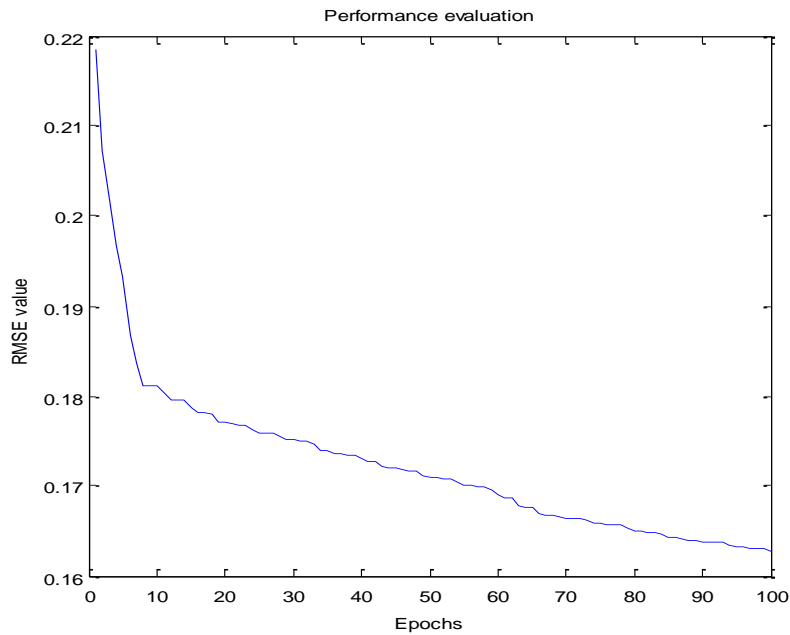


Figure IV-12. Performance d'apprentissage du Classifieur ANFIS.

Après l'apprentissage, 58 données de test ont été utilisées pour valider la précision du modèle ANFIS pour la classification de défauts des roulements. Les résultats de classification du modèle ANFIS sont donnés dans le tableau IV-5.

Tableau IV-5. Résultats de précision pour chaque vitesse de fonctionnement du Classifieur ANFIS.

Vitesse(Hz)	% de classification du Classifieur (ANFIS)
30	84.82
35	88.62
40	88.96
45	92.06
50	93.10

La précision obtenue est entre 84.82% et 93.10% selon la vitesse de fonctionnement. Les résultats montrent l'efficacité de cette méthode pour détecter les défauts du roulement.

IV.4.4. Effet de la vitesse :

Dans ce cas on s'intéresse à l'effet de la variation de la vitesse sur l'évolution des indicateurs et des taux de classification. On fixe la taille du segment à 1500 échantillons, et on fait varier la vitesse de fonctionnement de 30, 35, 40, 45,50hz pour calculer le taux de classification. Voir les tableaux 4.3, 4.4, 4.5

D'après les résultats trouvés, il faut noter que l'énergie des signaux vibratoire évolue progressivement avec la variation de la vitesse, l'énergie reflète l'amplitude des signaux vibratoire qui augmente avec la variation de la vitesse puisque cette variation induit des forces supplémentaires qui augmentent l'amplitude des impacts engendrés par le défaut et cela influe sur les entrées des Classifieurs.

IV.4.5. Effets de la taille du segment :

Dans cette partie nous nous intéressons à la variation de la taille du segment pour le calcul des indicateurs qui est un facteur important dans la qualité des Classifieurs (temps de calcul) ; on remarque que lorsque la taille des segments est grande le temps de classification devient grand, si on veut diminuer le temps de calcul il faut diminuer la taille des segments mais le nombre des données d'apprentissage et test devient assez grand.

Le Tableau IV-6 montre le taux de classification des trois Classifieurs selon la taille des segments n=1500, 1000, 500 échantillons pour la vitesse 45hz.

Tableau IV-6. Précision de classification des trois Classifieurs selon la taille des segments n=1500, 1000, 500 échantillons pour la vitesse 45hz.

Taille du segment Classifieur	1500	1000	500
	SVM	96.21	90.69
ANN	87.12	81.75	78.01
ANFIS	92.06	88.27	84.48

On remarque que le pourcentage de classification pour chaque Classifieur diminue lorsqu'on diminue la taille du segment.

IV.4.6. Effet de la nature et nombre des entrées :

Dans cette partie nous étudions les effets du nombre et les indicateurs les plus efficaces, d'après les résultats trouvés dans le tableau IV-7. On remarque que le nombre des indicateurs est un facteur important pour augmenter la précision des Classifieurs.

Aussi il y a des indicateurs qui sont pertinents et importants pour chaque Classifieur dans la classification des défauts de roulement. Les indicateurs les plus efficaces sont respectivement, le RMS, Max, Min, et le Kurtosis.

Le tableau IV-7 montre le taux de classification des trois Classifieurs selon le nombre et la nature des indicateurs avec la taille des segments n=1500 échantillons pour la vitesse 45hz.

Tableau IV-7. Précision de classification des trois Classifieurs selon le nombre et la nature des indicateurs avec la taille des segments n=1500 échantillons pour la vitesse 45hz.

Nombre d'indicateur	% de classification ANFIS	% de classification SVM	% de classification ANN
1 entrée : Q, K, S, Mx, Mn, Rms	55.86 63.44 55.51 73.79 76.89 82.06	51.72, 63.10, 48.97, 61.03, 65.86, 57.93	42.98, 46.09, 44.13, 54.94, 59.19, 69.31
2 entrée : Q, Rms	72.41	81.03	74.82
3 entrée : Q, K, Rms	76.55	85.86	79.65
4 entrée : Q, K, Mx, Rms	82.76	91.72	82.41
5 entrée : Q, K, S, Mx, Rms	86.20	94.14	84.36
6 entrée : Q, K, S, Mx, Mn, Rms	92.06	96.21	88.73

D'après ce tableau on voit que pour une seule entée c'est l'indicateur Kurtosis qui donne le meilleur résultat de classification sauf pour l'ANN ou c'est le RMS qui l'emporte, et bien sûr plus le nombre d'indicateurs augmente plus la précision augmente.

IV.5. CNN avec signal temporelle :

Dans cette partie nous étudions la méthode de classification basée sur le CNN avec le signal temporel des sept types de défaut qui sont les défauts de roulement, défauts désalignement, et déséquilibre.

Le signal de vibration de chaque condition est collecté sous différentes vitesses de fonctionnement. Chaque condition contient $262144/1024 = 256$ échantillons et chaque échantillon est un signal de vibration collecté contenant 1024 échantillons. L'échantillon de taille 1024×1 -D est ensuite transformé en une image de taille 32×32 .

Les données collectées sont classées en 170 données d'apprentissage et 85 données de test pour sélectionnées au hasard chaque condition.

Le tableau IV-8 montre les ensembles des données pour l'apprentissage et le test des classes sain et défaillantes.

Tableau IV-8. Description des ensembles de données pour l'apprentissage et le test des classes sain et défaillantes.

Conditions des classes	Nombre d'échantillons d'apprentissage	Nombre d'échantillons de test	Classes
Sain	170	85	1
Cage externe	170	85	2
Défaut de Bill	170	85	3
Cage interne	170	85	4
Défaut combiné	170	85	5
Désalignement	170	85	6
Déséquilibre1	170	85	7
Déséquilibre2	170	85	8

La Figure IV-13 montre les formes d'onde brutes des huit conditions qui sont très difficiles à classer.

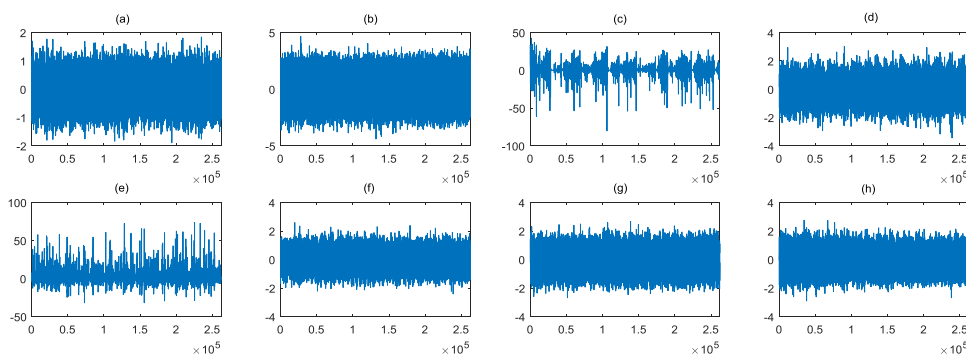


Figure IV-13. Données des signaux de vibration temporelle

(a) Roulement sain, (b) Défaut de cage extérieure, (c) Défaut de bille, (d) Défaut de cage intérieure, (e) Défaut combiné, (f) Défaut de désalignement, (g) Défaut de déséquilibre1, (h) Défaut de déséquilibre.

Dans la première étape, les signaux de vibration sont divisés en segments temporels de taille fixe. La longueur des segments temporels est choisie selon deux critères :

- Ils doivent être suffisamment longs pour mieux saisir les caractéristiques du signal ;
- Ils doivent être optimisés pour réduire le temps de calcul.

Dans cette expérience, la taille de chaque segment est de 1024 échantillons. L'amplitude des signaux de vibration de chaque échantillon est normalisée entre 0 et 1.

Les valeurs normalisées obtenues correspondront à l'intensité de chaque pixel de l'image de taille $M \times N$.

Dans l'étape suivante, les images vibratoires sont construites selon la méthode décrite dans le chapitre 3.2. La longueur de chaque segment du signal de vibration étant de 1024 échantillons. Nous sélectionnons la taille de l'image de vibration $M = 32, N = 32$ pixels ($M \times N = 32 \times 32 = 1024$). Il en résulte un ensemble de 256 images grises de taille 32×32 pixels pour chaque condition. Les images de vibration pour les différentes conditions de fonctionnement du roulement en plus de défaut déséquilibré et du désalignement sont illustrées à la Figure IV-14.

On remarque la différence entre les images qui indiquent les différents modes de fonctionnement pour la vitesse 45Hz.




Figure IV-14. Les images de vibration pour différentes conditions

(a) sain, (b) défaut de cage externe, (c) défaut de bille, (d) défaut de cage interne, (e) défaut combiné, (f) défaut de désalignement, (g) Défaut déséquilibré1, (h) Défaut déséquilibré2.pour la vitesse 45Hz

➤ **Apprentissage du modèle CNN**

L'ensemble d'apprentissage obtenu à partir des images sont les entrées du Classifieur CNN, ses sorties sont les huit classes définies précédemment.

Différents tests ont été réalisés pour un choix optimal de la structure du réseau CNN. Afin d'atteindre un meilleur temps de traitement, une structure contenant un nombre minimum de neurones est adoptée :

Une couche convolutionnelle de 20 filtres de taille 5×5 avec la fonction d'activation de type ReLU, la deuxième couche de sous-échantillonnage avec un filtre de dimensions 2×2 de type *stride* step 1, une couche de sortie (pour les 8 classes) avec une couche Softmax.

L'ensemble des données expérimentales est divisé aléatoirement en deux sous-ensembles 70% pour l'apprentissage et 30% pour les tests. L'apprentissage se fait à l'aide de l'algorithme de rétropropagation. L'architecture du réseau CNN est présentée dans le tableau IV-9.

Tableau IV-9. L'architecture du réseau CNN conçu et paramètres d'apprentissage utilisés dans cette partie.

Couches	Type	Variables et dimensions
0	Taille de segment	1024 échantillon
1	Couche de convolution	CW=5; CH=5; CC=1; CN=20; AF= ReLU.
2	Couche de mise en commun	S=1 ;SW=2; SH=2.
3	Couche de connection	8 noeuds
4	Softmax	8 sorties

CW= largeur du filtre; CH= hauteur du filtre; CC= canal de filtre; CN= nombre de filtre; AF= fonction d'activation; S= taux de sous-échantillonnage ; SW= largeur de sous-échantillonnage; SH= hauteur de sous-échantillonnage.

Tableau IV-10. Structure du réseau neuronal convolutionnel et paramètres d'apprentissage utilisés dans cette partie.

Paramètres d'apprentissage
SGD minibatch size= 50
Learning rate= 0.01
Max epochs=100
Training sample rate=70%

-Après l'étape d'apprentissage, la structure du CNN conçu est évaluée à l'aide des signaux de vibration dans le cas sain et avec différents types de défauts. Les résultats obtenus sont très efficaces avec une précision de 98,68% pour la vitesse 45z. Les résultats sont présentés dans la Figure IV-15




Figure IV-15. Résultats de classification de l'ensemble de données de test pour la vitesse 45Hz.

Pour étudier les performances du Classifieur utilisé pour les différentes classes, nous devons déterminer les probabilités de succès et d'échecs des paires, celle-ci peut être calculée à l'aide de la matrice de confusion. Pour une classification parfaite, ces probabilités seraient

respectivement de 1 et 0 [Lessmann 08]. La Figure IV-16 montre la matrice de confusion de la méthode basée sur le CNN avec le signal temporel pour la vitesse 45z.

Sortie du Classifieur CNN

		1	2	3	4	5	6	7	8
Sortie desirer	1	1.0000	0	0	0	0	0	0	0
	2	0	1.0000	0	0	0	0	0	0
	3	0	0	1.0000	0	0	0	0	0
	4	0.0002	0	0	0.9997	0	0	0	0
	5	0	0	0	0	1.0000	0	0	0
	6	0	0	0.0003	0	0	0.9996	0	0
	7	0	0	0	0	0	0	0.9998	0.0001
	8	0	0	0	0	0	0	0.0003	0.9996

Figure IV-16. Matrice de confusion des résultats obtenus du Classifieur CNN avec signal temporelle pour la vitesse 45Hz.

Lorsque nous considérons la matrice de confusion (voir Fig 4.16), les probabilités de réussite et d'échec sont (1, 0), (1, 0), (1, 0), (0,9997, 0,0002), (1, 0), (0,9996, 0,0003), (0,9998,0,0001) et (0,9996, 0,0003). Les probabilités globales de succès et d'échec du Classifieur sont respectivement de 0,9998 et 0,0001. On note qu'il y a une forte probabilité de réussite (0,9998) et une très faible probabilité d'échec (0,0001). Ce résultat montre que la technique de classification basée sur le CNN avec le signal temporel a un taux de classification très élevé.

IV.6. Méthode proposée

Pour appliquer l'algorithme de classification proposé, Le signal de vibration de chaque condition qui est collecté sous différentes vitesses de fonctionnement est segmenté a l'aide d'une fenêtre glissante de taille 1024 échantillon.

On obtient $262144/1024 = 256$ échantillons et chaque échantillon est un signal de vibration collecté contenant 1024 points de données. Chaque échantillon de taille $1024 \times 1-D$ est ensuite transformé en une image de taille 32×32 .

Les données collectées sont classées en 170 données d'apprentissage et 85 données de test sélectionnées de façon aléatoire pour chaque condition sous les différentes vitesses.

Tableau IV-11. Description des ensembles de données d'apprentissage et test des roulements sain et défectueux.

Condition des classes	Nombre d'échantillons d'apprentissage	Nombre d'échantillons de test	Classes
Sain	170	85	1
Cage externe	170	85	2
Défaut de bill	170	85	3
Cage interne	170	85	4
Défaut combinée	170	85	5

Premièrement, les signaux de vibration sont divisés en segments de taille fixe. La longueur des segments est choisie selon deux critères :

- Suffisamment longue pour mieux saisir les caractéristiques localisées du signal,
- Le plus court possible pour réduire le temps de calcul.

Dans cette expérience, la longueur de chaque segment est de 1024 échantillons. La transformée de Fourier rapide (FFT) est appliquée aux données de vibration de chaque segment la Figure IV-17 montre la (FFT) des différents signaux vibratoires sous les différentes vitesses de fonctionnement.

Le spectrogramme des données brutes de vibration pour différentes conditions de fonctionnement sous différentes vitesses est donné sur la Figure IV-18, on note que selon le défaut considéré, la densité spectrale est différente.

Le contenu spectral de chaque échantillon est normalisé entre 0 et 1. L'amplitude normalisée obtenue correspondra à l'intensité de chaque pixel de l'image spectrale de taille $M \times N$.

Dans l'étape suivante, les images vibratoires sont construites selon la méthode décrite dans la Section III.3. La longueur de chaque segment du signal vibratoire étant de 1024 échantillons. Nous sélectionnons la taille de l'image vibratoire $M = 32, N = 32$ pixels ($M \times N = 32 \times 32 = 1024$). Cela nous permet d'obtenir un ensemble de 256 images grises de 32×32 pixels pour chaque condition. Les images de vibration sous les différentes vitesses pour les cinq conditions de fonctionnement des roulements sont illustrées à la Figure IV-19.




Figure IV-17. Spectres de différentes conditions de fonctionnement à différentes vitesses.




Figure IV-18. Spectrogrammes des données de vibration brutes pour différentes conditions de fonctionnement à différentes vitesses.




Figure IV-19. Images spectrales pour différentes conditions de fonctionnement à différentes vitesses

(a) Roulement sain, (b) Défaut de cage externe, (c) Défaut de bille, (d) Défaut de cage interne, (e) Défaut combiné.

IV.6.1. Apprentissage du modèle CNN

L'ensemble d'apprentissage obtenu à partir des images sans bruit (SNR = 0 dB) sont les entrées du Classifieur CNN, ses sorties sont les cinq classes définies précédemment.

Différents tests ont été réalisés pour un choix optimal de la structure du réseau CNN. Afin d'atteindre une meilleure vitesse de traitement, une structure contenant un nombre minimum de neurones est adoptée :

Une couche convolutionnelle de 5 filtres de taille 5×5 avec la fonction d'activation du type ReLU, la deuxième couche de sous-échantillonnage avec un filtre de dimensions 2×2 du type *stride* step 1, une couche de sortie (pour les 5 classes) avec Softmax couche.

L'ensemble de données expérimentales ont divisé au hasard en deux sous-ensembles 70% pour l'apprentissage et 30% pour les tests. L'apprentissage se fait à l'aide de l'algorithme de rétropropagation. L'architecture du réseau CNN est représentée sur la Figure IV-20.

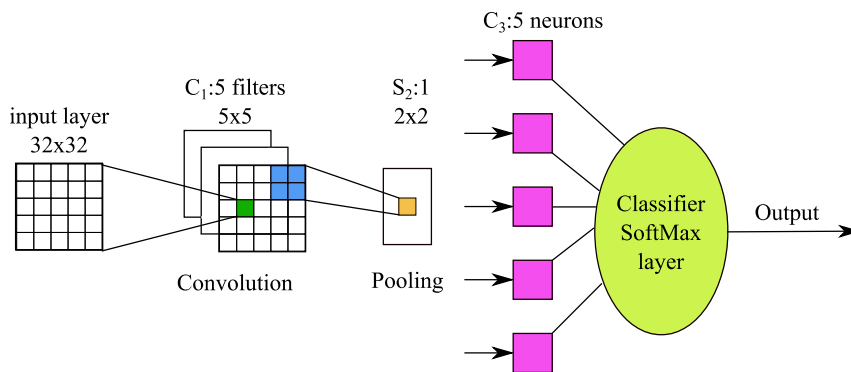


Figure IV-20. Structure du réseau neuronal convolutif utilisé dans notre travail.

IV.6.2. Test à vitesse unique

Après l'apprentissage, la structure du CNN conçu est évaluée par les signaux de vibration sans bruit dans le cas sain et avec défauts pour différentes vitesses de fonctionnement 30, 35, 40, 45,50Hz. Les résultats obtenus sont très efficaces avec une précision de 96,92% à 100%. Les résultats sont présentés dans Fig 4.21 et les résultats de précision sont résumés dans le tableau 4.11.

Pour étudier la qualité du Classifieur pour les différentes classes, nous devons déterminer la probabilité de succès et d'échecs de classification de la paire, qui peut être calculée à partir de la matrice de confusion. Pour une meilleure classification de défauts, une probabilité élevée de succès et une faible probabilité d'échec sont préférées, et pour un Classifieur parfait, ces probabilités seraient respectivement 1 et 0 [Lessmann 08]. La Figure IV-22 montre les matrices de confusion de l'algorithme proposé sous les vitesses suivantes 30, 35, 40, 45, 50Hz.

Par exemple, si nous prenons la vitesse de 30 Hz, à partir de la matrice de confusion (voir Figure IV-22(a)), les probabilités de réussite et d'échec sont (1, 0), (0,99, 0,0002), (1, 0), (1, 0) et (0,99, 0,0002). Les probabilités globales de succès et d'échec du Classifieur sont respectivement de 0,99 et 0,008. On note qu'il y a une forte probabilité de réussite (0,99) et

une très faible probabilité d'échec (0,008). Ce résultat indique que la technique de classification proposée a un taux de classification très élevé.




Figure IV-21. Résultats de la classification de l'ensemble de données d'essai pour différentes vitesses.

Tableau IV-12. Résultats de précision pour chaque vitesse de fonctionnement.

Vitesse (Hz)	% de précision de La méthode proposée
30	98.97
35	98.46
40	99.49
45	100.00
50	96.92

Sortie du Classifieur de la méthode proposé

	1	2	3	4	5
1	1	0	0	0	0
2	0	0.9997	0	0	0.0002
3	0	0	1	0	0
4	0	0	0	1	0
5	0	0	0.0002	0	0.9997

(a)

Sortie du Classifieur de la méthode proposé

	1	2	3	4	5
1	1	0	0	0	0
2	0	1	0	0	0
3	0	0	0.9994	0	0.0005
4	0	0	0	1	0
5	0	0	0	0.0002	0.9997

(b)

Sortie du Classifieur de la méthode proposée

	1	2	3	4	5
1	1	0	0	0	0
2	0	1	0	0	0
3	0	0	0.9997	0	0.0002
4	0	0	0	1	0
5	0	0	0	0	1

(c)

Sortie du Classifieur de la méthode proposée

	1	2	3	4	5
1	1	0	0	0	0
2	0	1	0	0	0
3	0	0	1	0	0
4	0	0	0	1	0
5	0	0	0	0	1

(d)

Sortie du Classifieur de la méthode proposée

	1	2	3	4	5
1	1	0	0	0	0
2	0	1	0	0	0
3	0	0	0.9989	0	0.0010
4	0	0	0	1	0
5	0	0	0.0005	0	0.9995

(e)

Figure IV-22. Matrices de confusion pour différentes vitesses de fonctionnement

(a) 30 Hz, (b) 35 Hz, (c) 40 Hz, (d) 45 Hz, (e) 50 Hz.

IV.6.3. Test à plusieurs vitesses

Dans cette partie, nous testons la méthode proposée par les données vibratoires de toutes les vitesses de fonctionnement 30, 35, 40, 45, 50 Hz en même temps. Les ensembles d'apprentissage et de test sont les images obtenues à partir de ces données qui sont divisées au hasard en deux sous-ensembles 70% pour la formation et 30% pour le test. Ces images sont les entrées du Classifieur CNN, et ses sorties sont les cinq classes. Les résultats obtenus sont très efficaces avec une précision de classification de 98,26%, les résultats sont également représentés sur les Fig 4.23 et Fig 4.24




Figure IV-23. Résultats de la méthode de classification proposée pour le test à plusieurs vitesses.

Sortie du Classifieur de la méthode proposée




Figure IV-24. Matrice de confusion pour test à plusieurs vitesses.

IV.6.4. Etude de robustesse

➤ Robustesse aux variations de vitesse

Pour valider la robustesse avec la variation de vitesse, la même structure du CNN conçu est évaluée à l'aide des signaux de vibrations pour les données d'apprentissage des vitesses de fonctionnement 30, 40, 50 Hz et testée à l'aide de données de 35, 45, 50 Hz.

Une précision élevée de 96,07% a été obtenue et les résultats sont présentés sur les Figures IV-25. Et la Figure IV-26 pour la matrice de confusion. Ces résultats montrent que la méthode proposée est robuste aux variations de vitesse.




Figure IV-25. Résultats de la méthode de classification proposée pour le test de la variation de vitesse.

Sortie du Classifieur de la méthode proposée




Figure IV-26. Matrice de confusion de la méthode de classification proposée pour le test de la variation de vitesse.

➤ Robustesse au bruit

Afin de valider la robustesse au bruit, la méthode proposée est testée par des signaux vibratoires bruyants de différentes conditions SNR variant de -4db à + 10db. Par exemple, la structure du CNN conçu à la vitesse de 45 Hz est testée par des données bruyantes sans apprentissage à nouveau. Une précision de classification élevée de 93,85% à 100% est obtenue en fonction du taux de bruit ajouté. Les résultats du Tableau IV-13 montrent que la méthode proposée est robuste au bruit. La Figure IV-27 montre l'évolution de la précision par rapport au taux de bruit ajouté. La Figure IV-28 montre la matrice de confusion de la méthode proposée pour la vitesse de fonctionnement de 45 Hz avec un bruit injecté de -4 dB.

Tableau IV-13. Variations de la précision par rapport au taux de bruit ajouté.

Bruit[db]	-4db	-3db	-2db	-1db	0db	+10db
[%] de précision de la méthode proposée	93.85	98.46	100	100	100	100




Figure IV-27. Courbe de précision par rapport au taux de bruit ajouté.

Sortie du Classifieur de la méthode proposée




Figure IV-28. Matrice de confusion à la vitesse de 45 Hz avec -4 dB de bruit ajouté.

IV.7. Étude de cas 2 : banc d'essai CWRU

IV.7.1. Configuration expérimentale et description des données

La base de données Case Western Reserve University (CWRU) est un banc d'essai à élément roulant accessible au public, contenant des données sur les signaux de vibrations collectées à partir d'un entraînement à moteur fonctionnant à différentes vitesses et charges et utilisant des roulements dans différents états [Loparo12]. L'objectif est de classer les différents défauts des roulements avec différents niveaux de gravité dans différentes conditions de charge. Les principaux composants de la configuration expérimentale sont un moteur de 2 ch, un transducteur de couple et un dynamomètre, comme le montre la Figure IV-29.




Figure IV-29. Configuration expérimentale de l'ensemble de données CWRU.

Les signaux de vibration ont été collectés à l'aide d'accéléromètres montés en trois positions : côté entraînement, côté ventilateur et à la base. Les conditions de fonctionnement des roulements sont les suivantes : état normal, défaut de bille (BF), défaut de cage externe (OR) et défaut de cage interne (IR). Chacun des défauts (BF, OR et IR) a trois niveaux de gravité. Les défauts ont été introduits pour chaque roulement par décharge électrique entraînant les diamètres de défauts suivants : 0,18 mm, 0,36 mm et 0,54 mm. Les conditions de roulement défaillantes étudiées sont présentées dans le Tableau IV-14.

Tableau IV-14. conditions du relèvement dans l'ensemble de données .

État	Gravité du défaut (mm)	Étiquette de classe
Sain	0	1
BF	0.18	2
BF	0.36	3
BF	0.54	4
OR	0.18	5
OR	0.36	6
OR	0.54	7
IR	0.18	8
IR	0.36	9
IR	0.54	10

Tableau IV-15. Ensemble de données des images vibratoires.

Nom du Data Set	Nombre d'images	Nombre d'images (apprentissage / test)	Condition de charge
A	2360	1580/780	3 hp
B	2360	1580/780	2 hp
C	1860	1240/620	1hp
D	310	200/110	0 hp

Les signaux de vibration ont été collectés dans les conditions de charge suivantes (0, 1, 2 et 3 ch) à une fréquence d'échantillonnage de 48 kHz, l'approche VSI proposée a été appliquée aux signaux pour construire les images utilisées pour le traitement qui en résulte. La partition

de l'ensemble de données en images d'apprentissage et de test dans différentes conditions de charge est présentée dans le tableau IV-15.

➤ **Apprentissage du modèle CNN**

L'ensemble de données est divisé de manière aléatoire en sous-ensembles d'apprentissage et de test. Le rapport de chaque sous-ensemble est défini comme 70% et 30% respectivement, qui sont couramment utilisés dans la littérature. L'ensemble de données d'apprentissage est utilisé pour former le réseau CNN. Dans l'expérience, l'apprentissage est d'abord exécuté pendant une période relativement longue. L'ensemble de données de test est ensuite utilisé pour tester la classification des défauts du modèle entraîné. La précision de l'ensemble des données de test est calculée pour évaluer les performances de la méthode proposée.

Les paramètres de la couche de convolution et des couches de mise en commun maximale de la structure CNN utilisée sont répertoriés dans le Tableau IV-16.

Tableau IV-16. Structure du réseau neuronal convolutionnel et paramètres d'apprentissage utilisés dans cette section.

Couches	Type	Variables et dimensions
0	Taille du segment	1024 échantillon
1	Couche de convolution	CW=5; CH=5; CC=1; CN=20; AF= ReLU.
2	Couche de mise en commun	SW=2; SH=2.
3	Couche de connetion	10 noeuds
4	Softmax	1 sortie

CW= largeur du filtre; CH= hauteur du filtre; CC= canal de filtre; CN= nombre de filtre;AF= fonction d'activation;SW= largeur de sous-échantillonnage; SH= hauteur de sous-échantillonnage.

Paramètres d'apprentissage
SGD minibatch size=4
Learning rate= 0.01
Max epochs=50
Training sample rate=70%

IV.7.2. Évaluation en condition de charge unique :

Après l'entraînement, le réseau CNN conçu est évalué par des signaux de vibration dans le cas sain et avec la présence de différents types de défauts sous différentes charges 0hp, 1hp, 2hp, 3hp. Les résultats obtenus sont très efficaces avec une précision de 97,27% à 99,68%. Les résultats sont présentés sur la figure IV-30 et les résultats de précision sont résumés dans le tableau IV-17. Des comparaisons et des analyses supplémentaires sont effectuées avec les travaux de recherche existants. Les résultats obtenus montrent que la méthode proposée est très efficace avec une précision de 97.27 % à 99,68% comme indiqué dans le Tableau IV-17.

Tableau IV-17. Résultats de précision pour chaque condition de charge.

Nom du Data Set	% de Précision
A	99.62
B	99.49
C	99.68
D	97.27




Figure IV-30. Résultats de la classification de l'algorithme proposé pour différentes charges.

Tableau IV-18. Comparaison de classification du VSI-CNN proposé avec celui de [Xia 18].

Les méthodes	% de Précision
Méthode proposée VSI-CNN avec l'ensemble de données A, B, C, D	99.62-99.49-99.68-97.27
1D CNN un capteur	98.35
1D CNN plusieurs capteur	99.44
Linear SVM	98.83
Quadratic SVM	99.36
KNN	98.61
Weighted KNN	98.36

IV.7.3. Évaluation sous différentes conditions de charges:

Dans les applications réelles ou dans l'industrie, les machines, y compris leurs roulements, doivent travailler dans différents types de conditions de chargement. Lorsque les conditions de fonctionnement changent, les signaux de vibration mesurés changent, ce qui rend la classification des défauts plus difficile, et l'apprentissage du Classifieur doit être exécuté à nouveau avant d'être appliquée à une condition de travail différente. Dans cette section, les expériences sont menées pour évaluer les performances de la méthode de diagnostic proposée dans différentes conditions de charge. Une base de données d'images vibratoires est construite correspondant aux quatre conditions de travail du banc d'essai : 0 ch (data set A), 1 ch (data set B), 2 ch (data set C) et 3 ch (data set D). La structure CNN

sélectionnée est formée par 4600 images de quatre ensembles de données, puis est testé par 2290 images de ces ensembles de données.

Le réseau VSI-CNN sélectionné atteint de bonnes performances avec une précision de classification de 99,56% comme le montre la figure IV-31. La méthode proposée fonctionne toujours bien lorsque les conditions de chargement changent.

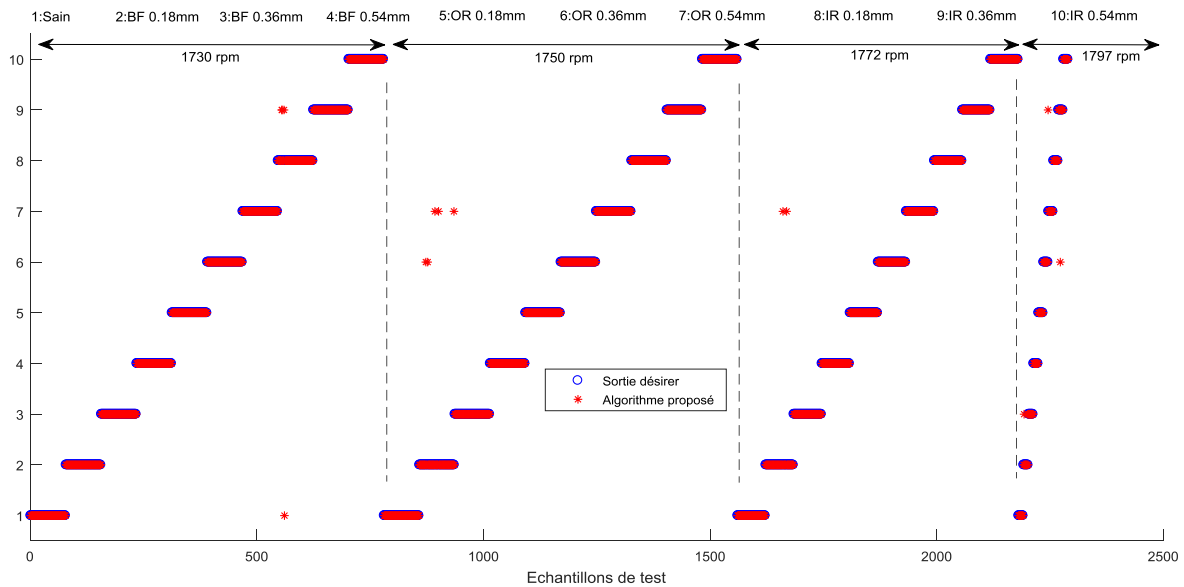


Figure IV-31. Résultats de la classification de l'ensemble de l'algorithme proposé pour toutes les conditions de chargement

IV.7.4. Évaluation dans des conditions de bruit

Afin de valider la robustesse au bruit de l'approche proposée appliquée pour l'ensemble de données CWRU, la structure VSI-CNN est testée à l'aide des signaux vibratoires bruyants à un rapport de bruit SNR de -10 dB. Le test est appliqué à une vitesse de fonctionnement de 3 ch en utilisant la structure VSI-CNN formée précédemment utilisée en utilisant des données sans bruit. Les résultats présentés sur la figure IV-32 montre une précision de classification élevée de 94,74%. La comparaison avec les travaux de recherche existants présentés dans le tableau (4.18) montre que l'approche proposée a la plus grande précision dans les conditions de fonctionnement bruyantes similaires.




Figure IV-32. Résultats de la classification de l'algorithme proposé avec un bruit ajouté de -10 dB.

Tableau IV-19. Comparaison de la méthode de classification VSI-CNN à SNR = -10db avec celle de [Amar15].

Méthode	% de Précision
Méthode proposée	94.74
S.K .Goumas	33.33
X.Lou	33.33
S.Seker	78.25
F.Li	86.00
A.Malhi	38.08
M.F.Yaqub	91.23

IV.8. Conclusion

Nous avons présenté dans ce chapitre, plusieurs expérimentations à base de plusieurs applications. Les méthodes de classification de défauts basés sur l'intelligence artificielle telle que SVM, ANN, et ANFIS ont été appliquées en premier lieu.

Ces méthodes donnent un pourcentage de classification de 96.21, 87.12 ,92.06 % respectivement pour les défauts de roulement.

La méthode de classification basée sur le CNN avec le signal temporel est appliquée pour classer huit types de défauts qui sont les défauts de roulement, déséquilibre, et balourd ; elle a donné une précision de 98,68%.

Dans ce chapitre aussi, nous avons appliqué la méthode proposée pour classer les défauts de roulements. Le contenu spectral des signaux de vibration segmentés dans le temps est transformé en images spectrales et a été considéré comme une caractéristique améliorée du signal vibratoire. Ces images sont ensuite utilisées pour former le Classifieur CNN. Cette technique de classification se caractérise par les principaux avantages suivants:

- Ne nécessite pas l'extraction ou la sélection d'indicateurs ayant un effet significatif sur la classification, ces étapes reposent généralement sur l'expertise des spécialistes du domaine.
- Donne une classification très précise des défauts de roulement pour différentes vitesses de fonctionnement 30, 35,40,45,50Hz avec une précision qui varie de 96,92% à 100%, ces résultats sont validés par des expériences avec des données réelles.
- L'approche proposée est capable de classer les données à vitesse de fonctionnement variable avec une précision de 98,26% pour le test à plusieurs vitesses.
- Les résultats ont montré que cette méthode a la capacité de généraliser la classification pour les données inconnues et donne une précision de 96,07% pour le modèle inconnu (entraînement en utilisant les données des vitesses de fonctionnement 30, 40, 50 Hz et test en utilisant les données des vitesses de fonctionnement 35, 45, 50Hz).
- Les tests de robustesse au bruit dans différentes conditions SNR varient de -4 dB à + 10 dB, ce qui donne des résultats de (93,85%) à 100% montrant que cette méthode est robuste au bruit.
- L'approche proposée est capable de classer les données de charges d'exploitation variables avec une bonne classification précision et avec robustesse à -10 dB SNR bruit ajouté.

Les performances de l'approche proposée ont été comparées à celles des techniques qui sont largement relevée dans la littérature, et a prouvé son efficacité.

Conclusion

Conclusion

Les systèmes électro-énergétiques représentent une classe dominante, dans les systèmes industriels, et peuvent y occuper des positions stratégiques. La surveillance de leurs états de fonctionnement présente donc un intérêt important, afin d'atteindre les objectifs visés.

Ainsi, pour surveiller et diagnostiquer les systèmes électro-énergétiques, plusieurs techniques et approches avec différents niveaux d'efficacité sont utilisées.

Un objectif global était visé. Celui de développer une nouvelle approche de diagnostic de défauts des systèmes électro-énergétiques, qui soit la plus appropriée et qui présenterait les meilleurs avantages.

Pour atteindre cet objectif, notre démarche était basée sur des études théoriques, sur l'expérimentation et sur l'évaluation de l'adaptabilité et l'efficacité des méthodes de surveillance et de diagnostic de défauts.

Ainsi, nous avons donné au premier chapitre, un aperçu sur les techniques de la surveillance des systèmes électro-énergétiques, et les méthodes de traitement de signal appliquées pour la surveillance et le diagnostic des défauts des systèmes électro-énergétiques.

Le deuxième chapitre, a été consacré à l'étude théorique des méthodes de diagnostic de défaut basé sur l'intelligence artificielle, une brève introduction sur les différents algorithmes d'intelligence artificielle, y compris les méthodes suivantes: machine à vecteurs de support SVM, réseau de neurones artificiels ANN ,et système d'inférence neuro floue adaptatif ANFIS.

Les systèmes de diagnostic des défauts basés sur l'intelligence artificielle se compose souvent de deux étapes : traitement des données (extraction des indicateurs), et reconnaissance des défaut (étape de classification).

Dans le troisième chapitre on a démontré les Intérêts de l'utilisation des Réseaux neuronaux convolutif (CNN) dans le processus de classification des défauts afin d'assurer un diagnostic automatique de défauts des systèmes électro-énergétiques, et de compenser les inconvénients des méthodes de diagnostic de défaut basé sur l'intelligence artificielle.

On a proposé une nouvelle méthode de classification de défauts basés sur le réseau neuronal convolutif (CNN) et l'imagerie du spectre vibratoire (VSI); les amplitudes normalisées du contenu spectral extrait des signaux vibratoires temporels en utilisant une fenêtre glissante sont transformés en images spectrales pour la formation et le test du Classifieur CNN.

L'étude comparative des différentes techniques de classification intelligentes avec celle basée sur le Classifieur CNN, présentée au quatrième chapitre dont le but était d'examiner les différentes techniques par des données expérimentales relevées sous forme de signaux vibratoires de roulements sur le banc d'essai du laboratoire URMA/CRTI et des données fournies par la banque de données « **Case Western Reserve University** » (CWRU), L'étude a révélé que :

Les méthodes de classification de défauts basés sur l'intelligence artificielle telle que SVM, ANN, et ANFIS donnent un bon pourcentage de classification.

La méthode de classification basée sur le CNN avec le signal temporelle est appliquée pour classer huit types de défauts qui sont les défauts de roulement, déséquilibre, et balourd ; elle a donné une grande précision de classification.

Pour surmonter les limitations et les insuffisances des méthodes de classification de défauts basés sur l'intelligence artificielle, une nouvelle approche a été introduite pour classer les défauts de roulements. Cette technique de classification se caractérise par les principaux avantages suivants :

- Ne nécessite pas l'extraction ou la sélection d'indicateurs ayant un effet significatif sur la classification, ces étapes reposent généralement sur l'expertise des spécialistes du domaine.
- Donne une classification très précise des défauts de roulement pour différentes vitesses de fonctionnement.
- L'approche proposée est capable de classer les données à vitesse de fonctionnement variable avec un taux de classification élevé.
- Les résultats ont montré que cette méthode a la capacité de généraliser la classification pour les données inconnues et donne une précision élevée.
- Les tests de robustesse au bruit dans différentes conditions SNR montrant que cette méthode est robuste au bruit.
- L'approche proposée est capable de classer les données de charges d'exploitation variables avec une bonne précision de classification.

Les performances de l'approche proposée ont été comparées à celles des techniques qui sont largement relevée dans la littérature, et a prouvé son efficacité.

Références bibliographiques

- [Abou El Anouar 16] B. Abou El Anouar et Al, "Comparaison des différentes méthodes de surveillance et de détection des défauts de roulements," JMATA-2016 (Conférence Internationale des Matériaux Innovants & Leurs Applications), 21 et 22 Avril 2016, Oujda-Maroc.
- [Agnes 05] A. Agnes Muszynska, *Rotordynamics*, vol. 188. CRC Press, 2005.
- [Amar 15] M. Amar, I. Gondal, C. Wilson (2015) Vibration spectrum imaging: a novel bearing fault classification approach. *IEEE Trans Ind Electron* 62(1):494–502.
- [Antoni 04] Jérôme Antoni, Menad Sidahmed, "Contrôle et diagnostic à partir des signaux acoustiques et vibratoires," Spécial congrès Surveillance 5 13Acoustique & Techniques n° 38, 2004.
- [Alavandar 08] S Alavandar and M J Nigam, 'Adaptive neuro-fuzzy inference system based control of six DOF robot manipulator', *Journal of Engineering Science and Technology Review*, Vol 1, pp 106-111, 2008.
- [El Badaoui 97] M. El Badaoui, M. Guillet, N. Nejjar, P. Martini et J. Danière, Diagnostic d'un train d'engrenages par analyse cepstrale synchrone, 16ème Colloque GRETI sur le traitement du signal et des images, 15-19 Septembre 1997, Grenoble.
- [Banerjee 12] T.P. Banerjee, S. Das, Multi-sensor data fusion using support vector machine for motor fault detection, *Inform. Sci.* 217 (2012) 96–107.
- [Bin 12] G. Bin, J. Gao, X. Li, B. Dhillon, Early fault diagnosis of rotating machinery based on wavelet packets empirical mode decomposition feature extraction and neural network, *Mech. Syst. Sign. Process.* 27 (2012) 696–711.
- [Bensana 08] T. Bensana, "Diagnostic des défaillances basé sur l'analyse vibratoire d'une turbine à vapeur", These de Magister universite de Annaba, Algerie, 2008.
- [Bingham 67] C. Bingham, M. Godfrey, and J. Tukey, "Modern techniques of power spectrum estimation," *IEEE Trans. Audio Electroacoust.*, vol. 15, no. 2, pp. 56–66, Jun. 1967.
- [Bouzouane 03] B. Bouzouane, A. Miloudi, N. Hamzaoui et A. Benchaala, Détection de défauts de machines tournantes par la méthode des ondelettes, 16ème Congrès Français de Mécanique, Nice, 1-5 Septembre 2003.
- [Boulenger 98] A. Boulenger and C. Pachaud, *Diagnostic Vibratoire en Maintenance Préventive*. Dunod, 1998.
- [Boulenger 07] Alain Boulenger /Christian Pachaud surveillance des machine par analyse des vibrations EDITION DUNOD p70.
- [Cardone 98] G. Cardone et Al, "Mesure par thermographie infrarouge quantitative du transfert de chaleur pariétal dans un conduit immobile ou en rotation falsant un coude de 180," *Revue Générale de Thermique* Volume 37, Issue 8, September 1998, Pages 644-652.

- [**Chaari 06**] F. Chaari, T. Fakhfakh et M. Haddar, Simulation numérique du comportement dynamique d'une transmission par engrenages en présence de défauts de dentures, *Mécanique et Industries* 6, (2006) 625-623.
- [**Ye 17**] Ye F., Zhang Z., Chakrabarty K., Gu X. (2017) Diagnosis Using Support Vector Machines (SVM). In: Knowledge-Driven Board-Level Functional Fault Diagnosis. Springer, Cham.
- [**Childers 77**] D. Childers, D. P. Skinner, and R. C. Kemerait, "The cepstrum: A guide to processing," *Proc. IEEE*, vol. 65, no. 10, pp. 1428–1443, 1977.
- [**Dekhane 20**] A. Dekhane, A. Djellal, F. Boutebbakh, and R. Lakel (2020), "Cooling Fan ComBinghamghamed Fault Vibration Analysis Using Convolutional Neural Network Classifier", The 3rd International Conference on Networking, Information Systems & Security.
- [**He 12**] D. He, R. Li, and J. Zhu, "Plastic Bearing Fault Diagnosis Based on a Two-Step Data Mining Approach," *IEEE Trans. Ind. Electron.*, pp. 1–1, 2012.
- [**Dowson 70**] D. Dowson, et Al " Analysis of Boosted Lubrication in Human Joints," *Journal of Mechanical Engineering science*, Vol12 No 5 1970.
- [**Ebrahimi 10**] E. Ebrahimi and K Mollazade , "Intelligent fault classification of a tractor starter motor using vibration monitoring and adaptive neuro-fuzzy inference system," *Insight* Vol 52 No 10 October 2010.
- [**Fengqi 07**] W. Fengqi, G. Meng, Compound rub malfunctions feature extraction based on full-spectrum cascade analysis and SVM, *Mech. Syst. Sign. Process.* 20 (8) (2006) 2007–2021.
- [**Hoang 17**] Hoang D-T and Kang H-J, (2017) "Convolutional neural network based bearing fault diagnosis BT - Intelligent Computing Theories and Application," 2017, pp. 105–111. https://doi.org/10.1007/978-3-319-63312-1_9.
- [**Henriquez 14**] P. Henriquez, J. B. Alonso, M. A. Ferrer, and C. M. Travieso, "Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals," *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 44, no. 5, pp. 642–652, May 2014.
- [**Immovilli 09**] Immovilli F, Cocconcelli M, Bellini A, Rubini R (2009) Detection of generalized-roughness bearing fault by spectral-kurtosis energy of vibration or current signals. *IEEE Trans Ind Electron* 56(11):4710–4717.
- [**Janssens 16**] Olivier Janssens, Viktor Slavkovikj, Bram Vervisch, Kurt Stockman, Mia Loccufier, Steven Verstockt, RikVan de Walle, SofieVan Hoecke, "convolutional neural network based fault detection for rotating machinery" Volume 377, 1 September 2016, Pages 331-345. <https://doi.org/10.1016/j.jsv.2016.05.027>.
- [**Jia 16**] Jia F, Lei Y, Lin J, Zhou X, Lu N (2016) Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mech Syst Signal Process* 72–73:303–315.

- [Kang 16] M. Kang, M. R. Islam, J. Kim, J.-M. Kim, and M. Pecht, "A Hybrid Feature Selection Scheme for Reducing Diagnostic Performance Deterioration Caused by Outliers in Data-Driven Diagnostics," *IEEE Trans. Ind. Electron.*, vol. 63, no. 5, pp. 3299–3310, May 2016.
- [Kankar 12] P.K. Kankar, S.C. Sharma, S.P. Harsha, Vibration-based fault diagnosis of a rotor bearing system using artificial neural network and support vector machine, *Int. J. Modell. Ident. Contr.* 15 (3) (2012) 185–198.
- [Kankar 11] P. Kankar, S.C. Sharma, S. Harsha, Fault diagnosis of ball bearings using machine learning methods, *Expert Syst. Appl.* 38 (3) (2011) 1876–1886.
- [Khelf 14] Ilyes KHELF "DIAGNOSTIC DES MACHINES TOURNANTES PAR LES TECHNIQUES DE L'INTELLIGENCE ARTIFICIELLE", These de Docorat universite de Annaba, Algerie, 2014.
- [Konar 11] P. Konar, P. Chattopadhyay, Bearing fault detection of induction motor using wavelet and support vector machines (SVMs), *Appl. Soft Comput.* 11 (6) (2011) 4203–4211.
- [Konar 15] Pratyay Konar et Al , "Multi-class fault diagnosis of induction motor using Hilbert and Wavelet Transform," **Applied Soft Computing Volume 30**, May 2015, Pages 341-352.
- [Lin 03] J. LIN and M. J. ZUO, "GEARBOX FAULT DIAGNOSIS USING ADAPTIVE WAVELET FILTER," *Mech. Syst. Signal Process.*, vol. 17, no. 6, pp. 1259–1269, Nov. 2003.
- [Liu 18] Liu R, Yang B, Zio E, Chen X (2018) Artificial intelligence for fault diagnosis of rotating machinery: a review. *Mech Syst Signal Process* 108:33–47.
- [LeCun 15] LeCun Y, Bengio Y, Hinton G (2015) Deep learning. *Nature* 521(7553):436–444.
- [Lessmann 08] Lessmann S, Baesens B, Mues C, Pietsch S (2008) Benchmarking classification models for software defect prediction: a proposed framework and novel findings. *IEEE Trans Softw Eng* 34(4):485–496
- [Loparo 12] Loparo KA (2012) "Case western reserve university bearing data center [online], Available: URL: <http://www.eecs.cwru.edu/laboratory/bearing/download.htm>, 2019.
- [Lyons 04] M .Lyons, S Adams, M. Woloshynowych, , C. Vincent, "Human reliability analysis in healthcare: A review of techniques", *International Journal of Risk & Safety in Medicine*, Vol.16, pp. 223–237, 2004.
- [Matsugu 03] Matsugu M, Mori K, Mitari Y, Kaneda Y (2003) Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks* 16(5–6):555–559.
- [Moghadasianet 17] Mahmood Moghadasianet al, Induction motor fault diagnosis using ANFIS based on vibration signal spectrum analysis, 2017 3rd International Conference on Frontiers of Signal Processing (ICFSP).

- [Morel 05] J. Morel. Surveillance vibratoire et maintenance prédictive. Techniques de l'ingénieur Comportement en service des systèmes et composants mécaniques.
- [Moubray 00] J. Moubray. Reliability, "Centered Maintenance", RCM, édition 2000.].
- [Nguyen 13] Nguyen D, Kang M, Kim C-H, Kim J-M (2013) Highly reliable state monitoring system for induction motors using dominant features in a two-dimension vibration signal. *New Rev Hypermedia Multimed* 19(3–4):248–258.
- [Pachaud 97] C. Pachaud, R. Salvetat, and C. Fray, "Crest factor and kurtosis contributions to identify defects inducing periodical impulsive forces," *Mech. Syst. Signal Process.*, vol. 11, pp. 903–916, 1997.
- [Patel 12] V.N. Patel, N. Tandon, R.K. Pandey, "Defect detection in deep groove ball bearing in presence of external vibration using envelope analysis and Duffing oscillator," *Measurement* Volume 45, Issue 5, June 2012, Pages 960-970.
- [Rahmoune 11] C. Rahmoune, "Analyse et traitement du courant statorique pour la détection des défauts dans les systèmes électromécaniques", Thèse de Magister université m'hamed bougara-boumerdes, Algerie, 2011.
- [Rafiee 07] J. Rafiee, F. Arvani, A. Harifi, M. Sadeghi, Intelligent condition monitoring of a gearbox using artificial neural network, *Mech. Syst. Sign. Process.* 21 (4) (2007) 1746–1754.
- [Ruonan 18] Ruonan Liu et al, 'Artificial intelligence for fault diagnosis of rotating machinery: A review', **Mechanical Systems and Signal Processing** Volume 108, August 2018, Pages 33-47.
- [Sadeghian 09] A. Sadeghian, Z. Ye, B. Wu, Online detection of broken rotor bars in induction motors by wavelet packet decomposition and artificial neural networks, *IEEE Trans. Instrum. Meas.* 58 (7) (2009) 2253–2263.
- [Safizadeh 05] M.S. Safizadeh et al, "USING SHORT-TIME FOURIER TRANSFORM In MACHINERY DIAGNOSIS," *Proceedings of WSEAS*, 2005.
- [Samanta 04] B. Samanta, Gear fault detection using artificial neural networks and support vector machines with genetic algorithms, *Mech. Syst. Sign. Process.* 18 (3) (2004) 625–644.
- [Samanta 03] B. Samanta et al, "ARTIFICIAL NEURAL NETWORK BASED FAULT DIAGNOSTICS OF ROLLING ELEMENT BEARINGS USING TIME-DOMAIN FEATURES," *Mechanical Systems and Signal Processing*, Volume 17, Issue 2, March 2003, Pages 317-328
- [Shao 18] Shao H, Jiang H, Zhang H, Liang T (2018) Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network. *IEEE Trans Ind Electron* 65(3):2727–2736.

- [Soualhi 15] A. Soualhi, K. Medjaher, N. Zerhouni, Bearing health monitoring based on Hilbert–Huang transform, support vector machine, and regression, *IEEE Trans. Instrum. Meas.* 64 (1) (2015) 52–62.
- [SNR 04] Maintenance Service, Document SNR, SNR Industry, 2004.
- [Sreejith 08] B. Sreejith et Al ,“Fault diagnosis of rolling element bearing using time-domain features and neural networks,” 2008 IEEE Region 10 and the Third international Conference on Industrial and Information Systems, 8-10 Dec. 2008.
- [Sun 02] Q. Sun and Y. Tang, “Singularity Analysis Using Continuous Wavelet Transform for Bearing Fault Diagnosis,” *Mech. Syst. Signal Process.*, vol. 16, no. 6, pp. 1025–1041, Nov. 2002.
- [Sun 14] H. Sun, Z. He, Y. Zi, J. Yuan, X. Wang, J. Chen, and S. He, “Multiwavelet transform and its applications in mechanical fault diagnosis – A review,” *Mech. Syst. Signal Process.*, vol. 43, no. 1–2, pp. 1–24, Feb. 2014.
- [Tandon 99] N. Tandon and A. Choudhury, “A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings,” *Tribol. Int.*, vol. 32, no. 1999, pp. 469–480, 1999.
- [Vapnik 95] Vapnik V (1995) The nature of statistical learning theory. Springer, Berlin.
- [Wang 16] J. Wang, Y. Peng, and W. Qiao, “Current-Aided Order Tracking of Vibration Signals for Bearing Fault Diagnosis of Direct-Drive Wind Turbines,” *IEEE Trans. Ind. Electron.*, vol. 63, no. 10, pp. 6336–6346, Oct. 2016.
- [Weixing 13] Weixing He et Al ,“Nonlinear methods for rolling bearing fault diagnosis,” 2013 Ninth International Conference on Natural Computation (ICNC), 23-25 July 2013.
- [Xia 18] Xia M, Li T, Xu L, Liu L, De Silva CW (2018) Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks. *IEEE/ASME Trans Mechatronics* 23(1):101–110.
- [Xiao-Yi 08] HU Xiao-yi et Al , “VIBRATION SIGNAL DEMODULATION METHOD BASED ON STFT AND ITS APPLICATION IN ROLLING BEARING FAULT DETECTIONS,” *Journal of Vibration and Shock* 2008-02.
- [Xie 17] Xie Y, Zhang T (2017) Fault diagnosis for rotating machinery based on convolutional neural network and empirical mode decomposition. *Shock Vib* 2017:1–12.
- [Xu 19] Xu G, Liu M, Jiang Z, Söfker D, Shen W (2019) Bearing fault diagnosis method based on deep convolutional neural network and random forest ensemble learning. *Sensors* 19(5):1088.
- [Yan 14] R. Yan, R. X. Gao, and X. Chen, “Wavelets for fault diagnosis of rotary machines: A review with applications,” *Signal Processing*, vol. 96, pp. 1–15, Mar. 2014.

- [Hu 01] Y.H. Hu, J.-N. Hwang, Handbook of Neural Network Signal Processing, CRC Press, 2001.
- [Youcef Khodja 20] Youcef Khodja, A., Guersi, N., Saadi, M.N. *et al.* Rolling element bearing fault diagnosis for rotating machinery using vibration spectrum imaging and convolutional neural networks. *Int J Adv Manuf Technol* **106**, 1737–1751 (2020).
- [Zhang 11] B. Zhang, C. Sconyers, C. Byington, R. Patrick, M. E. Orchard, and G. Vachtsevanos, “A Probabilistic Fault Detection Approach: Application to Bearing Fault Detection,” *IEEE Trans. Ind. Electron.*, vol. 58, no. 5, pp. 2011–2018, May 2011.
- [Zani 03] Marie-Line Zani, Guide d’achat, Mesures mécaniques, La surveillance des machines tournantes, MESURES 757, 77-84, Septembre 2003.
- [Zhi Qiang 15] Zhi Qiang Chen,¹ Chuan Li, et René-Vinicio Sanchez Gearbox fault identification and classification with convolutional neural networks, Volume 2015 |Article ID 390134 | 10 pages, <https://doi.org/10.1155/2015/390134>.

Annexe A. Les caractéristiques des roulements DATA BEARING CENTER

Le tableau A-1 représente les diamètres des défauts, leurs profondeurs.

*Les données non disponibles

Tableau A-1. Les défauts unique du coté accouplement (12kHz).

Diamètre du défaut	La charge du moteur	Vitesse de rotation	Bague intérieur	Élément roulant	Bague extérieur		
					Position relative de la zone de charge (la zone de charge est centrée à		
					Centrée 6:00	Orthogonal 3:00	Opposé 12:00
0.007"	0	1797	IR007_0	B007_0	OR007@6_0	OR007@3_0	OR007@12_0
	1	1772	IR007_1	B007_1	OR007@6_1	OR007@3_1	OR007@12_1
	2	1750	IR007_2	B007_2	OR007@6_2	OR007@3_2	OR007@12_2
	3	1730	IR007_3	B007_3	OR007@6_3	OR007@3_3	OR007@12_3
0.014"	0	1797	IR014_0	B014_0	OR014@6_0	*	*
	1	1772	IR014_1	B014_1	OR014@6_1	*	*
	2	1750	IR014_2	B014_2	OR014@6_2	*	*
	3	1730	IR014_3	B014_3	OR014@6_3	*	*
0.021"	0	1797	IR021_0	B021_0	OR021@6_0	OR021@3_0	OR021@12_0
	1	1772	IR021_1	B021_1	OR021@6_1	OR021@3_1	OR021@12_1
	2	1750	IR021_2	B021_2	OR021@6_2	OR021@3_2	OR021@12_2
	3	1730	IR021_3	B021_3	OR021@6_3	OR021@3_3	OR021@12_3
0.028"	0	1797	IR028_0	B028_0	OR028@6_0	*	*
	1	1772	IR028_1	B028_1	OR028@6_1	*	*
	2	1750	IR028_2	B028_2	OR028@6_2	*	*
	3	1730	IR028_3	B028_3	OR028@6_3	*	*

Tableau A-2. Les défauts uniques de côté accouplement (48kHz).

Diamètre du défaut	La charge du moteur	Vitesse de rotation	Bague intérieur	Élément roulant	Bague extérieur		
					Position relative de la zone de charge (la zone de charge est centrée à		
					Centrée 6:00	Orthogonal 3:00	Opposé 12:00
0.007"	0	1797	IR007_0	B007_0	OR007@6_0	OR007@3_0	OR007@12_0
	1	1772	IR007_1	B007_1	OR007@6_1	OR007@3_1	OR007@12_1
	2	1750	IR007_2	B007_2	OR007@6_2	OR007@3_2	OR007@12_2
	3	1730	IR007_3	B007_3	OR007@6_3	OR007@3_3	OR007@12_3
0.014"	0	1797	IR014_0	B014_0	OR014@6_0	*	*
	1	1772	IR014_1	B014_1	OR014@6_1	*	*
	2	1750	IR014_2	B014_2	OR014@6_2	*	*
	3	1730	IR014_3	B014_3	OR014@6_3	*	*
0.021"	0	1797	IR021_0	B021_0	OR021@6_0	OR021@3_0	OR021@12_0
	1	1772	IR021_1	B021_1	OR021@6_1	OR021@3_1	OR021@12_1
	2	1750	IR021_2	B021_2	OR021@6_2	OR021@3_2	OR021@12_2
	3	1730	IR021_3	B021_3	OR021@6_3	OR021@3_3	OR021@12_3

Le tableau A-3 représente les diamètres des défauts, leurs profondeurs et les marques de roulement utilisés.

Tableau A-3. Caractéristiques des défauts des roulements.

Position du roulement	Emplacement du défaut	Diamètre [inches]	Profondeur [inches]	Marque du roulement
Coté entraînement	Bague Intérieur	0.007"	0.011	SKF
		0.014"		
		0.021"		
		0.028"		
	Bague extérieur	0.007"	0.011	SKF
		0.014"		
		0.021"		
		0.028"		
	Bille	0.007"	0.011	SKF
		0.014"		
		0.021"		
		0.028"		
Coté ventilateur	Bague Intérieur	0.007"	0.011	SKF
		0.014"		
		0.021"		
		0.028"		
	Bague extérieur	0.007"		
		0.014"		
		0.021"		
		0.028"		
	Bille	0.007"		
		0.014"		
		0.021"		
		0.028"		

Des roulements SKF ont été utilisés pour les défauts de diamètres 0.007", 0.014" et 0.021", et des roulements équivalents NTN ont été utilisés pour les défauts de diamètre 0.028" et 0.040". Sachant que 1"=25.4mm.

Caractéristique du roulement coté entraînement : 6205-2RS JEM SKF, roulement à Billes de cannelure profonde.

Taille : (inches)

Tableau A-4. Caractéristique du roulement coté entraînement.

Diamètre Intérieur	Diamètre Extérieur	Épaisseur	Diamètre de Bille	Diamètre primitif
0.9843	2.0472	0.5906	0.3126	1.537

Caractéristique du roulement coté ventilateur:6205-2RS JEM SKF, roulement à Billes de cannelure profonde.

Taille: (inches)

Tableau A-5. Caractéristique du roulement coté ventilateur.

Diamètre Intérieur	Diamètre Extérieur	Épaisseur	Diamètre de Bille	Diamètre primitif
0.6693	1.5748	0.4724	0.2656	1.122

Les fréquences caractéristiques des défauts du roulement coté entraînement

La bague intérieure

Tableau A-6. Fréquences caractéristiques d'un défaut de bague intérieure.

Le couple (HP)	Vitesse de rotation (tr /min)	Fréquence caractéristique (Hz)
0	1797	161.69
1	1772	159.90
2	1750	157.90
3	1730	156.11

La bague extérieure

Tableau A-7. Fréquences caractéristiques d'un défaut de bague extérieure.

Le couple (HP)	Vitesse de rotation (tr /min)	Fréquence caractéristique (Hz)
0	1797	107.01
1	1772	105.83
2	1750	104.51
3	1730	103.33

Les billes

Tableau A-8. Fréquences caractéristiques d'un défaut de bille.

Le couple (HP)	Vitesse de rotation (tr /min)	Fréquence caractéristique (Hz)
0	1797	140.74
1	1772	139.189
2	1750	137.44
3	1730	135.89

La cage

Tableau A-9. Fréquences caractéristiques d'un défaut de cage.

Le couple (HP)	Vitesse de rotation (tr /min)	Fréquence caractéristique (Hz)
0	1797	11.89
1	1772	11.75
2	1750	11.61
3	1730	11.48

Annexe B. Publications et Communications

Articles de revue

- Youcef Khodja, A., Guersi, N., Saadi, M.N, N. Boutasseta. Rolling element bearing fault diagnosis for rotating machinery using vibration spectrum imaging and convolutional neural networks. *Int J Adv Manuf Technol* **106**, 1737–1751 (2020).

Article de conférence

- A. Youcef Khodja, N. Guersi, M. N. Saadi , N. Boutasseta .Vibration based diagnosis of bearing faults using temporal indicators. 3ème Conférence Internationale de Mécanique, 26-27 Avril 2017 Annaba Algérie.