

Ministère de l'enseignement Supérieur et de la recherche Scientifique

وزارة التعليم العالي والبحث العلمي

Badji Mokhtar University Annaba
Université Badji Mokhtar –Annaba

Faculté de Technologie

Département d'Electromécanique



جامعة باجي مختار – عنابة

كلية التكنولوجيا

قسم الكتروميكانيك

Année : 2023/2024

Thèse

Présentée pour obtenir le diplôme de Doctorat

Doctorat LMD

Département : Electromécanique

Spécialité : Maintenance Industrielle

Filière : Electromécanique

Thème:

**DIAGNOSTIC DES DÉFAUTS DE LA COMBINAISON ENGRENAGES
ET ROULEMENTS PAR ANALYSE VIBRATOIRE.**

Par :

MILOUDI Zakaria

<i>M.</i>	<i>KABOUCHE</i>	<i>Abdallah</i>	<i>Professeur</i>	<i>UBMA</i>	<i>Président</i>
<i>M.</i>	<i>HADJADJ AOUL</i>	<i>Elias</i>	<i>Professeur</i>	<i>UBMA</i>	<i>Encadreur</i>
<i>Mm</i>	<i>DJEMAI</i>	<i>Mounira</i>	<i>M.C.B</i>	<i>UBMA</i>	<i>Co-Encadreur</i>
<i>M.</i>	<i>BOUZAOUIT</i>	<i>Azzedine</i>	<i>Professeur</i>	<i>Univ. Skikda</i>	<i>Examineur</i>
<i>M</i>	<i>BENCHOUIA</i>	<i>Nedjem Eddine</i>	<i>Professeur</i>	<i>Univ. Souk Ahras</i>	<i>Examineur</i>
<i>M.</i>	<i>BENLALLI</i>	<i>Yacine</i>	<i>M.C.A</i>	<i>UBMA</i>	<i>Examineur</i>

Remerciements

Je tiens à exprimer ma profonde gratitude envers mon directeur de thèse, le Professeur Hadjadj Aoul Elias, du département d'électromécanique de l'Université Badji Mokhtar d'Annaba, pour son encadrement attentif et son soutien tout au long de mes travaux. Ses conseils éclairés et son expertise ont grandement contribué à l'avancement de ma recherche.

Je souhaite également remercier chaleureusement Madame Djemai Mounira pour son soutien continu en tant que co-encadrante.

Un remerciement spécial au Professeur Kabouche Abdallah, qui a présidé le jury avec compétence et bienveillance. Sa contribution à l'évaluation de ma thèse a été d'une grande valeur.

Je remercie également le Professeur Saad Salah de l'Université Badji Mokhtar d'Annaba et je suis reconnaissant envers le Professeur Bouzaouit Azzedine de l'Université du 20 Août 1955 à Skikda, le Professeur Benchouia Nedjem Eddine de l'Université de Souk Ahras, ainsi que le Docteur Benlalli Yacine de l'Université Badji Mokhtar pour leur participation et leur expertise en tant que membres du jury.

Je souhaite adresser mes remerciements à Monsieur Meddour Ikhlass et Monsieur Bouras AbdelKarim pour leur soutien et leur assistance lors de mes travaux de recherche.

Je suis profondément reconnaissant envers ma famille pour leur soutien indéfectible tout au long de ce parcours académique. Un grand merci à mon père, ma mère, ainsi qu'à mes sœurs et frères, Kotob, Hicham, Soundous et Salsabil, pour leur amour et leur encouragement constants.

Je souhaite également remercier mes collègues de l'Université Badji Mokhtar à Annaba à pour leur collaboration et leur camaraderie précieuses.

Enfin, je tiens à exprimer ma gratitude envers toutes les personnes, proches ou lointaines, qui ont contribué de quelque manière que ce soit au succès de cette thèse.

العنوان

" تشخيص العيوب المشتركة في التروس والمحامل من خلال تحليل الاهتزازات "

: الملخص

تهدف هذه الأطروحة إلى معالجة التحدي التقني المرتبط بالكشف عن العيوب المشتركة وتشخيصها في التروس والمحامل، والتي تُعد من أهم المكونات في الأنظمة الميكانيكية الدوارة. نظراً لأهمية هذه العناصر في نقل الحركة والقدرة داخل مختلف الآلات، فإن أي خلل فيها قد يؤدي إلى أعطال جسيمة وخسائر تشغيلية كبيرة.

يعتمد هذا البحث على تحليل الإشارات الاهتزازية كوسيلة فعالة لمراقبة الحالة التشغيلية للتروس والمحامل، حيث يتم استخدام تقنيات معالجة الإشارات لاستخلاص الخصائص المميزة للعيوب. كما يتم تعزيز هذا النهج من خلال دمج خوارزميات الذكاء الاصطناعي، وخاصة التعلم الآلي، بهدف تحسين دقة التصنيف وتقليل معدلات الخطأ في التشخيص.

تم تنظيم محتوى الأطروحة في فصول متسلسلة تشمل الإطار النظري، التقنيات المستخدمة، الدراسة التطبيقية، وتحليل النتائج.

وُختتم الرسالة باقتراح نموذج تشخيصي يجمع بين تحليل الاهتزازات والتعلم الآلي، يُظهر كفاءة عالية في تحديد العيوب المركبة حتى في الظروف التشغيلية المعقدة.

يساهم هذا العمل في دعم استراتيجيات الصيانة التنبؤية وتحسين موثوقية واستمرارية عمل المعدات الصناعية.

: الكلمات المفتاحية

الاهتزازات – التروس – المحامل – التشخيص – الذكاء الاصطناعي – الصيانة التنبؤية – التعلم الآلي

Abstract

Title

"DIAGNOSIS OF COMBINED GEAR AND BEARING FAULTS VIA VIBRATION ANALYSIS"

This thesis addresses the crucial issue of detecting and diagnosing combined faults in gears and bearings, essential components in various mechanical applications. The introduction highlights the importance of gears and bearings in power transmission and underscores the challenges associated with their maintenance. Vibration analysis is identified as a key method for monitoring the health status of rotating machinery.

The research problem is defined around the question of how to improve the detection and diagnosis of faults in gears and bearings using vibration analysis. The objectives aim to develop and validate a methodology based on vibration analysis for the precise diagnosis of combined faults. The thesis is organized into several chapters, each focusing on a specific aspect of the problem.

In conclusion, this thesis proposes an innovative approach to addressing the complex issue of fault diagnosis in gears and bearings. By combining expertise in vibration analysis with advanced machine learning techniques, this research aims to significantly contribute to improving equipment reliability.

Keywords : Vibration analysis, Fault detection, Diagnosis, Gears, Bearings, Predictive maintenance, Deep neural networks, Industrial reliability

Résumé

Intitulé

"DIAGNOSTIC DES DÉFAUTS DE LA COMBINAISON ENGRENAGES ET ROULEMENTS PAR ANALYSE VIBRATOIRE"

Cette thèse traite de l'importante question de la détection et du diagnostic des défauts combinés dans les engrenages et les roulements, qui sont des éléments cruciaux dans de nombreuses applications mécaniques. Dans l'introduction, on souligne le rôle vital des engrenages et des roulements dans la transmission de puissance, ainsi que les défis associés à leur maintenance. L'analyse vibratoire est présentée comme une méthode essentielle pour surveiller l'état de santé des machines tournantes. La problématique de la recherche se concentre sur l'amélioration des techniques de détection et de diagnostic des défauts dans les engrenages et les roulements grâce à l'exploitation de l'analyse vibratoire. Les objectifs de cette étude incluent de développer et valider une méthodologie basée sur l'analyse vibratoire pour le diagnostic précis des défauts combinés. La thèse est organisée en plusieurs chapitres, chacun se concentrant sur un aspect spécifique de la problématique. En conclusion, cette thèse propose une approche novatrice pour aborder la problématique complexe du diagnostic des défauts dans les engrenages et les roulements. Cette recherche vise à améliorer significativement la fiabilité des équipements en combinant l'expertise en analyse vibratoire avec des techniques avancées d'apprentissage automatique.

Mots clés : Analyse vibratoire, Détection des défauts, Diagnostic, Engrenages, Roulements, Maintenance prédictive, Réseaux de neurones profonds, Fiabilité industrielle.

Table des matières

Remerciements	i
Abstract	iii
Résumé	iv
I Initiation à la Maintenance Industrielle et à la Surveillance des Systèmes Complexes	4
I.1 Introduction	5
I.2 Définition et objectifs de la maintenance	5
I.3 Différents types de maintenance	6
I.3.1 Maintenance préventive	6
I.3.2 Maintenance corrective	8
I.4 Choix du type de maintenance	9
I.5 Surveillance	10
I.5.1 Étapes du processus de surveillance	10
I.6 Types de surveillance	11
I.6.1 Surveillance en ligne ou suivi continu	11
I.6.2 Surveillance hors ligne ou suivi périodique	12
I.6.3 Le choix du type de surveillance	13
I.7 Techniques de surveillance des machines tournantes	14
I.7.1 La thermographie infrarouge	14
I.7.2 Analyse des huiles	15
I.7.3 Analyse vibratoire	16
I.7.4 Analyse acoustique	17
I.8 Choix de l’outil de surveillance	17
I.9 Choix de l’outil de surveillance en fonction des défauts potentiels	18
I.9.1 Terminologies utilisées en surveillance	19
I.10 Modélisation et évaluation des stratégies de maintenance	20
I.11 Généralités sur la sûreté de fonctionnement (SdF)	20
I.12 Les critères de classification des méthodes d’analyse de la SdF	21
I.13 Conclusion	22
II Vibrations et Comportement aux Défauts Combinés dans les Engrenages et Roulements	23
II.1 Introduction	24
II.2 Types de défauts	24
II.2.1 Défauts de roulements	24
II.2.2 Défauts d’engrenages	25
II.2.3 Défauts combinés des engrenages et des roulements	27
II.2.4 Défauts de lubrification	28

II.3	Fondements de la Vibration des Roulements et des Engrenages	29
II.3.1	Analyse des Vibrations des Roulements	29
II.3.2	Analyse des Vibrations des Engrenages	29
II.4	Identification des Défauts à Partir des Vibrations	30
II.4.1	Techniques de Traitement du Signal	30
II.4.2	Caractéristiques des Défauts de Roulements et d'Engrenages	31
II.5	Méthodes de Détection et de Diagnostic des Défauts Combinés	31
II.5.1	Méthodes Traditionnelles d'Analyse Vibratoire	31
II.5.2	Méthodes d'Apprentissage Automatique et Réseaux de Neurones Profonds	34
II.6	Conclusion	36
III Réseaux de Neurones Profonds (CNN) et Apprentissage Automatique pour le Diagnostic des Défauts Combinés		37
III.1	Introduction	38
III.2	Réseaux de neurones convolutifs (CNN)	38
III.2.1	Couche de convolution	38
III.2.2	Couche de Pooling	39
III.2.3	Couche entièrement connectée	39
III.3	Application des CNN pour le diagnostic de défauts d'engrenages et de roulements	40
III.3.1	Prétraitement des données	41
III.3.2	Entraînement du modèle	41
III.3.3	Évaluation du modèle	42
III.3.4	Interprétation des résultats	42
III.4	Défis et limitations des CNN dans le diagnostic des défauts combinés	42
III.5	Techniques d'apprentissage automatique pour la détection des défauts	42
III.5.1	AFS-SVM (Adaptive Feature Selection-Support Vector Machine)	42
III.5.2	MLP (Multi-Layer Perceptron)	43
III.5.3	LR (Logistic Regression)	43
III.5.4	K-NN (K-Nearest Neighbors)	44
III.5.5	RF (Random Forest)	44
III.5.6	GNB (Gaussian Naive Bayes)	45
III.6	Application des techniques d'apprentissage automatique pour le diagnostic des défauts combinés dans les engrenages et les roulements	46
III.7	Défis et limitations associés à ces techniques dans le diagnostic des défauts combinés	46
III.8	Conclusion	47
IV Méthodologie de Recherche et Mise en Place de l'Expérience		48
IV.1	Introduction	49
IV.2	Méthodologie de Recherche	49
IV.2.1	Collecte de Données	49
IV.2.2	Prétraitement des Données	50
IV.2.3	Extraction de Caractéristiques	50
IV.2.4	Classification des Défauts	50
IV.2.5	Comparaison des Approches	50
IV.2.6	Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec CNN	50
IV.3	Études Expérimentales	51

IV.3.1	Configuration Expérimentale de la Dynamique de Boîte de Vitesses . . .	51
IV.4	Méthode Proposée	51
IV.5	Résultats et discussion	56
IV.5.1	Méthode de diagnostic des défauts basée sur un réseau neuronal bidimensionnel (CNN-2D)	56
IV.5.2	Méthode de diagnostic des défauts basée sur un réseau neuronal unidimensionnel (CNN-1D)	59
IV.5.3	Méthode de diagnostic des défauts basée sur l'apprentissage automatique (Machine Learning)	62
IV.6	Comparaison des approches de diagnostic	67
IV.7	Conclusion	70
V	Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec CNN	71
V.1	Introduction	72
V.2	Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec des Réseaux de Neurones Convolutionnels (CNN)	72
V.3	Méthodologie	74
V.3.1	Acquisition et Description des Données	75
V.3.2	Préparation des Données	76
V.3.3	Construction du Modèle de Diagnostic	76
V.3.4	Entraînement et Évaluation du Modèle	76
V.4	Construction du Modèle de Diagnostic	76
V.4.1	Architecture du Modèle	76
V.4.2	Intégration du Modèle VGG16	76
V.4.3	Compilation du Modèle	77
V.4.4	Définition des Rappels	78
V.4.5	Entraînement du Modèle	78
V.5	Évaluation du Modèle	79
V.5.1	Résultats de l'entraînement	79
V.5.2	Résultats de Test	80
V.5.3	Courbes d'Accuracy et de Loss	80
V.5.4	Rapport de Classification	82
V.5.5	Matrice de confusion	83
V.5.6	Courbe ROC	84
V.6	Conclusion	84
VI	CONCLUSION ET PERSPECTIVES	87

Table des figures

I.1	Classification des types de maintenance[9].	7
I.2	Maintenance conditionnelle[10].	7
I.3	Principe de la maintenance corrective [11].	8
I.4	Choix du type de maintenance [15].	10
I.5	Architecture générale d'un système de Surveillance [18].	11
I.6	Étapes du processus de surveillance [20].	12
I.7	Surveillance "On-line" [21].	12
I.8	Le choix du type de suivi.	13
I.9	Différentes techniques de la surveillance des machines tournantes.	14
I.10	Principe de l'analyse thermographique [22].	15
I.11	Principe de l'analyse vibratoire [23].	16
II.1	Roulement sain (b) défaut de la bague intérieure (c) défaut de la bague extérieure (d) défaut de la bille [38].	24
II.2	Défaut de cage [39].	25
II.3	Défaut de denture [40].	26
II.4	Défaut de l'arbre d'engrenage [41].	27
II.5	Défaut d'engrenage par pitting [42].	27
II.6	Défaut d'engrenage par fatigue de contact [43].	27
II.7	Défaut combiné d'engrenage et de roulement [44].	28
II.8	Défaut de lubrification [45].	28
II.9	Extraction du spectre de fréquences à l'aide de la FFT.	32
II.10	Analyse spectrale et CWT.	33
II.11	Exemple de méthodes traditionnelles pour détecter un signal de vibration[47].	34
II.12	Exemple d'utilisation de réseaux de neurones profonds pour diagnostiquer les défauts de roulement.[48].	35
II.13	Exemple d'utilisation de méthodes d'apprentissage automatique pour diagnostiquer les défauts d'engrenage et de roulement.[49].	36
III.1	Exemple de réseau de neurones convolutif (CNN).	39
III.2	Exemple de Max Pooling.	40
III.3	Exemple de couche entièrement connectée.	40
III.4	Exemple d'architecture d'un réseau de neurones convolutifs pour le diagnostic des défauts d'engrenages et de roulements.	41
III.5	Illustration de la séparation des classes par SVM.	43
III.6	Structure d'un perceptron multicouche.	44
III.7	Principe de l'algorithme K-NN.	44
III.8	Illustration de la forêt aléatoire.	45

III.9	Diagramme représentant l'application des techniques d'apprentissage automatique pour le diagnostic des défauts combinés.	46
IV.1	Organigramme de la méthodologie de recherche.	49
IV.2	Configuration du banc d'essai.	51
IV.3	Neuf pignons avec différents états de défaut (cinq niveaux de gravité pour la pointe éclatée).	52
IV.4	Schéma général de la méthode proposée.	53
IV.5	Protocole des méthodes proposées.	54
IV.6	Méthode de diagnostic des défauts basée sur un réseau neuronal CNN.	55
IV.7	Évolution de la précision et de la perte du modèle au cours des époques pour CNN-2D.	57
IV.8	Matrice de confusion pour le modèle CNN-2D.	58
IV.9	Évolution de la précision et de la perte du modèle au fil des époques pour CNN-1D.	60
IV.10	Visualisation des caractéristiques bidimensionnelles des données d'échantillon.	63
IV.11	Performances du modèle MLP en fonction du nombre de caractéristiques sélectionnées.	66
IV.12	Matrice de confusion du modèle MLP.	67
IV.13	Courbes ROC du modèle MLP.	68
IV.14	Vue d'ensemble des performances des méthodes de diagnostic.	69
V.1	Architecture du modèle CNN.	77
V.2	Intégration du modèle VGG16.	77
V.3	Compilation du modèle.	77
V.4	Définition des rappels.	78
V.5	Entraînement du modèle.	78
V.6	Courbe de la perte et de l'exactitude au fil des époques.	80
V.7	Courbes de performance.	81
V.8	Matrice de confusion du modèle CNN.	83
V.9	Courbe ROC du modèle CNN.	85

Liste des tableaux

I.1	Choix de l’outil de surveillance en fonction des défauts potentiels.	19
II.1	Types de défauts de roulement.	24
II.2	Principaux défauts des engrenages	26
IV.1	Nombre d’échantillons par état de santé de la boîte de vitesses.	52
IV.2	Illustration détaillée de l’architecture du modèle CNN-2D.	56
IV.3	Résultats des tests pour différentes configurations d’optimiseurs et tailles de lot.	57
IV.4	Détails des couches du modèle.	60
IV.5	Performances des différents modèles CNN.	61
IV.6	Résultats des modèles avec caractéristiques sélectionnées.	64
IV.7	Performances du modèle en fonction du nombre de caractéristiques sélectionnées.	65
IV.8	Comparaison des performances des modèles.	69
V.1	Description du modèle VGG16.	73
V.2	Les types de défauts de l’ensemble de données de la boîte de vitesses.	75
V.3	Résultats d’évaluation du modèle.	79
V.4	Rapport de classification du modèle CNN.	82

Acronymes

IA	Intelligence Artificielle
NF	Norme Française
MPC	Maintenance préventive conditionnelle
SdF	Sûreté de fonctionnement
FDMS	Fiabilité, disponibilité, maintenabilité et sécurité
APR	Préliminaire des Risques
AMDEC	Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité
AdD	Arbres de Défaillances
ML	Machine Learning
CNN	Réseaux de Neurones Convolutionnels
STFT	Transformée de Fourier à court terme
BPFO	Ball Pass Frequency Outer race
BPIF	Ball Pass Frequency Inner race
BSF	Ball Spin Frequency
FFT	Transformée de Fourier rapide
SVM	Support Vector Machine
K-NN	k-Nearest Neighbors
RF	Random Forest
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
LSTM	Long Short-Term Memory
MLP	Multilayer Perceptron
CWT	Continuous Wavelet Transform
IVA	Instantaneous Variability Analysis
GNB	Gaussian Naive Bayes
LR	Logistic Regression
AFS-SVM	Adaptive Feature Selection-Support Vector Machine
CNN 2D	Réseaux de Neurones Convolutionnels Bidimensionnels
CNN 1D	Réseaux de Neurones Convolutionnels Unidimensionnels
UoC	Université du Connecticut
SGD	Stochastic Gradient Descent
RMSPROP	Root Mean Square Propagation
Adam	Adaptive Moment Estimation
AUC	Area Under the Curve
RMS	Écart quadratique moyen
STD	l'Écart-type
CF	Central Frequency

Nomenclature

- Ω Ensemble total des événements
- C La tribu
- ω Un événement particulier
- x Variable aléatoire
- $X(t)$ Variable au cours du temps
- H_0 L'hypothèse nulle
- H_1 L'hypothèse alternative
- $\Pr(x)$ Probabilité de x
- $F(x)$ La fonction de répartition de la variable aléatoire x
- $f(x)$ La fonction de densité de probabilité
- $R(t)$ La fonction de fiabilité
- $\lambda(t)$ Le taux de défaillance
- $W(\eta, \beta, \gamma)$ La loi Weibull
 - η Paramètre d'échelle (la loi Weibull)
 - β Paramètre de forme (la loi Weibull)
 - γ Paramètre de localisation (la loi Weibull)
- $N(\mu, \sigma)$ La loi normale
 - μ Dérive (loi normale)
 - σ Ecart-type (la loi normale)
 - h Le pas de temps
- Ga (α, β) La loi Gamma
 - α Paramètre de forme (la loi gamma)
 - β Paramètre d'échelle (la loi gamma)
- $B(t)$ Le mouvement brownien
 - fe La fréquence d'échantillonnage
 - Te Une période
- Tacq Le temps d'acquisition
- fmax La fréquence maximale
- Ne Nombre de points enregistrés
- VRMS Valeur efficace
 - $x(n)$ Le signal temporel mesuré
 - ξ Le nombre d'échantillons prélevés
 - VC Valeur crête
 - FC Facteur crête
 - M4 Moment statistique d'ordre 4
 - M2 Moment statistique d'ordre 2

T La transformée de Fourier

t La variable temps

f La variable fréquence

DFT La transformée de Fourier discrète rapide

t_e La période d'échantillonnage du signal temporel

n Le numéro de l'échantillon

k Le numéro de la ligne fréquentielle

Δf L'intervalle entre deux raies fréquentielles

$R(s, t)$ Fonction de corrélation

$E(x(t))$ L'espérance

$V(x(t))$ La variance

$Cv(x(t))$ Le coefficient de variation

α Le degré de risque

$\phi(t)$ La fonction de répartition de la loi normale centrée

$Y(t)$ Processus de dégradation

χ^2 La loi Khi carré

INTRODUCTION GENERALE

Introduction

Dans le contexte industriel actuel, Il est exigeant de garantir la fiabilité des systèmes mécaniques, notamment pour les éléments comme les engrenages et les roulements, qui jouent un rôle significatif dans de multiples applications mécaniques [1]. Ces éléments jouent une fonction centrale dans la transmission de puissance, la diminution de vitesse, ainsi que dans diverses autres fonctions essentielles. Cependant, ils sont susceptibles de faire face à de nombreuses formes de dégradations, par exemple l'usure, le désalignement, le déséquilibre, et la fissure, qui peuvent entraîner des répercussions financières significatives et poser des risques pour la sécurité [2].

Il est donc essentiel de détecter ces défauts rapidement et avec précision en vue de garantir la performance des installations industrielles, optimiser les interventions de maintenance, et minimiser les coûts associés [3]. L'analyse vibratoire est devenue une méthode indispensable pour la surveillance d'état de santé des machines tournantes et la détection des signes préliminaires de défaillances potentielles [4].

Cependant, le diagnostic devient particulièrement complexe lorsque des défauts surviennent simultanément dans les engrenages et les roulements, en raison de la superposition des signaux vibratoires émis par ces derniers. Cette complexité nécessite l'utilisation de techniques avancées de traitement de signal et de méthodes de diagnostic novatrices pour l'identification des défauts individuels avec une grande précision.

Problématique de la Recherche

Cette recherche se concentre sur les questions suivantes : Comment la détection et le diagnostic des défauts dans les engrenages et les roulements peuvent-ils être améliorés par l'analyse vibratoire ?

Quels sont les indicateurs précurseurs de ces défauts, et comment peut-on les identifier de manière fiable et précise ?

Pour répondre à ces questions, cette thèse explore l'application des techniques d'analyse vibratoire au diagnostic des défauts combinés dans les roulements et les engrenages. On met l'accent sur le développement de méthodes de diagnostic spécifiques, et l'intégration d'outils de diagnostic innovants.

Objectifs de la Recherche

L'objectif fondamental de cette recherche consiste à concevoir et à valider une méthodologie fondée sur l'analyse vibratoire afin de diagnostiquer avec précision les défauts liés aux engrenages et roulements. Cette méthodologie vise à fournir une solution fiable, rapide et non invasive pour le diagnostic des défauts. L'amélioration de la précision et de l'efficacité du diagnostic se fait à partir de l'incorporation de réseaux de neurones et de méthodes d'apprentissage automatique [3].

La thèse est structurée en plusieurs chapitres, chacun se concentrant sur un aspect précis de la problématique et contribuant à la réalisation des objectifs de recherche. Les concepts fondamentaux associés aux défauts combinés dans les engrenages et les roulements sont exposés dans le premier chapitre. Le deuxième chapitre traite l'utilisation des divers techniques d'apprentissage automatique et des réseaux de neurones profonds pour le diagnostic de ces défauts combinés.

Enfin, le troisième chapitre décrit la méthodologie de recherche et le cadre expérimental mis en place.

Chapitre 1 : Initiation à la Maintenance Industrielle et à la Surveillance des Systèmes Complexes

Dans ce chapitre, les concepts fondamentaux de la sûreté de fonctionnement et de la maintenance industrielle dans les systèmes complexes sont présentés. En plus, les différents types de maintenance ; préventive et corrective, les principes et les techniques utilisés pour la surveillance des machines tournantes sont détaillés. Le choix d'outil de surveillance adapté au défaut potentiel est discuté, tout comme la terminologie spécifique à ce domaine. Le chapitre met en évidence l'importance de l'évaluation des stratégies de maintenance et la modélisation, ainsi que les principaux critères pour classer les méthodes d'analyse de la sûreté de fonctionnement.

Chapitre 2 : VIBRATIONS ET COMPORTEMENT DES DÉFAUTS COMBINÉS DANS LES ENGRENAGES ET ROULEMENTS

Dans ce chapitre, les fondements théoriques et pratiques sont mises en place afin de saisir les défauts combinés dans les engrenages et les roulements. Les différents types de défauts, les principes de l'analyse des vibrations, et les techniques de diagnostic existantes, sont présentés tout en mettant en lumière les défis et les enjeux liés à la détection des anomalies dans ces composants critiques.

Chapitre 3 : Réseaux de Neurones Profonds et Apprentissage Automatique pour le Diagnostic des Défauts Combinés

La concentration sur l'utilisation des réseaux de neurones convolutifs (CNN) et d'autres méthodes d'auto-apprentissage pour le diagnostic des défauts combinés est apparue dans ce chapitre. Ensuite, les principes fondamentaux de ces approches, leurs applications, les avantages qu'elles offrent, ainsi que les défis et les limitations rencontrés lors de leur mise en œuvre sont présentés.

Chapitre 4 : Méthodologie de Recherche et Mise en Place de l'Expérience

La méthodologie détaillée adoptée pour mener à bien cette recherche est présentée dans ce chapitre, en incluant l'acquisition et le traitement des données, l'extraction des caractéristiques, la classification des défauts, et l'évaluation comparative des performances des différentes méthodes utilisées. Ce chapitre décrit également les configurations expérimentales et les études de cas effectuées.

Chapitre 5 : Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec CNN

Ce chapitre explore une approche innovante pour le diagnostic des défauts dans les machines, en particulier les défauts combinés d'engrenages et des roulements. Cette approche est basée sur l'utilisation de réseaux de neurones convolutifs (CNN) pour automatiser l'analyse des signaux vibratoires dans le processus de diagnostic proposé. L'objectif majeur est le développement d'un modèle CNN efficace, apte à reconnaître et à classifier les différents types de défauts combinés.

Conclusion

Pour conclure, cette thèse se propose d'aborder la problématique complexe du diagnostic des défauts dans les engrenages et les roulements à travers une approche innovante fondée sur l'analyse des vibrations et les techniques avancées d'apprentissage automatique. Le défi est considérable puisqu'il s'agit d'assurer la fiabilité et la sécurité des systèmes mécaniques dans un environnement industriel en perpétuelle évolution. Les méthodologies et les outils qui seront développés et validés au cours de ce travail de recherche visent à apporter une contribution significative dans le domaine du diagnostic des machines tournantes. En associant l'expertise en analyse vibratoire à la puissance des techniques d'apprentissage automatique, cette recherche s'efforce de franchir une nouvelle étape vers un diagnostic précis et une analyse détaillée des défauts combinés des engrenages et des roulements sera abordée. Les subdivisions de cette thèse examineront les bases théoriques, les méthodes de recherche et les applications pratiques et industrielles. L'objectif majeur est de renforcer et d'améliorer la fiabilité des équipements, de réduire les coûts de maintenance et d'optimiser les performances des installations et des machines dans le secteur industriel. ce travail aspire ainsi à apporter une contribution notable à l'évolution des connaissances et à l'innovation dans le domaine de la détection et le diagnostic des systèmes mécaniques.

Chapitre I

Initiation à la Maintenance Industrielle et à la Surveillance des Systèmes Complexes

I.1 Introduction

L'augmentation des exigences opérationnelles vers des standards principe toujours plus rigoureux, associée à la complexité croissante des systèmes et à une demande accrue de continuité de service, conduit l'industrie à renforcer son niveau de vigilance quant à l'état de leurs installations. Si la maintenance régulière reste une nécessité pour répondre aux besoins opérationnels, elle s'avère souvent insuffisante ou inapplicable à l'ensemble des équipements, que ce soit pour des raisons économiques ou techniques. Longtemps perçue comme une charge incontournable pour les entreprises, la maintenance a récemment évolué pour s'affranchir de cette réputation, Émergeant comme un facteur déterminant de la compétitivité, il joue un rôle essentiel dans la gestion des risques, qu'ils soient liés à la sécurité, aux finances ou à l'environnement [5].

Ce chapitre se concentre sur la politique de maintenance, visant à prévenir, éviter ou corriger les dysfonctionnements dans une large gamme de systèmes, souvent complexes, qu'il s'agisse de réseaux, de systèmes électroniques, et bien d'autres encore. Nous explorerons également les avancées récentes dans ce domaine, notamment l'intégration de technologies de pointe telles que l'intelligence artificielle (IA) et l'apprentissage automatique, qui transforment la manière dont la maintenance est planifiée, exécutée et optimisée.

Enfin, Nous examinerons les meilleures pratiques et les stratégies innovantes adoptées par les entreprises pour optimiser leur politique de maintenance, tout en assurant la durabilité et la performance de leurs équipements.

I.2 Définition et objectifs de la maintenance

“Selon la norme française NF EN 13306 X 60-319 [6], la maintenance englobe l'ensemble des actions techniques, administratives et de gestion effectuées tout au long du cycle de vie d'un bien, visant à le maintenir ou à le restaurer dans un état fonctionnel.” Cette définition couvre un large éventail d'activités destinées à garantir le bon fonctionnement et la disponibilité des équipements industriels.

Aujourd'hui, la maintenance embrasse un spectre beaucoup plus grand en matière de contributions à la productivité, à la valeur et aux objectifs de développement de l'entreprise ; de là, l'importance de son efficacité et de son optimisation. Parfois, il peut être difficile d'évaluer et de comparer les avantages et les coûts des décisions de maintenance. Par conséquent, tout le processus de maintenance doit être rationnel pour que la maintenance constitue un véritable atout pour l'entreprise.

Une modélisation adéquate des processus de maintenance, ajustée aux besoins et exigences spécifiques, peut servir d'outil précieux pour évaluer et rationaliser les pratiques de maintenance. Cette approche facilite la prise de décisions éclairées sur la planification et la réalisation des tâches de maintenance en harmonie avec les objectifs stratégiques de l'entreprise[7].

Selon Dekker [8], lon peut diviser les objectifs de la maintenance en quatre aspects, en fonction du domaine d'application et des priorités du décideur :

1. **Assurer le fonctionnement du système** : Ce premier objectif vise généralement à garantir le bon fonctionnement du système en termes de production. Il est mesuré à travers des indicateurs tels que la fiabilité, la disponibilité, l'efficacité, ainsi que des indicateurs qualité comme le taux de rebut. Dans ce contexte, il est possible d'évaluer la valeur économique des résultats de maintenance en se basant sur ces indicateurs.
2. **Préserver la valeur économique du bien** : La maintenance vise à maintenir le système en bon état et à prolonger sa durée de vie utile. Ce but est particulièrement important

dans le domaine des infrastructures civiles car il peut être délicat d'évaluer l'efficacité des travaux d'entretien et d'établir les critères pour noter une déféctuosité spécifique comme le cas des routes et leur niveau acceptable de détérioration avant d'être jugées en faillite complète.

3. **Assurer la sécurité des biens et des individus** : La sécurité revêt une importance capitale dans les domaines où une défaillance pourrait entraîner des conséquences graves, tels que l'aviation ou le nucléaire. L'objectif de la maintenance dans ces domaines est de maintenir le niveau de risque au dessous d'un seuil strictement appropriée et définie. Les inspections et les examens jouent alors un rôle essentiel dans ce processus.
4. **Assurer le bien-être de l'humanité** : Ce dernier objectif prend en compte le bien-être humain dans des situations où les aspects économiques ou techniques sont moins prioritaires. Il s'agit plutôt de répondre à des besoins psychologiques, comme la restauration d'œuvres d'art telles que les peintures ou les statues. Quantifier cet objectif reste néanmoins difficile.

I.3 Différents types de maintenance

En ce qui concerne la gestion des équipements industriels, deux approches principales de la maintenance sont souvent utilisées : la maintenance préventive et la maintenance corrective. Dans le but d'assurer la fiabilité et la durabilité des systèmes, de même que pour la réduction du coût et du temps d'arrêt de la production.

La maintenance corrective est réalisée après qu'un équipement a subi un dysfonctionnement ou une panne. Son objectif est de réparer ou de restaurer l'équipement afin qu'il puisse reprendre son fonctionnement. Cependant, ce type de maintenance peut engendrer des discontinuité sur la production et des coûts supplémentaires si elle n'est pas planifiée de manière adéquate.

La maintenance préventive, en revanche, est effectuée avant qu'un équipement ne tombe en panne. Cette approche vise à prévenir les défaillances potentielles par des actions planifiées et régulières.

Les différents types de maintenance sont classifiés en fonction de l'état du système, comme le montre la figure I.1. Les parties ci-dessous décriront en détail chaque type de maintenance et comment elle doit être effectuée :

I.3.1 Maintenance préventive

La mise en place de la maintenance préventive vise à améliorer la fiabilité et la disponibilité des installations industrielles, en réduisant les coûts d'intervention et les temps d'arrêt imprévus. Ce type de maintenance est réalisé en trois niveaux : la maintenance systématique, la maintenance conditionnelle et la maintenance prévisionnelle.

- **Maintenance systématique** : Ce type de maintenance se fait avec des interventions planifiées et réguliers, pour le remplacement ou l'entretien des composants du système, en suivant les recommandations du fabricant ou des intervalles prédéfinis. L'objectif principal est de prévenir les défaillances en remplaçant les pièces avant qu'elles n'atteignent leur fin de vie théorique. Cependant, ce type de maintenance peut être coûteux et inefficace si les remplacements sont effectués trop fréquemment ou si les pièces ne présentent aucun signe de défaillance imminente.

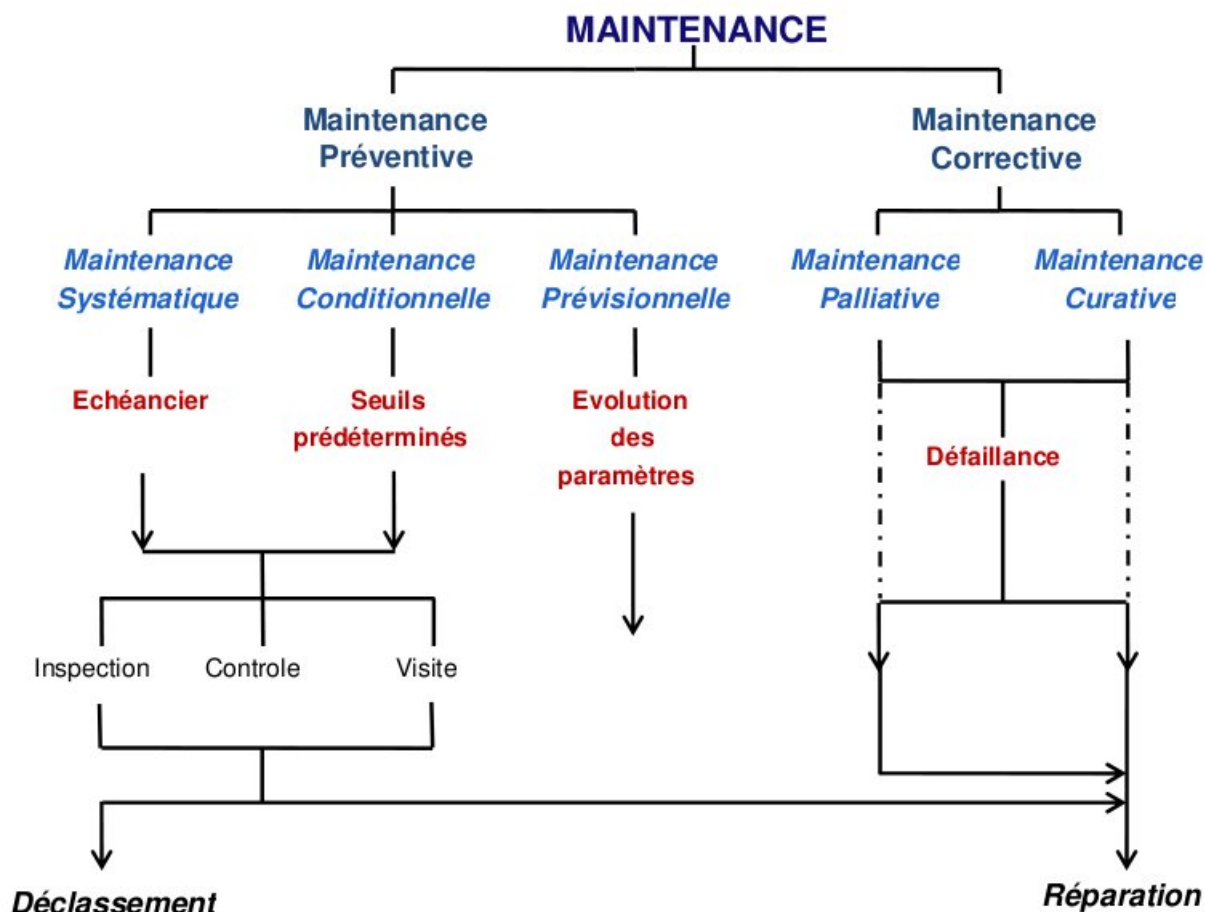


FIGURE I.1 – Classification des types de maintenance[9].

- **Maintenance conditionnelle (MPC)** : Ce type de maintenance s’appuie sur la surveillance en temps réel des paramètres opérationnels des équipements obtenus par les instruments de mesure et les capteurs. Quand l’un des paramètre mesuré dépasser un seuil prédéfini, indiquant une déviation par rapport aux conditions normales de leur fonctionnement, la mise en place des actions de maintenance est nécessaire. Ces actions pourraient inclure des inspections, des ajustements, des réparations ou le remplacement total de composant défectueuse. La force majeure de la maintenance conditionnelle réside dans sa capacité à identifier les défaillances émergentes et à intervenir de manière précise, ce qui permet de réduire le temps d’arrêt imprévu de la machine et de minimiser les coûts associés.




FIGURE I.2 – Maintenance conditionnelle[10].

Dans le cadre de la maintenance conditionnelle, diverses techniques sont employées pour surveiller les machines et détecter les défauts avant qu’ils ne conduisent à une

panne. Parmi ces techniques on cite : l'analyse des huiles, la thermographie infrarouge, et l'analyse des vibrations. La thermographie infrarouge permet de mesurer sans contact la température des composants, ce qui facilite la détection d'éventuelles augmentations anormales de température signalant un défaut. L'analyse d'huile permet d'évaluer la l'état d'huile afin de juger de la santé de la machine. Enfin, l'analyse vibratoire, principalement appliquée aux machines tournantes, détecte les vibrations anormales causées par des défauts.

- **Maintenance prévisionnelle** : L'objectif de ce type de maintenance est d'analyser en détail les changements dans les paramètres de performance et de dégradation des équipements au cours du temps. Ce type de maintenance repose sur des techniques avancées comme l'analyse de données, la modélisation et l'intelligence artificielle, afin de prédire les défaillances possibles et d'organiser les interventions de manière proactive. Cette méthode facilite le passage d'une gestion réactive à une gestion prédictive des équipements, en optimisant les ressources et en maximisant la disponibilité opérationnelle. La maintenance prévisionnelle est souvent considérée comme Le niveau de maintenance le plus avancé et performant, apportant des bénéfices considérables tels que la réduction des coûts, l'amélioration de la productivité et le renforcement de la sécurité.

Pour mettre en place des stratégies de maintenance préventive de manière efficace Il est important d'avoir une combinaison adéquate de méthodes, d'outils et de technologies adaptés aux besoins spécifiques de chaque équipement et processus. Les entreprises adoptant une approche proactive en matière de maintenance sont mieux préparées pour prévenir les pannes, optimiser les performances et garantir une exploitation sûre et rentable de leurs équipements.

I.3.2 Maintenance corrective

Le correctif comprend toutes les actions prises après la détection et la localisation d'une panne sur un processus industriel ou un équipement. La Figure I.3 montre ces activités, qui nécessitent généralement deux types d'interventions :

- — Les interventions palliatives, qui ont pour objectif de rétablir temporairement le bon fonctionnement du système.
- — Les interventions curatives, qui offrent la réparation définitive du système.

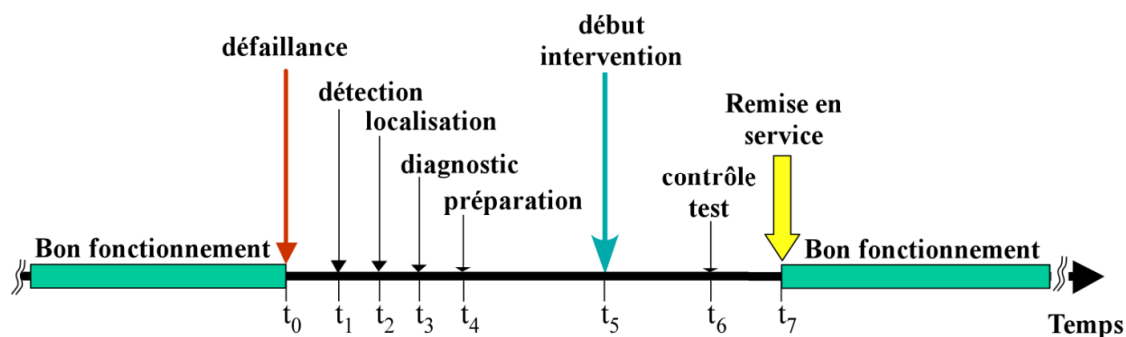


FIGURE I.3 – Principe de la maintenance corrective [11].

— **Maintenance palliative**

Ce type de maintenance corrective permet à un équipement de continuer à fonctionner de manière provisoire ou partielle, afin de maintenir tout ou partie de sa fonctionnalité requise. Également appelée "dépannage", cette forme de maintenance comprend des actions temporaires qui doivent être suivies d'interventions curatives pour résoudre le problème de manière définitive [12].

— **Maintenance curative**

La maintenance curative vise à identifier et à corriger les causes profondes d'une défaillance, ainsi qu'à réparer ou remplacer les éléments défaillants pour éviter la réapparition d'une telle panne. Les effets de la maintenance curative sont obligés d'être durables et permanents afin de garantir le bon fonctionnement continu de l'équipement ou du processus industriel [13].

La fiabilité et les performances opérationnelles de l'équipement ou l'installation sont fortement influencées par la qualité des interventions effectuées par le service de maintenance. Toutefois, l'approche corrective est souvent perçue comme moins efficace et plus coûteuse que l'approche préventive, car elle ne résout pas les problèmes sous-jacents et peut entraîner des temps d'arrêt prolongés ainsi que des pertes de production [14].

I.4 Choix du type de maintenance

Le choix du type de maintenance à privilégier au sein d'une entreprise revêt une importance capitale et repose principalement sur des considérations économiques. Dans certains cas, il peut être économiquement avantageux de recourir à la maintenance curative, en attendant qu'une panne se manifeste, à condition que cette approche soit bien maîtrisée. En revanche, dans d'autres situations, l'adoption des stratégies de prédiction et de prévention des panne peuvent être plus rentable. Le schéma de la Figure I.4, montre comment choisir le type de maintenance. Il est donc important que Les entreprises prennent des décisions en tenant compte de divers facteurs techniques, économiques, ainsi que d'autres éléments intrinsèques ou extrinsèques. Ces facteurs comprennent également :

- La fréquence des défaillances, qu'elles soient liées au caractère aléatoire ou à la cyclicité des équipements : Quand les défaillances sont prévisibles et fréquentes, une approche de maintenance préventive ou conditionnelle pourrait mieux convenir.
- Les compétences et les qualifications du personnel de maintenance ou des sous-traitants : La présence de personnel expert et formé pour effectuer des tâches de maintenance préventive ou conditionnelle peut influencer la décision en faveur de ces approches.
- Les politiques et méthodes d'organisation du travail : La culture d'entreprise et les méthodes de travail influencent également la sélection du type de maintenance approprié.
- La compétitivité au niveau du marché : Les besoins du marché et la concurrence peuvent agir sur la sélection de la stratégie de maintenance.
- Les particularités des produits : Quelques produits ou équipements peuvent nécessiter des approches spécifiques en raison de leurs particularités techniques.

En résumé, le choix du type de maintenance doit être basé sur une évaluation approfondie des coûts, des risques et des gains liés à chaque approche, en considérant les spécificités propres à l'entreprise et de son environnement compétitif.

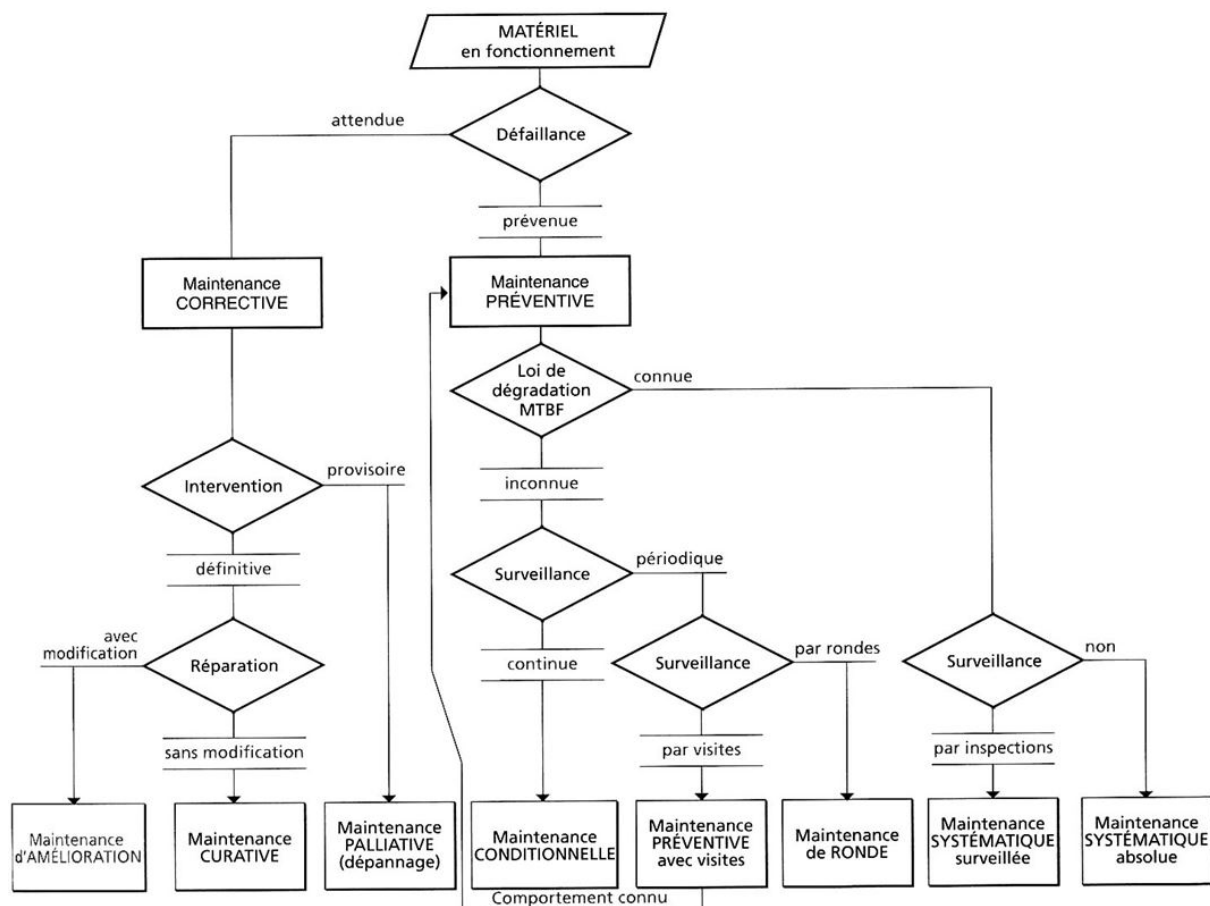


FIGURE I.4 – Choix du type de maintenance [15].

I.5 Surveillance

Dans le milieu industriel, La surveillance des machines joue un rôle central dans la maintenance préventive conditionnelle, car elle facilite la fourniture en continu des informations sur leur état tout en garantissant la continuité de la production. L'objectif vise à renforcer la disponibilité et la sécurité des équipements, tout en limitant les pertes de production [16, 17].

L'architecture générale d'un système de surveillance est décrite dans La Figure I.5.

I.5.1 Étapes du processus de surveillance

La surveillance comprend de deux phases majeures : la détection et le diagnostic ((consulter la Figure I.6) [19].

- **Détection** : Cette phase vise à déterminer la présence d'un défaut affectant le procédé en examinant et en détectant ses impacts sur le système (symptômes).
- **Diagnostic** : En s'appuyant sur les défauts relevés, cette étape comporte :
 - **Localisation** : Déterminer le type de défaut affectant le mécanisme à l'aide des informations liées à l'élément défaillant.
 - **Identification** : Repérer avec précision la cause des symptômes en déterminant la nature du défaut.

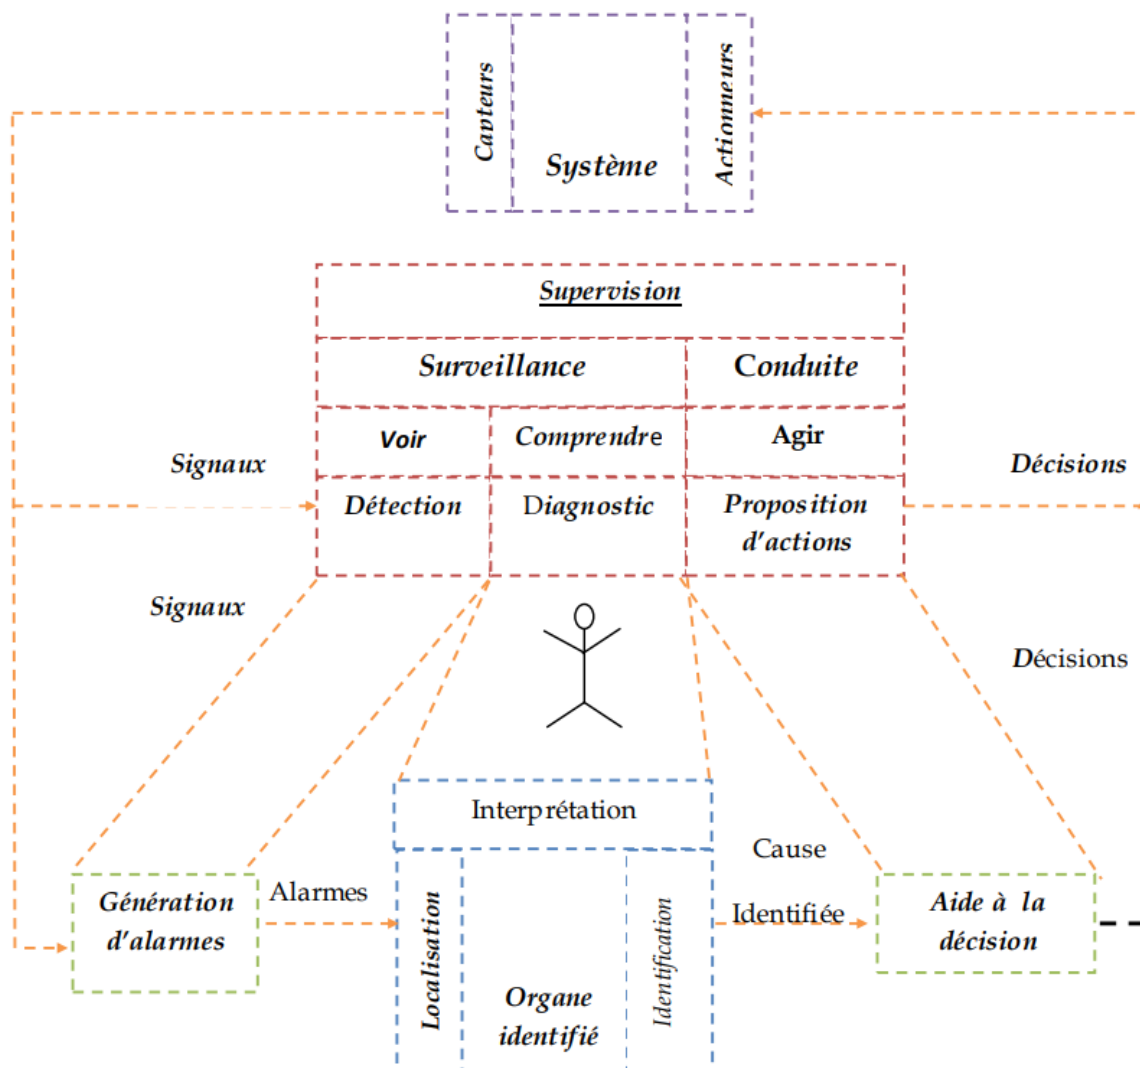


FIGURE I.5 – Architecture générale d'un système de Surveillance [18].

I.6 Types de surveillance

Les machines peuvent exiger un système de surveillance en ligne doté de fonctions de diagnostic, ou d'un système de surveillance hors ligne, plus adapté aux machines simples comme les pompes ou les ventilateurs, selon leur criticités et leur importance. On différencie principalement deux types de surveillance :

I.6.1 Surveillance en ligne ou suivi continu

La surveillance en ligne est appliquée en mode permanent sur des machines spécifiques, favorisant un suivi continu d'état de fonctionnement, via une mesure continue de différents paramètres physiques, en particulier ceux qui connaissent une évolution rapide, comme la vitesse et la vibration.

L'objectif majeur de suivi continu est d'optimiser la sécurité des machines et la disponibilité, tout en diminuant les pertes de production. Si l'état de la machine change radicalement, le système émet un signal d'alarme dans la salle de contrôle.

Généralement, La surveillance en ligne s'appuie sur les techniques de diagnostic qui utilise

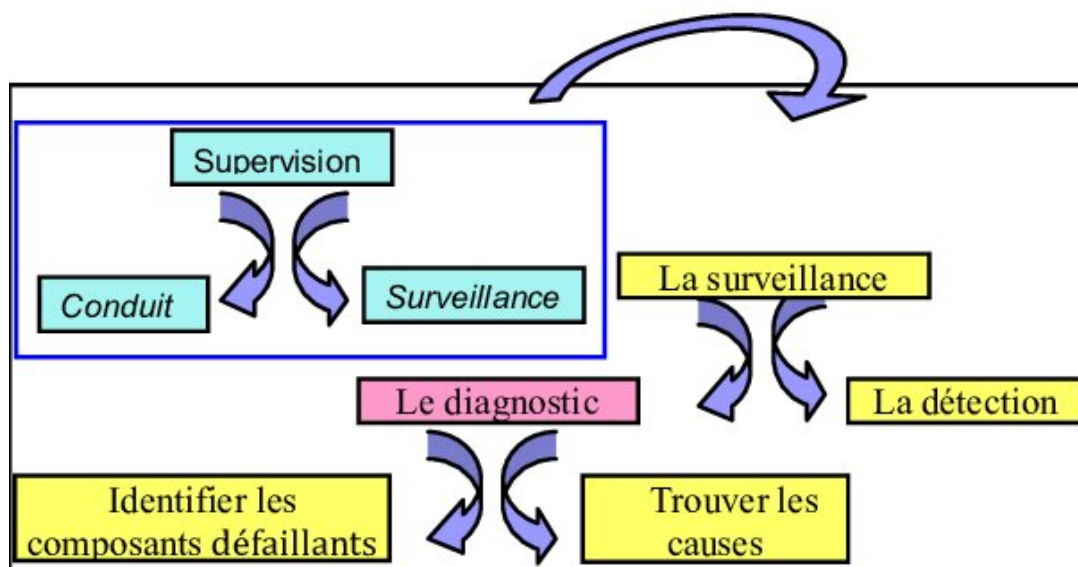


FIGURE I.6 – Étapes du processus de surveillance [20].

des modèles, en intégrant une modélisation comportementale et structurelle du système à surveiller. Le principe consiste à comparer le comportement prédictif du modèle (en état de fonctionnement optimal) avec le comportement réel observé. Les irrégularités détectées facilitent l'identification des causes potentielles de défaillances et de prendre des mesures correctives.

La surveillance en ligne implique la mise en place d'outils de détection des défaillances et de systèmes de commande fiables et robustes pour assurer un fonctionnement optimal de l'ensemble. La Figure I.7 illustre un système de surveillance en ligne.




FIGURE I.7 – Surveillance "On-line" [21].

I.6.2 Surveillance hors ligne ou suivi périodique

La surveillance hors ligne, également appelée suivi périodique, consiste à effectuer de prélèvements, de mesures, et de vérifications à des moments préétablis et à des intervalles réguliers. Contrairement à la surveillance en ligne, qui implique une mesure continue des paramètres, la surveillance hors ligne est basée sur une approche plus intermittente. Par exemple, des techniques telles que la thermographie infrarouge ou l'analyse d'huiles, où les paramètres physiques évoluent lentement, nécessitent une surveillance périodique.

Cette méthode est adaptée lorsque les changements d'état des machines sont moins fréquents ou moins critiques, tout en nécessitant une attention régulière pour éviter les défaillances.

La décision concernant le choix du type de surveillance, repose sur plusieurs considérations importantes, comme le type de machine à surveiller, la nature des anomalies ou défaillances à détecter, et les caractéristiques particulières de l'équipement.

Pour choisir le type de surveillance le plus approprié, il est essentiel de prendre en compte plusieurs critères, notamment le degré de complexité de la machine, la criticité des défaillances potentielles, la fréquence des changements d'état, et aussi les ressources accessibles pour la surveillance. Ce choix peut inclure soit une surveillance en ligne continue, avec des mesures en temps réel et une surveillance permanente, soit une surveillance hors ligne périodique, avec des analyses effectuées à des intervalles du temps prédéfinis. Chaque démarche offre des atouts ainsi que des limites, Il est essentiel que la décision soit conforme aux objectifs de surveillance ainsi qu'aux contraintes opérationnelles de l'entreprise.

I.6.3 Le choix du type de surveillance

Le choix du quel type de surveillance a suivi dépend du type de la machine et de la défaillance à détecter. La sélection est guidé par plusieurs questions déterminantes, comme illustré dans la Figure I.8.

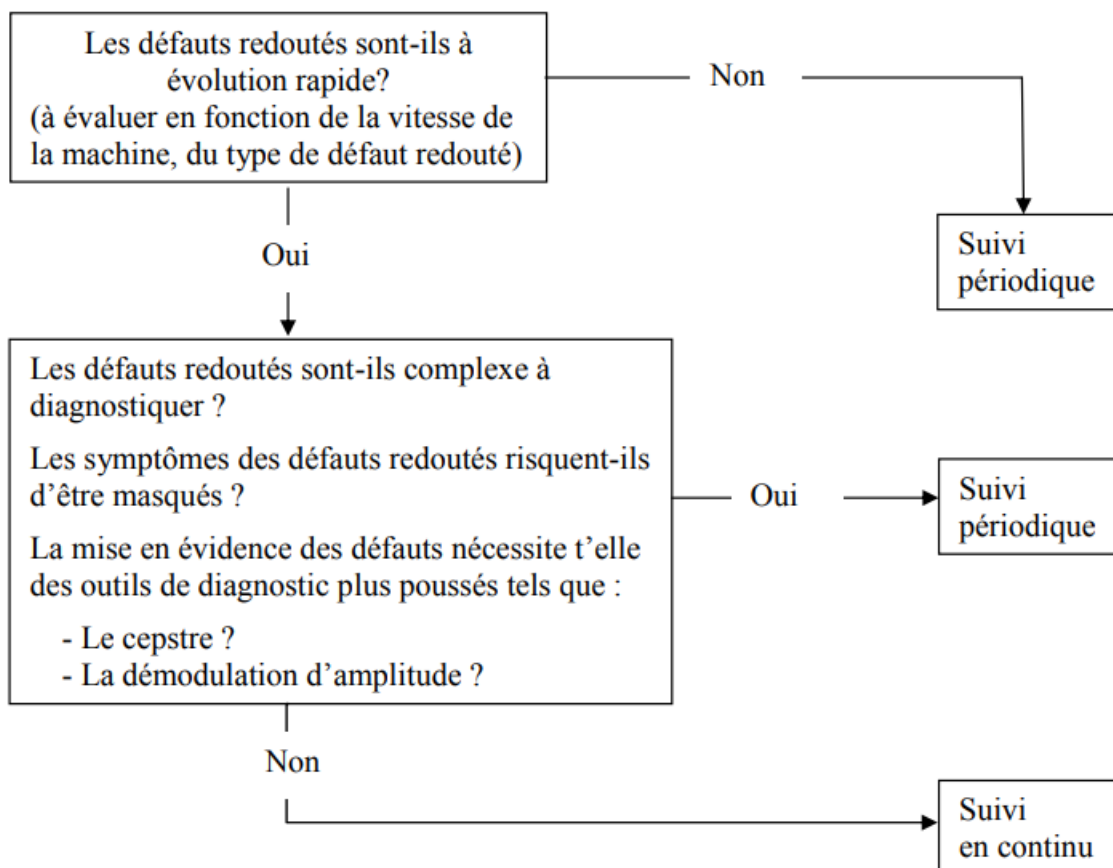


FIGURE I.8 – Le choix du type de suivi.

Pour prendre une décision éclairée concernant le type de surveillance à mettre en œuvre, il est important de prendre en considération plusieurs facteurs, en particulier la complexité de la machine, la sévérité des défaillances envisageables, la fréquence de changement d'état, de même que les ressources disponibles pour la surveillance. Selon ces facteurs, on peut choisir entre une surveillance en ligne continue, qui permet de mesurer les paramètres en temps réel

et d'assurer une surveillance permanente, ou une surveillance hors ligne périodique, où les mesures sont effectuées à des intervalles fixés à l'avance. Chaque méthode a de points forts et de points faibles, et meilleure sélection sera en fonction des objectifs spécifiques liés au surveillance et au contraintes opérationnelles de l'entreprise.

I.7 Techniques de surveillance des machines tournantes

A présent, un large éventail de techniques est disponible pour surveiller l'état des machines tournantes en analysant une variété des paramètres comme l'état de lubrification, la température, les vibrations, le courant, et d'autres. Cette multiplicité facilite la détection des anomalies sur une hyper-large gamme avec une surveillance bien détaillée. La Figure I.9 offre une vue d'ensemble des techniques employées dans la surveillance des machines rotatives.




FIGURE I.9 – Différentes techniques de la surveillance des machines tournantes.

I.7.1 La thermographie infrarouge

La thermographie infrarouge est une méthode de surveillance qui permet de mesurer la température des composants sans contact physique direct. Elle est couramment utilisée pour surveiller les machines rotatives; détecter les anomalies qui se caractérisent par une élévation anormale de la température. L'un des avantages primordiaux de la thermographie réside dans sa possibilité de prendre des mesures à distance. Permettant ainsi l'inspection de zones difficiles d'accès sans interrompre les opérations de production. Cette technique génère immédiatement une image thermique de la zone examinée, facilitant ainsi l'identification des zones présentant des températures anormales.

Le fonctionnement de l'analyse thermographique repose sur la détection des rayonnements infrarouges émis par les objets en fonction de leur température. Les caméras thermographiques captent ces rayonnements et les convertissent en images thermiques, où les variations de température sont représentées par des couleurs distinctes. Les zones présentant des températures anormalement

élevées ou basses peuvent ainsi être facilement détectées. Le principe de l'analyse thermographique est illustré à la Figure I.10.

Par la surveillance régulière des températures au niveau d'éléments d'une machine tournante utilisant la thermographie infrarouge, il est envisageable de repérer les anomalies potentielles tels que les surchauffes, les frottements excessifs ou les problèmes de lubrification. Cela permet d'implémenter des mesures correctives avant que les défauts ne conduisent à des dommages plus graves ou à des interruptions non planifiées. En conclusion, la thermographie infrarouge constitue une technique précieuse pour la surveillance des machines tournantes, offrant une méthode non destructive et non intrusive pour identifier les défauts thermiques. Son utilisation L'utilisation régulière de cette méthode favorise la prévention des pannes et l'optimisation de la fiabilité et de la disponibilité des installations industriels.




FIGURE I.10 – Principe de l'analyse thermographique [22].

I.7.2 Analyse des huiles

L'analyse des huiles est une approche de surveillance indispensable dans l'industrie, visant à évaluer l'état de fonctionnement des machines tournantes. Elle repose sur l'idée que l'huile, en contact continu avec les composants mobiles, elle délivre des informations significatives sur l'état opérationnel de la machine. A des conditions de fonctionnement strictes, La qualité des huiles peuvent se détériorer en raison de l'usure, de la contamination ou d'autres facteurs. L'analyse des huiles est donc appliquée à diverses machines contenant des lubrifiants, tels que les moteurs thermiques, les motoréducteurs, les réducteurs. L'analyse commence par un prélèvement d'échantillon d'huile. Cet échantillon est ensuite soumis à une série de tests en laboratoire pour évaluer plusieurs indicateurs, tels que la viscosité, l'existence de particules d'usure, la contamination via corps étrangers, et la présence de matières potentiellement inflammables. En examinant ces indicateurs, Les techniciens pourraient déterminer l'état de santé de l'équipement et d'identifier des signes de détérioration potentielles. Pour illustrer, la détection de débris métalliques dans l'huile peut indiquer un frottement excessif ou une usure.

La même chose pour la viscosité d'huile, une telle variations dans la viscosité de l'huile peut signaler une contamination ou d'autre problème liés au lubrification.

L'analyse d'huile offre aux opérateurs et aux techniciens de maintenance de mettre en œuvre des mesures préventives avant que les problèmes ne deviennent graves, évitant ainsi des dommages coûteux ou des temps d'arrêt imprévus. En surveillant régulièrement l'état de santé des lubrifiants, pour augmenter la durée de vie de matériels et améliorer la fiabilité et la disponibilité des systèmes.

I.7.3 Analyse vibratoire

L'analyse vibratoire est une méthode de surveillance particulièrement suit aux composants mécaniques des machines tournantes en service. Elle est fréquemment utilisée dans le secteur industriel, pour identifier une gamme variée de défauts susceptibles d'affecter ces machines.

Cette technique repose sur le principe que les machines en fonctionnement génèrent des vibrations directement liées à leur état de santé. Les études ont démontré que la vibration est omniprésente dans les machines en fonctionnement et qu'il existe une forte corrélation entre le profil vibratoire et l'état de santé de la machine. C'est-à-dire, plus la dégradation de la machine est avancé, plus le niveau vibratoire est élevé.

L'analyse de vibrations permet la détection de nombreux types de défauts, comme balourd, désalignement, défauts de roulement, fissures, jeux. Cette méthode est appliquée pour analyser l'état de santé de la machine et identifier les signes précoces de défaillance imminente.

Le processus d'analyse vibratoire consiste généralement à mesurer et à analyser les vibrations à différentes fréquences et à divers points de la machine. Les valeurs recueillies sont après comparées avec des données de référence avec des seuils prédéfinis pour détecter tout altération ou changement significatif dans la réponse vibratoire de la machine. Le schéma de la Figure I.11 expose le principe de l'analyse vibratoire.

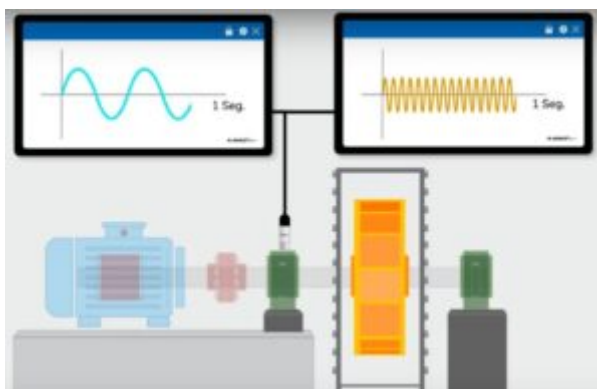


FIGURE I.11 – Principe de l'analyse vibratoire [23].

En surveillant régulièrement les vibrations d'une machine, l'équipe de maintenance pourrait détecter rapidement les anomalies dès leur apparition. Cela leur permet d'intervenir de manière corrective avant que les défauts ne se détériorent davantage, ce qui pourrait provoquer des dommages importants ou des interruptions inattendues sur la production.

L'analyse vibratoire contribue à allonger la durée de vie des installations, réduire les frais associés au maintenance donc, améliorer la fiabilité et la disponibilité des équipements.

L'analyse vibratoire est au cœur de notre recherche doctorale, constituant une méthode cruciale pour la surveillance des machines tournantes.

Cette technique est essentielle dans notre thèse, qui se concentre sur le développement de méthodes avancées d'analyse vibratoire afin de détecter précocement les défauts dans les installations industrielles.

Par conséquent, notre recherche s'inscrit dans le domaine de la surveillance conditionnelle des machines stratégiques, employant des techniques novatrices d'analyse vibratoire pour la prédiction des défauts, la réduction des frais de maintenance et l'optimisation des performances de notre équipement.

I.7.4 Analyse acoustique

L'analyse acoustique, également connue sous le nom d'analyse par ultrasons, offre une approche supplémentaire pour la surveillance des machines tournantes, favorisant la détection de défauts spécifiques grâce aux signaux sonores.

Cette technique utilise des microphones placés près de l'équipement pour détecter les bruits anormaux générés pendant le fonctionnement. Ces bruits peuvent alerter sur des problèmes tels que des frottements anormaux, des vibrations atypiques ou d'autres indications d'un dysfonctionnement. L'analyse par ultrasons vise à identifier des défauts par l'utilisation des signaux de haute fréquence et de faible amplitude, notamment les dégradations anticipées des roulements. Cette technique d'analyse, favorise la détection des signes de défaillance qui pourraient être négligés par d'autres techniques de surveillance.

En intégrant ces méthodes avec d'autres techniques telles que l'analyse vibratoire et l'analyse des huiles, il est possible d'obtenir une évaluation globale de l'état des machines tournantes, facilitant ainsi une maintenance proactive et préventive pour assurer leur fonctionnement optimal et augmenter leur durée de vie.

I.8 Choix de l'outil de surveillance

Le choix d'outil de surveillance est déterminé par plusieurs facteurs, pour faire du diagnostic, localiser et identifier des défauts. Parmi ces facteurs, on cite : les exigences opérationnelles, la complexité de la ligne de production et les paramètres environnementaux. Ce qui suit offre un aperçu sur les critères à évaluer pour sélectionner l'outil de surveillance le plus approprié :

Analyse Vibratoire

- **Avantages Principaux :** La détection précoce des défauts via l'analyse vibratoire contribue à prévenir l'occurrence des pannes et d'éviter des arrêts de production coûteux. Cette méthode est particulièrement efficace pour identifier les défauts dans les parties cinématiques et la configuration des machines.
- **Limitations Principales :** L'interprétation de spectre de vibration peut parfois s'avérer complexe, rendant le diagnostic délicat. En plus, l'implémentation de système de surveillance en ligne peut impliquer des frais relativement élevés.
- **Domaines d'Application Privilégiés :** L'analyse des vibrations sert à identifier les défauts dans les composants cinématiques et la structure des machines, notamment les déséquilibres, les non-alignements et les jeux.

Analyse d'Huiles

- **Avantages Principaux :** L'analyse des huiles permet de détecter une pollution anormale du lubrifiant, prévenant ainsi les défaillances mécaniques et réduisant les coûts de réparation.

Cette technique est efficace pour surveiller les propriétés du lubrifiant, identifier les problèmes de lubrification, et analyser les éléments d'usure.

- **Limitations Principales** : L'analyse d'huile ne permet pas de localiser les défauts de manière précise et requiert des précautions strictes durant le prélèvement des échantillons d'huile.
- **Domaines d'Application Privilégiés** : L'analyse des huiles sert essentiellement à vérifier les caractéristiques du lubrifiant et détecter les problèmes liés au lubrification.

Thermographie IR

- **Avantages Principaux** : La thermographie infrarouge permet un contrôle rapide et non destructif des installations, en fournissant une image thermique de la zone inspectée. Elle est efficace pour identifier les défauts causant un échauffement.
- **Limitations Principales** : Cette technique est limitée à la détection des échauffements à la surface ne donne pas la possibilité de réaliser une analyse approfondie des défauts.
- **Domaines d'Application Privilégiés** : La thermographie IR est utilisée pour détecter les défauts entraînant un échauffement, tels que les problèmes de lubrification.

Analyse Acoustique

- **Avantages Principaux** : L'analyse acoustique permet de détecter des défauts audibles et de réaliser une surveillance continue. Elle est utile pour identifier des bruits anormaux nécessitant une analyse approfondie.
- **Limitations Principales** : La réalisation du diagnostic peut être compliquée du fait de la sensibilité aux nuisances sonores ambiantes et de complications liées à la répétabilité des mesures.
- **Domaines d'Application Privilégiés** : L'analyse acoustique est principalement employée pour détecter des bruits inhabituels nécessitant une évaluation ultérieure.

I.9 Choix de l'outil de surveillance en fonction des défauts potentiels

L'analyse acoustique constitue une méthode essentielle dans la surveillance conditionnelle des machines industrielles. Elle permet de détecter les bruits anormaux générés par des défauts naissants ou des dysfonctionnements au sein des composants mécaniques. Ces anomalies acoustiques, souvent imperceptibles à l'oreille humaine, sont captées à l'aide de capteurs spécifiques tels que des microphones haute sensibilité ou des capteurs piezoélectriques.

Cette technique est particulièrement efficace pour identifier des phénomènes tels que les frottements excessifs, les impacts, les fissures ou les déséquilibres qui se manifestent par des signatures sonores distinctes. Une fois détectés, ces bruits inhabituels nécessitent une analyse approfondie, soit par traitement numérique du signal, soit par comparaison avec des modèles de référence, afin de diagnostiquer précisément l'origine et la gravité du défaut.

Le tableau I.1 synthétise les différents types d'outils de surveillance adaptés selon les défauts potentiels identifiés, soulignant ainsi l'importance de sélectionner la méthode la plus appropriée en fonction du contexte opérationnel et des caractéristiques spécifiques des machines surveillées [24, 25].

TABLE I.1 – Choix de l’outil de surveillance en fonction des défauts potentiels.

Type de défauts	Analyse vibratoire	Thermographie IR	Analyse d’huiles	Analyse acoustique
Déséquilibres, balourd	Oui	Non (sauf en cas d’usure ou échauffement)	Non	Non
Jeux, défauts de serrage	Oui	Non (sauf en cas d’échauffement)	Non	Oui (notamment en cas de résonance)
Défauts spécifiques aux roulements	Oui	Oui	Oui	Oui
Défauts spécifiques aux engrenages	Oui	Oui	Oui	Oui
Défauts de courroies	Oui	Oui (échauffement possible)	Non	Oui
Défauts d’alignement	Oui	Parfois (si échauffement)	Non	Oui
Lubrification – dégradation de l’huile	Non (sauf cas de paliers hydrodynamiques)	Non	Oui	Non
Lubrification – manque d’huile	Oui	Oui	Oui	Oui
Défauts électromagnétiques (moteurs)	Oui (harmoniques spécifiques)	Oui	Non	Oui
Défauts d’écoulements (pompes, hydraulique)	Oui	Parfois (si échauffement fluide)	Non	Oui (sans caractéristiques)

I.9.1 Terminologies utilisées en surveillance

Dans le domaine de la surveillance, divers termes sont employés pour décrire les concepts et phénomènes observés [26, 30] :

- **Système** : Un ensemble défini d’éléments distincts (composants, parties) interconnectés ou en échange entre eux.
- **Processus** : renvoie à un système, équipement ou à une machine constituée d’éléments interagissant entre eux et avec leur environnement pour réaliser une tâche précise et créer de la valeur ajoutée.
- **Composant** : est un élément technologique faisant partie intégrante d’un processus industriel.
- **Dégradation** : correspond à une baisse de performance dans l’une des fonctions que remplit un équipement.
- **Défaut** : est une divergence par rapport aux conditions standards d’un paramètre du système.
- **Panne** : indique un état dans lequel un système ne parvient pas à remplir la fonction spécifiée en raison d’une défaillance.
- **Résidu** : Un résidu est un signal potentiellement indicatif d’anomalie.

I.10 Modélisation et évaluation des stratégies de maintenance

La modélisation et l'évaluation des stratégies de maintenance sont des facteurs cruciaux pour assurer une gestion optimale des systèmes industriels. Ces processus sont cruciaux pour anticiper les besoins en maintenance, optimiser les ressources, et garantir la disponibilité ainsi que la fiabilité des machines.

L'efficacité du modèle utilisé pour décrire le système est primordiale pour la prise de décisions sur les politiques de maintenance. Un modèle exacte et fiable simplifie la prévision du comportement du système et la planification des actions de maintenance.

La conception du modèle d'un système industriel, permet d'évaluer le comportement "a priori" en termes de probabilité d'occurrence d'événements tels que les pannes ou les dégradations. Elle permet également d'estimer l'évolution de l'état du système progressivement. Cela a une signification primordiale pour prendre des décisions éclairées en matière de maintenance.

Au milieu industriel, le pronostic consiste à anticiper l'état futur d'une installation basé sur son état actuel et son historique de fonctionnement [31].

On utilise habituellement deux approches majeures : la maintenance conditionnelle et la maintenance systématique. La maintenance conditionnelle est fondée sur l'utilisation de modèles de système avec les données recueillies par les dispositifs de surveillance en temps réel. Elle offre la possibilité de mettre en place des interventions selon l'état présent du système, telles que les pannes ou les dépassements des seuils.

En revanche, la maintenance systématique s'appuie principalement sur des modèles de durée de vie du système. Planification d'interventions à des moments précis, Quelle que soit l'état de fonctionnement ou d'usure du système étudié. Ces interventions peuvent être régulières ou basées sur des cycles préétablis. Le processus de création d'un modèle implique plusieurs étapes. Il est d'abord nécessaire de définir l'espace d'états, représentant l'ensemble des mesures pour décrire l'état fonctionnel du système à chaque instant. Puis, Les états qui entraînent la défaillance du système sont modélisés à l'aide de diverses approches, telles que les modèles en "boîte blanche", en "boîte noire" ou en "boîte grise" [32].

Ces approches offrent diverses perspectives sur le fonctionnement du système et sont sélectionnées en fonction des besoins spécifiques de la maintenance prédictive. Les données historiques sur les défaillances et les pannes peuvent être ajoutées aux modèles, ainsi qu'à des informations en temps réel issue de systèmes de surveillance.

En bref, pour une gestion optimale des systèmes industriels, la modélisation et l'évaluation des stratégies de maintenance sont d'une importance cruciale. L'entreprise peut améliorer leur opérations de maintenance en combinant des modèles bien crée avec des données de surveillance en temps réel, cela permet de maximiser la fiabilité et la disponibilité des équipements, réduire les coûts de maintenance, améliorer la productivité et renforcer la satisfaction des clients.

I.11 Généralités sur la sûreté de fonctionnement (SdF)

"Selon Alain Villemeur, la sûreté de fonctionnement est décrite comme l'aptitude d'une entité à remplir une ou plusieurs fonctions requises dans des conditions particulières. Elle démontre la confiance que l'on peut avoir dans un système, et la sûreté de fonctionnement est ainsi reconnue comme la science des défaillances et des pannes [33]."

Dans un système complexe, L'application de la sûreté de fonctionnement cherche à réduire le nombre de défaillances potentielles et les conséquences des défaillances possible. La sûreté de fonctionnement (SdF) englobe simultanément un ensemble de moyens et de résultats obtenus :

- Des approches et des outils pour identifier et gérer les conséquences des imprévus, des erreurs et des pannes.
- L'évaluation des caractéristiques des systèmes pour indiquer l'alignement de leurs comportements et actions sur le long terme.

"Diverses sources [33, 37] définissent la sûreté de fonctionnement comme le montre les éléments suivants :

- La fiabilité, la disponibilité, la maintenabilité et la sécurité.
- La science des défaillances.
- La confiance justifiée dans le service fourni.
- Le maintien de la qualité dans le temps.

La sûreté de fonctionnement, qui repose sur les critères de fiabilité, disponibilité, maintenabilité et sécurité (FDMS), souligne l'interconnexion de ces éléments. Bien que l'un de ces termes se rapporte à des performances spécifiques du système, la sûreté de fonctionnement ne se limite pas à une seule de ces performances, mais se construit à travers l'intégralité de ces dimensions [33].

La définition globale de la SdF intègre ces quatre dimensions pour offrir une vue d'ensemble plus complète de la sûreté de fonctionnement sous divers aspects.

I.12 Les critères de classification des méthodes d'analyse de la SdF

Dans l'évolution des systèmes complexes, il est devenu indispensable d'évaluer la sûreté de fonctionnement [33]. Pour optimiser ce développement, Il est nécessaire d'avoir des méthodes permettant d'évaluer la sûreté de fonctionnement tout au long du processus. Pour estimer la sûreté de fonctionnement d'un système, il est nécessaire d'analyser les défaillances des composants afin d'en mesurer l'impact sur le fonctionnement total. Classiquement, des méthodes comme l'Analyse Préliminaire des Risques (APR), l'Analyse des Modes de Défaillance de leurs Effets et de leurs Criticités (AMDEC), et les Arbres de Défaillances (AdD) ont été appliquées.

Néanmoins, ces approches conventionnelles sont sujettes à des limitations, principalement en ce qui touche leur capacité à gérer la complexité croissante des systèmes modernes. C'est là que les méthodes de Machine Learning interviennent. Ces approches repose sur des algorithmes d'apprentissage automatique pour le traitement des données et l'identification des modèles de défaillance, apportant ainsi des informations riches pour l'optimisation de sûreté de fonctionnement.

Les techniques de Machine learning offrent divers bénéfices. Permettant le traitement des données délivrées par les différents capteurs, l'analyse détaillé et approfondie des défaillances potentielles. De plus, ces méthodes peuvent identifier des modèles complexes et non linéaires qui pourraient échapper aux approches traditionnelles.

En outre, les méthodes de Machine Learning peuvent être adaptées aux systèmes dynamiques, Ce qui les rend extrêmement pertinentes pour l'analyse de la sûreté de fonctionnement. À titre d'exemple, la modélisation du comportement dynamique et la détection des défaillances en direct peuvent être effectuées par les réseaux de neurones artificiels.

I.13 Conclusion

Ce chapitre, dédié à la maintenance industrielle, constitue une composante essentielle de notre thèse intitulée "Diagnostic des défauts combinant engrenages et roulements par analyse vibratoire utilisant des réseaux de neurones convolutifs (CNN)". Ce secteur est essentiel pour garantir le bon fonctionnement des installations industriels et améliorer la fiabilité des processus de production.

Nous avons décrit les notions fondamentales de la maintenance industrielle, expliqué les différents types de maintenance, et présenté les techniques de surveillance relatives. Les stratégies de surveillance ont été aussi présentées, soulignant les avantages et les limites de chaque approche.

Le prochain chapitre explorera les concepts clés de l'analyse des vibrations et l'analyse des défauts dans les machines tournantes. Nous considérons spécifiquement l'application des réseaux de neurones convolutifs (CNN) pour le diagnostic des défauts combinés des engrenages et des roulements par l'utilisation de l'analyse vibratoire.

Les concepts généraux de la maintenance et de la sûreté de fonctionnement sont rappelés dans cette section, ainsi que la modélisation associées au maintenance prédictive.

Nous avons mis en évidence les types d'analyses des systèmes complexes, en particulier l'analyse fonctionnelle et l'analyse dysfonctionnelle ont été mises en évidence, mettant en évidence l'importance de la modélisation pour évaluer les stratégies de maintenance.

Nous avons notamment souligné l'importance des techniques statistiques et de simulation dans l'analyse des dysfonctionnements, puisque elles permettent la détection des défaillances des éléments composant le système. Tandis que qu'il existe de diverses méthodes d'analyse de la sûreté de fonctionnement, les processus stochastiques se révèlent particulièrement adaptés à la modélisation et à l'analyse des systèmes complexes, comme nous le développerons dans le chapitre suivant.

Chapitre II

Vibrations et Comportement aux Défauts Combinés dans les Engrenages et Roulements

II.1 Introduction

Les défaillances combinées d'engrenages et de roulements sont fréquentes dans les systèmes mécaniques et peuvent entraîner une dégradation des performances ainsi qu'une usure prématurée des composants. Dans cette section, Nous allons analyser les divers types de défauts combinés d'engrenages et de roulements, en utilisant des exemples pratiques. Nous discuterons aussi de manière approfondie, les signaux vibratoires issus de roulements et d'engrenages en étudiant les principes fondamentaux, les équations et les modèles associés. En addition, Nous procéderons à une analyse approfondie des différents phénomènes vibratoires associées aux défauts d'engrenages et de roulements.

II.2 Types de défauts

II.2.1 Défauts de roulements

L'importance des roulements est primordiale au niveau de toutes les machines tournantes. Ils sont susceptibles de présenter divers défauts dus à l'usure, à la faiblesse, à un manque de graissage, à des surcharges ou à des imperfections de fabrication. Les principaux types de défauts de roulements sont présentées dans le tableau II.1 :

TABLE II.1 – Types de défauts de roulement.

Type de défaut	Description
Défaut de la bague intérieure	Usure, fissures ou écaillage sur la surface de la bague intérieure, souvent localisés au même endroit à chaque rotation.
Défaut de la bague extérieure	Dommmages sur la surface de la bague extérieure, tels que des piqûres, fissures ou déformations.
Défaut des éléments roulants	Présence d'écaillage, de corrosion ou de fissures sur les billes ou les rouleaux du roulement.
Défaut de la cage	Déformation, usure ou rupture partielle de la cage qui maintient les éléments roulants en position.
Usure généralisée	Dégradation uniforme de l'ensemble des composants du roulement due à un fonctionnement prolongé.
Grippage	Collage ou soudure partielle entre les surfaces en contact, souvent causé par un manque de lubrification.




FIGURE II.1 – Roulement sain (b) défaut de la bague intérieure (c) défaut de la bague extérieure (d) défaut de la bille [38].

Défauts de la bague intérieure

Les défauts de la bague interne se manifestent quand des anomalies apparaissent sur la surface interne du roulement, souvent à cause de l'usure, de la fatigue ou d'une lubrification insuffisante. Ces défauts peuvent engendrer une augmentation du bruit et des vibrations, et dans les cas graves, peuvent provoquer une défaillance du roulement.

Défauts de la bague extérieure

Les défauts de la bague externe se manifestent quand des anomalies apparaissent sur la surface externe du roulement. Ils peuvent également causer une augmentation du bruit et des vibrations et peuvent conduire à une défaillance du roulement s'ils ne sont pas réparés.

Défauts des éléments roulants

Les rouleaux ou les billes, sont des éléments roulants qui peuvent également présenter des défauts dus à l'usure ou à la fatigue. Ces anomalies peuvent augmenter la vibration et le bruit et endommager le mode de fonctionnement du roulement.

Défauts de cage

Les défauts de la cage de roulement, attachent la structure de roulement qui supportent les éléments roulants (billes ou rouleaux). Ces défauts peuvent résulter de l'affaiblissement du matériau, de l'usure, de la corrosion, de la déformation produite par des chocs ou des surcharges.



FIGURE II.2 – Défaut de cage [39].

II.2.2 Défauts d'engrenages

Les engrenages sont également des composants essentiels dans de nombreuses machines rotatives et peuvent subir divers défauts. Ceux-ci sont souvent causés par l'usure, la fatigue, une lubrification insuffisante, des surcharges, ou des imperfections de fabrication. Le tableau II.2 expose les principaux types de défauts d'engrenages :

TABLE II.2 – Principaux défauts des engrenages

Catégorie de défaut	Description des dommages
Absence de dent	Une dent de l'engrenage est manquante, ce qui affecte son fonctionnement
Fissure à la base des dents	Apparition de fissures au niveau des racines des dents
Desquamation	Détachement de petites particules de matériau sur la surface des dents
Impact en bout de dent	Dommages concentrés au niveau de l'extrémité des dents

Défauts de denture

Ce genre de défauts est l'un des plus fréquents dans le domaine des engrenages. Ces défauts peuvent résulter de divers facteurs, tels que l'usure intensive, les influences mécaniques, la fatigue du matériau, et des défauts issus de la fabrication. Les symptômes associés englobent le bruit, les vibrations et la décroissance de l'efficacité de la transmission de puissance. L'identification de ce genre de défauts, implique l'utilisation de méthodes comme le contrôle visuelle, la thermographie, l'analyse des vibrations, et d'autre.



FIGURE II.3 – Défaut de denture [40].

Défauts de l'arbre d'engrenage

Ces défauts sont souvent causés par la fatigue, une torsion excessive, l'usure ou la corrosion. Ces défauts peuvent provoquer une déformation ou même une rupture de l'arbre, entraînant des dommages graves à l'ensemble du système mécanique. Pour détecter ces défauts, il est généralement nécessaire de réaliser une analyse vibratoire détaillée, une inspection visuelle, ou d'utiliser des techniques de mesure non destructives..

Défauts d'engrenage par pitting

Le pitting est une forme de dégradation de surface résulte par le détachement de petites zones de la surface d'engrenage à cause de la fatigue du matériau. Ce phénomène peut accroître la rugosité de surface, diminuer l'efficacité de la transmission de puissance et,



FIGURE II.4 – Défaut de l'arbre d'engrenage [41].

finalement, entraîner une panne totale de l'engrenage. Les méthodes d'identification du pitting incluent l'inspection visuelle, l'analyse de la texture de surface, et l'analyse vibratoire.




FIGURE II.5 – Défaut d'engrenage par pitting [42].

Défauts d'engrenage par fatigue de contact

La fatigue de contact se produit lorsque les surfaces des dents sont sujettes à des contraintes de contact répétées. Ce événement pourrait provoquer des fissures au niveau de la surface des dents, qui peuvent ensuite se propager et causer une défaillance.



FIGURE II.6 – Défaut d'engrenage par fatigue de contact [43].

II.2.3 Défauts combinés des engrenages et des roulements

Il arrive parfois que des défauts se produisent en même temps aux niveaux d'engrenages et de roulements d'un système mécanique. Ces défauts combinés sont souvent complexes

à diagnostiquer et à résoudre en raison des interactions entre les différents composants du système. Par exemple, un défaut dans un engrenage peut agrandir les contraintes sur les roulements, accélérant la dégradation et même l'usure. De la même manière, un problème dans un roulement peut perturber la marche des engrenages, entraînant une usure accrue et une dégradation des dents. Il est crucial de reconnaître que les défauts combinés peuvent avoir des effets synergiques, où l'impact total de ces défauts combinés dépasse la somme de leurs effets individuels. Cela les rend particulièrement nuisibles et difficiles à gérer.




FIGURE II.7 – Défaut combiné d'engrenage et de roulement [44].

La Figure II.7 illustre un exemple de défaut combiné d'engrenage et de roulement. Dans cet exemple, on constate simultanément une perte de dent sur l'engrenage et un défaut de bague intérieure et extérieure même défaut des éléments roulants du roulement. Ces derniers défauts combinés peuvent dégrader les performances du système.

II.2.4 Défauts de lubrification

La lubrification est un élément essentiel pour le fonctionnement optimal de nombreux systèmes mécaniques, en particulier ceux avec des engrenages et des roulements. Les défauts liés à la lubrification peuvent causer divers problèmes, tels qu'une usure, un excès de bruit et de vibration, et une réduction de la durée de vie des composants mécaniques.

Un certain nombre de facteurs peuvent engendrer des défauts de lubrification, tels qu'une quantité insuffisante de film d'huile, l'application d'un lubrifiant mal choisi, ou la pollution du lubrifiant par des particules de saleté ou d'autres substances étrangères. Parfois, les défauts d'huile peuvent provoquer des problèmes de conception, comme des anomalies dans le mécanisme de distribution du lubrifiant.




FIGURE II.8 – Défaut de lubrification [45].

II.3 Fondements de la Vibration des Roulements et des Engrenages

II.3.1 Analyse des Vibrations des Roulements

Les vibrations des roulements résultent principalement d'imperfections géométriques, de défauts de surface, de charges variables et d'interactions avec d'autres composants du système mécanique. Ces vibrations peuvent être modélisées en utilisant les équations du mouvement et les propriétés matérielles des roulements.

Équations de Mouvement

Le mouvement d'un élément roulant dans un roulement peut être modélisé par l'équation de Newton-Euler :

$$m\ddot{x} + c\dot{x} + kx = F(t) \quad (\text{II.1})$$

où m désigne la masse de l'élément roulant, x est sa position, \ddot{x} représente l'accélération, \dot{x} est la vitesse, c est le coefficient d'amortissement, k la rigidité, et $F(t)$ la force externe appliquée.

Théorie de Hertz pour le Contact

Le contact entre les éléments roulants et les chemins de roulement peut être décrit par la théorie de contact de Hertz. Cette théorie indique que la force de contact $F(t)$ est proportionnelle au déplacement relatif δ :

$$F(t) = k_c \delta^n \quad (\text{II.2})$$

où k_c représente la rigidité de contact selon Hertz, et n est un exposant dépendant du type de contact (en général, $n = 1.5$ pour un contact sphérique et $n = 2$ pour un contact cylindrique).

II.3.2 Analyse des Vibrations des Engrenages

Les vibrations dans les engrenages sont engendrées par les déformations structurelles, les imprécisions de placement, les variations de charge, le mauvais état de surface et les interactions avec d'autres composants du système mécanique. Elles peuvent être modélisées à l'aide des équations du mouvement et des propriétés matérielles des engrenages.

Équations du Mouvement

L'équation du mouvement d'un engrenage est donnée par l'équation de Newton-Euler :

$$m\ddot{\theta} + c\dot{\theta} + k\theta = M(t) \quad (\text{II.3})$$

où m est la masse de l'engrenage, θ est son angle, $\ddot{\theta}$ est son accélération angulaire, $\dot{\theta}$ est sa vitesse angulaire, c est un coefficient d'amortissement angulaire, k est la rigidité angulaire, et $M(t)$ est le moment externe appliqué.

Modèle de Contact des Dents d'Engrenage

Le contact entre les dents d'engrenage peut être modélisé par la théorie de contact élastique. Selon cette théorie, la force de contact $F_{contact}(t)$ est proportionnelle au déplacement relatif δ des dents :

$$F_{contact}(t) = k_g \delta^n \quad (II.4)$$

où k_g c'est la rigidité du contact des dents, et n c'est un exposant dépendant du type de contact (généralement compris entre 1.5 et 2).

Modèle de Vibration Global

Dans le cadre de la modélisation de vibration globale du système mécanique comportant des roulements et des engrenages, il est important de prendre en compte l'interaction entre les différents éléments et les origines de vibration. On peut établir un modèle de vibration global en combinant les équations du mouvement des roulements et des engrenages avec les modèles de contact. La résolution numérique de ce modèle s'effectue en utilisant des techniques de simulation, telles que la méthode des éléments finis ou la méthode de Monte Carlo.

II.4 Identification des Défauts à Partir des Vibrations

L'analyse vibratoire est une technique indispensable pour identifier les défauts dans les roulements et les engrenages. En analysant les caractéristiques des vibratoires telle que l'amplitude, la fréquence et la phase, on peut détecter et diagnostiquer divers défauts, comme les fissures, les bris de dents et les déformations.

II.4.1 Techniques de Traitement du Signal

De nombreuses techniques de traitement du signal sont offertes afin d'analyser les vibrations. Notamment :

- Analyse temporelle : se fait par le calcul d'indicateurs statistiques, telles que la valeur moyenne, l'écart-type et le facteur de crête à partir du signal vibratoire dans le domaine temporel.
- Analyse fréquentielle : se fait par l'application de la transformée de Fourier pour passer au domaine fréquentiel et identifier les fréquences caractéristiques de défauts dominantes.
- Analyse temporelle-fréquentielle : se fait par application des méthodes, comme la transformée de Fourier à court terme (STFT) ou la transformée en ondelettes pour analyser les variations temporelles des fréquences caractéristiques.
- Analyse non linéaire : Application de techniques telles que l'analyse de récurrence ou l'entropie de permutation pour détecter les comportements non linéaires dans les vibrations, souvent liées à des défauts complexes ou progressifs.

II.4.2 Caractéristiques des Défauts de Roulements et d'Engrenages

Ce type de défaut peut être identifié en examinant les caractéristiques des vibrations, comme :

- Amplitude : Une augmentation soudaine de l'amplitude de la vibration peut indiquer un défaut, tel qu'une fissure ou un bris de dent.
- Fréquence : Des fréquences spécifiques sont souvent produites par les défauts de roulements et d'engrenages, qui peuvent être repérées en analysant le spectre de fréquence. A titre d'exemple, les fréquences caractéristiques des défauts de roulement (BSF, BPFI, BPFO, etc.), sont liées aux défauts rencontrés dans les roulements. Alors que les fréquences de défaut des engrenages (mesh, harmoniques, etc.) sont associées aux défauts rencontrés dans les engrenages.
- Modulation : Les déformations d'engrenages ou la combinaison de défaut engrenage-roulement peuvent être signalés par la présence de modulation d'amplitude ou de fréquence dans le signal vibratoire.
- Phase : Les changements de phase entre les signaux vibratoires mesurés en différents points du système peuvent offrir des données utiles sur la localisation et la nature des défauts.
- Non-linéarité : Les défauts complexes ou évolutifs peuvent introduire des comportements non linéaires dans les vibrations, qui peuvent être détectés en faisant appel aux techniques d'analyse non linéaire.

II.5 Méthodes de Détection et de Diagnostic des Défauts Combinés

Il est essentiel d'utiliser des techniques avancées pour la détection et le diagnostic des défauts combinés dans les engrenages et roulements, afin d'analyser et d'interpréter les signaux vibratoires et les données provenant des différents capteurs. Parmi ces techniques, on cite :

- Analyse spectrale (FFT)
- Analyse temps-fréquence (ondelettes)
- Analyse de la variabilité instantanée
- Méthodes statistiques et basées sur les caractéristiques
- Méthodes d'apprentissage automatique (SVM, K-NN, Random Forest)
- Réseaux de neurones profonds (CNN, RNN, LSTM)

II.5.1 Méthodes Traditionnelles d'Analyse Vibratoire

Il existe plusieurs techniques d'analyse vibratoire, allant de méthodes simples basées sur le temps ou la fréquence à des méthodes plus avancées qui fusionnent les informations temporelles et fréquentielles.

Analyse Spectrale (FFT)

L'analyse spectrale, connue aussi par l'analyse fréquentielle, est une méthode largement utilisée pour l'analyse vibratoire. Elle se base sur la transformation du signal vibratoire du domaine temporel vers le domaine fréquentiel, d'une manière générale, en utilisant la transformée de Fourier. Les fréquences caractéristiques des défauts associées aux engrenages et roulements

peuvent être identifiées à partir du spectre de fréquence et utilisées pour diagnostiquer les défauts. Cependant, l'analyse spectrale présente des limitations, notamment dans les cas où les signaux sont non stationnaires ou présentent des défauts combinés

L'analyse spectrale permet de décomposer un signal dans le domaine fréquentiel. La méthode la plus couramment utilisée pour l'analyse spectrale est la Transformée de Fourier Rapide (Fast Fourier Transform - FFT). La FFT d'un signal $x(t)$ est définie par :

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (II.5)$$

La FFT convertit le signal du domaine temporel en domaine fréquentiel, ce qui permet d'identifier les fréquences présentes dans le signal. En ce qui concerne le diagnostic des défauts, les fréquences spécifiques peuvent être associées à certains types de défauts.




FIGURE II.9 – Extraction du spectre de fréquences à l'aide de la FFT.

Analyse Temps-Fréquence (Ondelettes)

L'analyse temps-fréquence s'associe les atouts des analyses temporelle et fréquentielle, permettant l'analyse des caractéristiques des signaux vibratoires dans les domaines temporels et fréquentiels. Des méthodes telles que la transformée de Fourier à court terme (STFT), la transformée en ondelettes et l'analyse de Wigner-Ville sont couramment utilisées pour obtenir des représentations temps-fréquence. Toutefois, ces méthodes peuvent être sensibles au bruit et aux altérations aux paramètres opérationnels.

Une ondelette est une fonction intégrée à zéro, utilisée pour décomposer le signal en différentes échelles. La transformée en ondelettes continue (Continuous Wavelet Transform - CWT) d'un signal $x(t)$ avec une ondelette $\psi(t)$ est définie comme suit :

$$CWT(s, \tau) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{s}} \psi\left(\frac{t - \tau}{s}\right) dt \quad (II.6)$$

où s est l'échelle et τ est la translation. La CWT fournit une représentation temps-fréquence du signal, utile pour identifier les défauts évoluant avec le temps.

Analyse de la Variabilité Instantanée

L'analyse de la variabilité instantanée (Instantaneous Variability Analysis IVA) mesure la variation de la fréquence d'un signal dans le temps. Elle est particulièrement utile pour

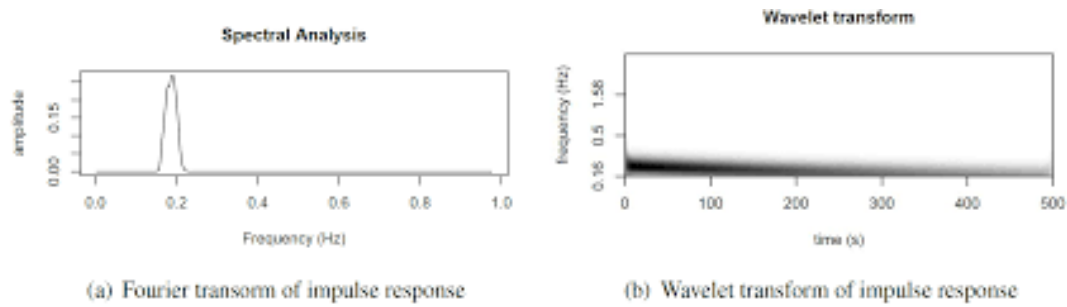


FIGURE II.10 – Analyse spectrale et CWT.

analyser les signaux qu'ils ne sont pas stationnaires, dont les caractéristiques statistiques évoluent au cours du temps. Les signaux vibratoires provenant de machines, comme les et engrenages et les roulements, sont souvent non stationnaires à cause des changements d'états de fonctionnement [46].

L'IVA s'appuie sur la notion de fréquence instantanée, qui est définie comme la dérivée de la phase d'un signal analysé. Si on considère un signal analytique $x(t)$, sa fréquence instantanée sera déterminée par :

$$f_i(t) = \frac{1}{2\pi} \frac{d\phi(t)}{dt} \quad (\text{II.7})$$

où $\phi(t)$ est la phase de $x(t)$.

Méthodes Statistiques et Basées sur les Caractéristiques

L'analyse vibratoire est fréquemment traitée à partir de méthodes statistiques. En mettant l'accent sur l'analyse des caractéristiques du signal vibratoire dans le domaine temporel. Des indicateurs statistiques comme l'énergie du signal, la valeur moyenne, l'écart-type, le kurtosis et le skewness peuvent être calculés pour décrire le comportement du signal. Bien que l'analyse temporelle soit simple et intuitive, elle peut manquer de précision pour détecter des défauts complexes ou combinés. L'énergie du signal est calculée comme la somme des carrés des amplitudes du signal. Si nous avons un signal $x(t)$ avec N points, son énergie est donnée par :

$$E = \sum_{n=0}^{N-1} |x(n)|^2 \quad (\text{II.8})$$

Les moments statistiques du kurtosis et du skewness offrent des données sur la distribution du signal. Le calcul du kurtosis est effectué à l'aide de cette formule :

$$Kurtosis = E \left[\left(\frac{x - \mu}{\sigma} \right)^4 \right] \quad (\text{II.9})$$

où $E[\]$ c'est l'Espérance, μ c'est la Moyenne du signal et σ c'est l'écart-type.

Le skewness est calculé par :

$$Skewness = E \left[\left(\frac{x - \mu}{\sigma} \right)^3 \right] \quad (\text{II.10})$$

Ces propriétés peuvent agir comme des entrées pour un algorithme d'apprentissage automatique facilitant ainsi la création d'un modèle de détection de défauts.

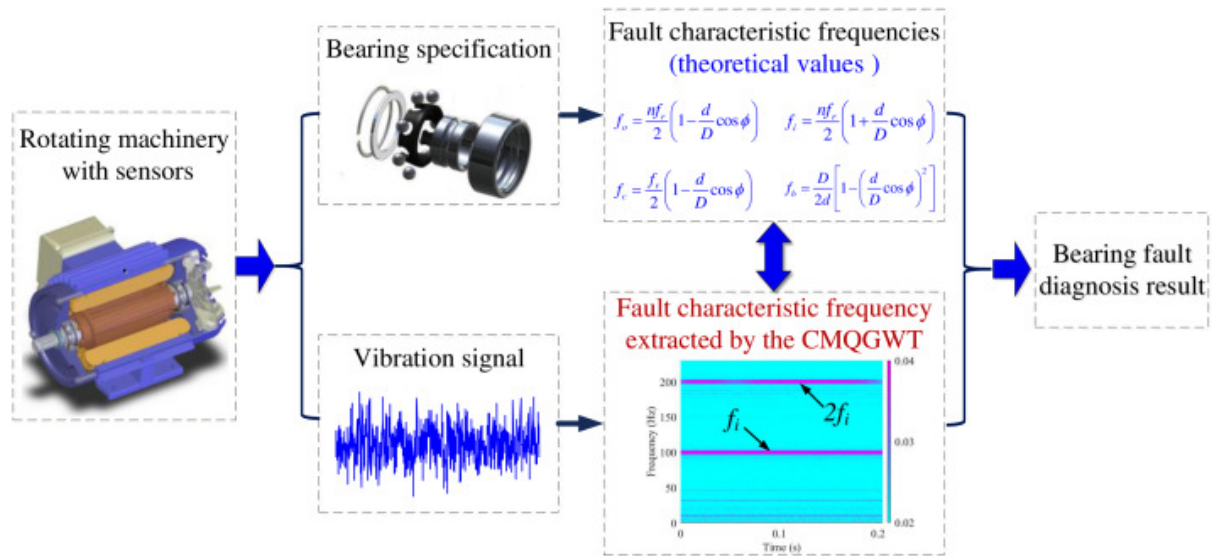


FIGURE II.11 – Exemple de méthodes traditionnelles pour détecter un signal de vibration[47].

II.5.2 Méthodes d'Apprentissage Automatique et Réseaux de Neurones Profonds

De plus en plus, les techniques d'apprentissage automatique et les réseaux de neurones profonds sont employés afin de détecter et diagnostiquer les défauts d'engrenage et de roulement. Ces techniques ont la capacité d'acquérir des connaissances sur des modèles complexes et des caractéristiques à partir des données vibratoires, ce qui peut Optimiser la précision et la robuste de la détection et du diagnostic des défauts.

Réseaux de neurones profonds

Le domaine de la détection et du diagnostic des défauts combinés d'engrenages et de roulements, est largement influencé par les réseaux de neurones profonds, comme les réseaux de neurones convolutionnels (CNN), les réseaux de neurones récurrents (RNN) et les réseaux de mémoire à long terme (LSTM). Ces approches avancées ont la capacité automatique d'acquérir des caractéristiques pertinentes à partir des données vibratoires et de traiter des séquences temporelles longues et complexes.

La figure II.12 illustre l'utilisation de réseaux neuronaux profonds pour le diagnostic des défauts des roulements.

CNN (Convolutional Neural Networks) Les CNN sont particulièrement efficaces pour l'analyse des données spatiales et temporelles. Les CNN peuvent être employés dans le secteur des systèmes mécaniques afin d'extraire des caractéristiques à partir de signaux vibratoires. Ils permettent en plus d'identifier de manière précise des défauts. Grâce à leur compétence à détecter les relations spatiales dans les données, les CNN sont un outil puissant pour diagnostiquer les problèmes.

RNN (Recurrent Neural Networks) Les RNN sont conçus pour le traitement de séquences de données, exploitant des connexions récurrentes qui leur offrent la capacité de mémoriser des informations sur une longue période. Cette caractéristique est particulièrement utile

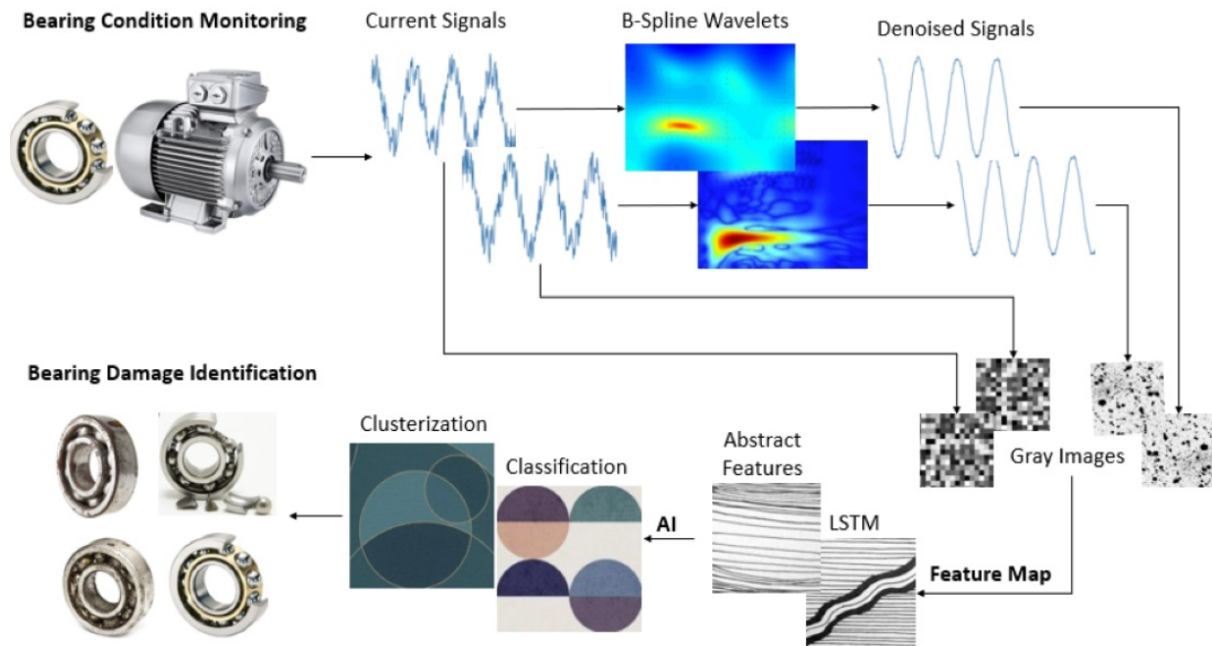


FIGURE II.12 – Exemple d’utilisation de réseaux de neurones profonds pour diagnostiquer les défauts de roulement.[48].

pour analyser les séries temporelles de données de vibration, où les événements passés peuvent influencer le comportement actuel.

LSTM (Long Short-Term Memory) Les LSTM, une variante des RNN, Ils sont spécifiquement conçus pour remédier au problème du gradient évanescent et pour capturer les dépendances à long terme présentes dans les données séquentielles. Les LSTM sont employés pour modéliser des séquences temporelles complexes, permettant ainsi d’atteindre une détection plus fine des défauts dans les systèmes mécaniques à des dynamiques complexes.

Méthodes d’apprentissage automatique

Les machines à vecteurs de support (SVM), les k-plus proches voisins (K-NN) et les forêts aléatoires (Random Forest) sont des algorithmes d’apprentissage automatique essentiels pour le diagnostic des défauts d’engrenage et de roulement. En général, ces méthodes requièrent une étape d’extraction de caractéristiques à partir des données vibratoires, comme les statistiques de base, les coefficients de Fourier et les coefficients d’ondelettes. La figure II.13 fournit un exemple d’application de méthodes d’apprentissage automatique pour le diagnostic des défauts d’engrenages et de roulements.

SVM (Support Vector Machines) Les SVM sont des modèles d’apprentissage supervisé efficaces pour la classification et la régression des données. Ils peuvent être utilisés pour séparer les différentes classes de défauts en utilisant un hyperplan optimal. Les SVM sont robustes et bien adaptés aux petits ensembles de données où les caractéristiques extraites sont discriminantes.

K-NN (K-Nearest Neighbors) La méthode de classification basée sur la distance, permet d’attribuer une classe à un échantillon en fonction des classes des k voisins les plus proches dans l’espace de caractéristiques. K-NN est une méthode de classification simple à implémenter et peut servir à diagnostiquer les défauts d’après la similarité des caractéristiques extraites.

Random Forest Random Forest un type de classification repose sur des arbres de décision. Ce

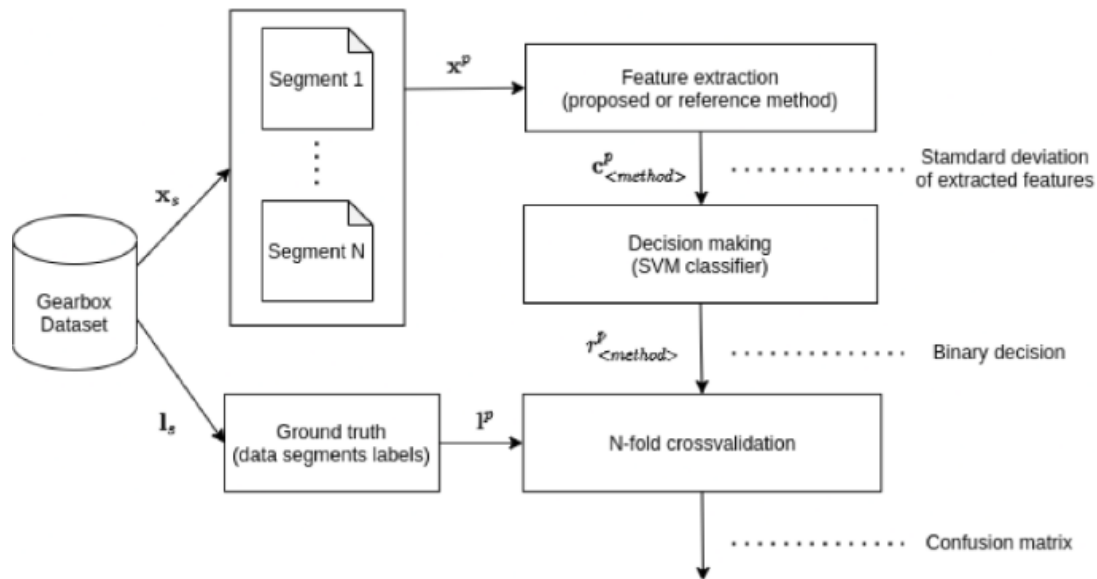


FIGURE II.13 – Exemple d'utilisation de méthodes d'apprentissage automatique pour diagnostiquer les défauts d'engrenage et de roulement.[49].

type offre une robustesse et une précision accrues en associant les prédictions de plusieurs arbres de décision Préparés à partir de sous-ensembles aléatoires de données. Les forêts aléatoires offrent une grande efficacité dans la gestion d'ensembles de données de grande taille et permettent d'évaluer l'importance des caractéristiques.

II.6 Conclusion

Dans ce chapitre, nous avons expliqué les divers aspects relatifs aux vibrations et la combinaison d'engrenages et de roulements comme un défaut. Nous avons aussi détaillé les différents types de défauts qui peuvent survenir dans les roulements et les engrenages, ainsi que les défauts qui peuvent apparaître lorsqu'ils sont utilisés ensemble. Nous avons également discuté des problèmes de lubrification qui peuvent affecter la performance de ces éléments mécaniques. En nous basant sur ces connaissances, nous avons redéfini les bases de l'analyse vibratoire de ces composants. Cela nous a donné l'occasion de comprendre comment ces vibrations peuvent être utilisées pour identifier les défauts. Nous avons par la suite exploré les diverses approches de traitement du signal qui permettent d'extraire des données significatives des signaux vibratoires. D'autre part, Nous avons pris en compte les spécificités des défauts de roulements et d'engrenages qui peuvent être identifiées à partir des signaux. Enfin, On a examiné les diverses techniques qui peuvent être employées afin de détecter et de diagnostiquer les défauts associés. Cela inclut les techniques classiques d'analyse vibratoire ainsi que les techniques plus contemporaines utilisant l'apprentissage automatique et les réseaux de neurones profonds.

En résumé, l'analyse et le diagnostic des défauts associés dans les engrenages et les roulements sont des opérations complexes, qui exigent une bonne connaissance de la dynamique des systèmes mécaniques, ainsi que des techniques progressives de traitement du signal et d'apprentissage automatique. Les travaux présentés dans ce chapitre constituent une base solide pour notre recherche future dans cette thèse.

Chapitre III

Réseaux de Neurones Profonds (CNN) et Apprentissage Automatique pour le Diagnostic des Défaits Combinés

III.1 Introduction

Le développement rapide des technologies d'apprentissage automatique, notamment les réseaux de neurones convolutifs (CNN), a ouvert de nouvelles occasions dans différents secteurs d'application, incluant le diagnostic des défauts dans les systèmes industriels. Les défauts des engrenages et des roulements, surtout quand ils se produisent simultanément, constituent un défi de taille pour les ingénieurs en maintenance. Même si les méthodes traditionnelles sont fréquemment employées, mais toujours présentent des obstacles au niveau de la précision, d'efficacité et de compétence pour gérer mieux des défaillances vraiment compliquées.

Le présent chapitre, explore l'utilisation des techniques d'apprentissage automatique, en particulier les CNN, pour le diagnostic des défauts combinés de roulements et d'engrenages. Nous entamons par un aperçu sur les CNN, suivie d'une analyse de différentes méthodes d'apprentissage automatique appliquées au diagnostic des défauts. Nous examinons ensuite l'application de ces techniques pour identifier les défaillances combinées.

Toutefois, malgré leur potentiel, ces méthodes présentent aussi des défis. Pour cette raison, nous traiterons les limitations et les obstacles associés à l'utilisation des réseaux neuronaux convolutionnels et des méthodes d'apprentissage automatique dans le diagnostic des défaillances combinées. L'objectif de ce chapitre est de fournir une vision approfondie de ces approches et de leur pertinence dans le domaine du diagnostic des défauts.

III.2 Réseaux de neurones convolutifs (CNN)

"Les réseaux de neurones convolutifs (CNN), initialement développés par Yann LeCun en 1998, sont des modèles de réseaux neuronaux artificiels conçus spécifiquement pour traiter des données d'entrée sous forme de pixels, comme dans les applications de reconnaissance et de traitement d'images.". Les CNN marchent de manière similaire à d'autres réseaux neuronaux, mais chaque couche CNN effectue un filtrage à deux dimensions (ou plus) qui est convolué avec l'entrée de la couche. Ce processus est essentiel pour l'apprentissage de mécanismes par de des entrées très grandes. Le filtrage des CNN englobe des informations contextuelles en adoptant une structure spatiale similaire, bien que réduite, au contenu d'entrée, tout en mettant en œuvre des stratégies pour minimiser considérablement le nombre de variables neuronales de type feedforward.

Les CNN sont actuellement la méthode dominante pour la majorité des applications de recherche d'images et de reconnaissance vocale. Dans cette section, nous détaillerons les CNN. La Figure III.1 montre l'architecture d'un CNN normal, se compose d'une série de couches. Les premières couches contiennent des couches convolutives et des couches de pooling, alors que la couche finale inclut une couche entièrement interconnectée et un modèle de classification standard.

III.2.1 Couche de convolution

La couche initiale d'un CNN est désignée sous le nom de couche de convolution. Elle est formée d'une série de filtres appliqués à l'entrée pour obtenir une carte de caractéristiques en sortie. Ces filtres, ou noyaux de convolution, partagent les mêmes poids pour tous les neurones qui les composent. Chaque filtre est conçu pour identifier une caractéristique spécifique des données d'entrée. Par exemple, dans la classification d'images, certains filtres peuvent être conçus pour la détection des contours, alors que d'autres sont employés

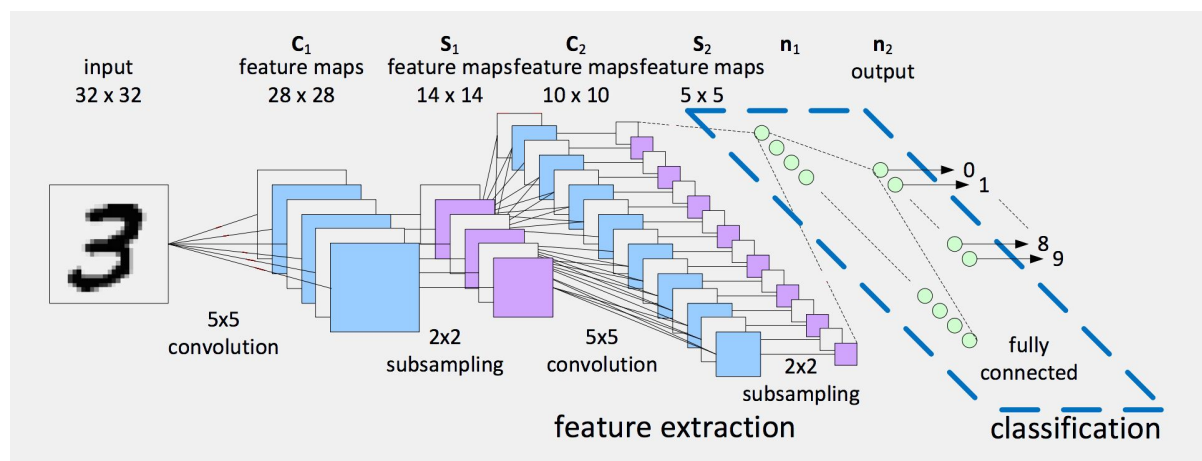


FIGURE III.1 – Exemple de réseau de neurones convolutif (CNN).

pour l'identification des couleurs ou des textures. Ces différents aspects d'une image peuvent ainsi être analysés à l'aide de ces filtres.

$$Y_{ij}^{(k)} = \sum_m \sum_n W_{mn}^{(k)} X_{i+m, j+n} + b^{(k)} \quad (\text{III.1})$$

où :

- $X_{i+m, j+n}$ est la valeur d'entrée à la position $(i + m, j + n)$,
- $W_{mn}^{(k)}$ représente le poids du filtre à la position (m, n) pour la k -ième carte de caractéristiques,
- $b^{(k)}$ correspond au biais pour la k -ième carte de caractéristiques,
- $Y_{ij}^{(k)}$ est la valeur de sortie obtenue.

III.2.2 Couche de Pooling

Une couche de pooling (ou sous-échantillonnage) est souvent utilisée après la couche de convolution afin de diminuer les dimensions des cartes de caractéristiques tout en conservant les informations les plus importantes. La couche de pooling réalise une opération de pooling, y compris le max pooling ou le pooling moyen, sur des régions distinctes de la carte de caractéristiques.

$$Y_{ij}^{(k)} = \max_{m \in M, n \in N} X_{i+m, j+n}^{(k)} \quad (\text{III.2})$$

où :

- M et N représentent la région de pooling,
- $X_{i+m, j+n}^{(k)}$ désigne la valeur de la carte de caractéristiques à la position $(i + m, j + n)$ pour la k -ième carte de caractéristiques,
- $Y_{ij}^{(k)}$ correspond à la valeur de sortie à la position (i, j) pour la k -ième carte de caractéristiques.

III.2.3 Couche entièrement connectée

La couche terminale principale d'un CNN est nommée par la couche entièrement connectée. Elle prend toutes les sorties des couches précédentes et les transforme en un vecteur unidimensionnel.

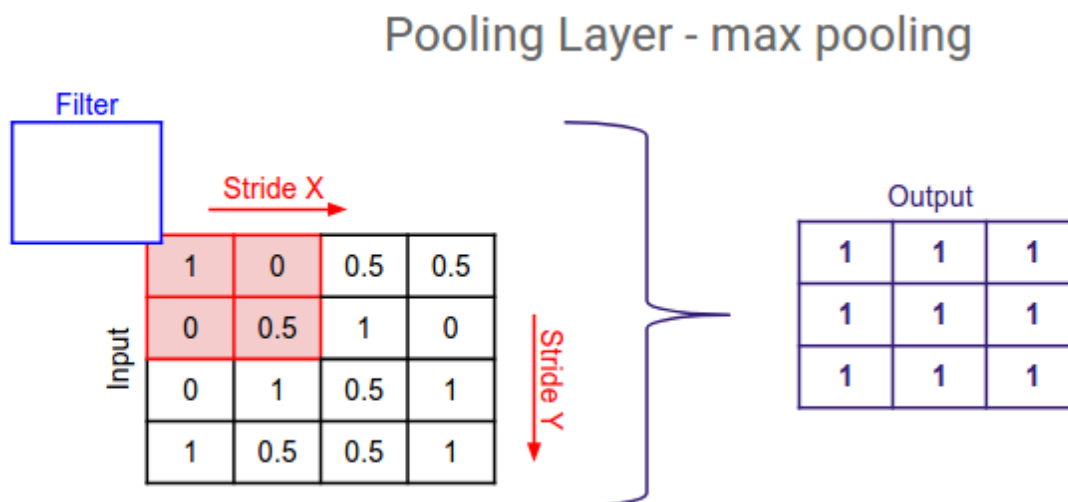


FIGURE III.2 – Exemple de Max Pooling.

La classification ou la regression se est accomplie par cette couche. Pour classifier, une fonction d’activation softmax est souvent utilisée pour convertir les sorties en probabilités associées à chaque classe.




FIGURE III.3 – Exemple de couche entièrement connectée.

$$Y_i = \frac{e^{X_i}}{\sum_j e^{X_j}} \quad (\text{III.3})$$

où :

- X_i représente l’entrée à la position i ,
- Y_i correspond à la sortie (ou probabilité) pour la classe i .

III.3 Application des CNN pour le diagnostic de défauts d’engrenages et de roulements

L’application des CNN au diagnostic des défauts d’engrenages et de roulements est basées sur la conversion des signaux vibratoires en images 2D, que le CNN peut ensuite traiter.

Ces images peuvent être générées à l'aide de techniques telles que les spectrogrammes, l'encodage en couleur de l'amplitude du signal, ou les cartes de cohérence. Les CNN ont l'avantage d'extraire automatiquement les caractéristiques pertinentes de ces images, ce qui peut améliorer la précision du diagnostic par rapport aux méthodes traditionnelles basées sur les caractéristiques.

Lorsque il s'agit de défauts combinés, l'un des principaux défi est que plusieurs types de défauts peuvent générer des signaux vibratoires très similaires, induisant leur distinction difficile. Cependant, les CNN ont démontré leur capacité à détecter des motifs subtils et complexes dans les données, ce qui pourrait les rendre particulièrement efficaces pour le diagnostic des défauts combinés.




FIGURE III.4 – Exemple d'architecture d'un réseau de neurones convolutifs pour le diagnostic des défauts d'engrenages et de roulements.

La figure III.4 souligne l'architecture typique d'un CNN utilisé pour diagnostiquer les défauts d'engrenages et de roulements. L'entrée du réseau est une image bidimensionnelle représentant le signal vibratoire, La sortie permet de prédire la classe de défaut.

III.3.1 Prétraitement des données

La première étape dans l'utilisation des CNN pour le diagnostic de défauts implique le prétraitement des données. Ce processus inclut la conversion des signaux de vibration en images ainsi que la division des données en ensembles d'entraînement, de validation et de test. Ce partitionnement est essentiel pour évaluer la capacité du modèle à généraliser lorsqu'il est confronté à de nouvelles données.

III.3.2 Entraînement du modèle

Après le prétraitement, l'entraînement du modèle peut commencer. Cet entraînement repose sur l'utilisation d'un algorithme d'optimisation, tel que la descente de gradient stochastique, afin de réduire une fonction de coût, comme la cross-entropie. La fonction précédente évalue l'écart entre les prédictions du modèle et les classes réelles. Lors de cette phase, les poids et biais du réseau sont ajustés pour améliorer progressivement la précision du modèle.

III.3.3 Évaluation du modèle

Une fois l'entraînement terminé, le modèle est testé sur l'ensemble de données réservé à cet effet pour en évaluer la performance globale. Il est aussi crucial d'analyser les performances du modèle pour chaque classe de défaut, car certains peuvent s'avérer plus difficiles à détecter que d'autres.

III.3.4 Interprétation des résultats

L'interprétation des résultats est une étape clé pour comprendre les types de défauts que le modèle est capable de détecter avec succès et ceux qui posent des difficultés. Cette analyse peut orienter les améliorations futures du modèle et la conception de stratégies pour affiner la précision de diagnostic.

III.4 Défis et limitations des CNN dans le diagnostic des défauts combinés

En dépit des résultats encourageants des CNN dans le diagnostic de défauts, il reste encore plusieurs défis et limitations. Par exemple, l'entraînement de ces réseaux nécessite des volumes de données importants, ce qui peut poser problème dans le cas de certains défauts qui se produisent rarement. De même, l'opacité des CNN, la plupart du temps qualifiés de "boîtes noires", peut compliquer l'interprétation des décisions prises par le modèle. Par ailleurs, l'entraînement de CNN, en particulier pour les modèles avancés comportant des millions de paramètres, peut entraîner des coûts importants en termes de temps et de ressources informatiques.

Même avec ces obstacles, les CNN représentent une avancée significative dans le domaine du diagnostic des défauts.

III.5 Techniques d'apprentissage automatique pour la détection des défauts

L'apprentissage automatique présente un potentiel significatif dans le domaine de la détection et le diagnostic des défauts dans les systèmes mécaniques [50]. Cette section passe en revue plusieurs méthodes, dont AFS-SVM, MLP, SVM, K-NN, LR, RF, et GNB.

III.5.1 AFS-SVM (Adaptive Feature Selection-Support Vector Machine)

L'AFS-SVM associe la sélection adaptative des caractéristiques à une machine à vecteurs de support (SVM), permettant une sélection efficace des caractéristiques les plus pertinentes pour la détection des défauts [51]. Le concept clé de la SVM est de déterminer l'hyperplan qui maximise la marge entre les classes [52]. Le SVM a l'équation suivante :

$$f(x) = \langle w, x \rangle + b \quad (\text{III.4})$$

où :

- w est le vecteur de poids,
- x représente le vecteur d'entrée,
- b est le biais.

La figure III.5 illustre comment une machine à vecteurs de support (SVM) sépare les classes dans un espace bidimensionnel.

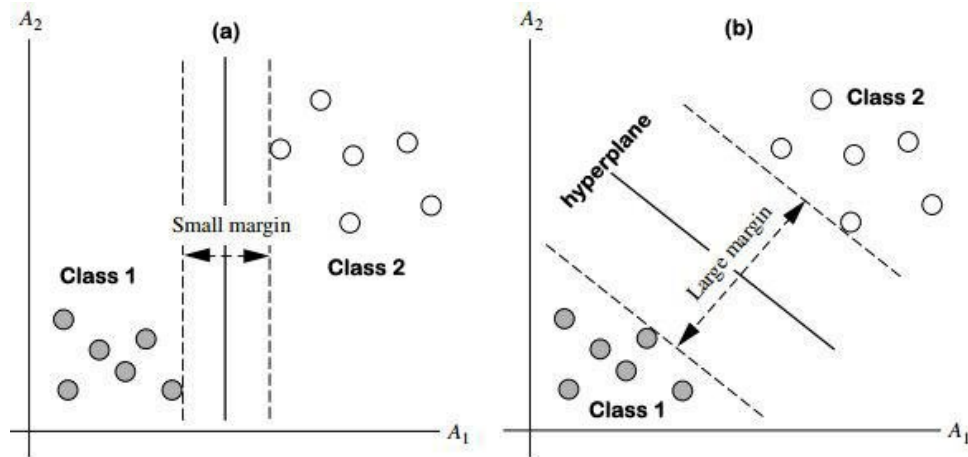


FIGURE III.5 – Illustration de la séparation des classes par SVM.

III.5.2 MLP (Multi-Layer Perceptron)

Le perceptron multicouche (MLP) constitue un réseau de neurones artificiels de type feedforward. Il est apte à modéliser des relations non linéaires entre les paramètres d'entrées et de sorties, ce qui le rend parfaitement efficace à la détection de défauts [53]. Un MLP intègre de différentes couches de neurones, chaque neurone effectuant un calcul de la combinaison linéaire des entrées suivie d'une fonction d'activation non linéaire. Dans un MLP, l'équation d'un neurone est :

$$y = \phi \left(\sum_i w_i x_i + b \right) \quad (\text{III.5})$$

où :

- y est la sortie du neurone,
- ϕ représente la fonction d'activation,
- w_i sont les poids associés à chaque entrée,
- x_i sont les valeurs d'entrée,
- b est le biais.

La figure III.6 montre la structure d'un perceptron multicouche (MLP).

III.5.3 LR (Logistic Regression)

La régression logistique est une technique d'apprentissage supervisé qui utilise une fonction logistique pour estimer la probabilité qu'un échantillon appartienne à une certaine classe [54]. Elle est un cas particulier des modèles linéaires généralisés. L'équation de la régression logistique est :

$$P(Y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X)}} \quad (\text{III.6})$$

où :

- $P(Y = 1|X)$ représente la probabilité que l'échantillon appartienne à la classe 1,
- X est le vecteur des caractéristiques d'entrée,
- β_0 et β_1 sont les coefficients estimés du modèle.




FIGURE III.6 – Structure d'un perceptron multicouche.

III.5.4 K-NN (K-Nearest Neighbors)

L'algorithme K-NN est une méthode d'apprentissage supervisé qui repose sur le principe que les échantillons similaires ont tendance à être regroupés [55]. Pour classer un nouvel échantillon, K-NN identifie les k adjacents les plus proches dans l'espace des caractéristiques, après accorde à l'échantillon la classe majoritaire parmi ces voisins. La figure III.7 illustre le principe de fonctionnement du K-NN.

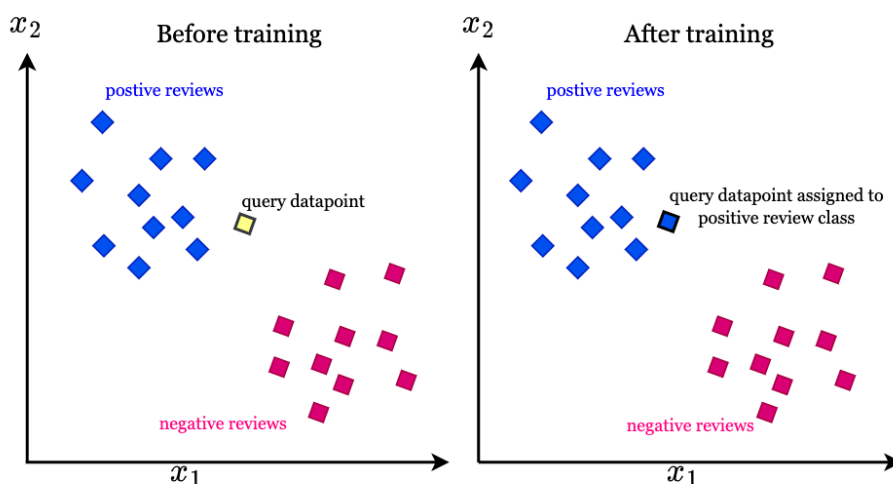


FIGURE III.7 – Principe de l'algorithme K-NN.

III.5.5 RF (Random Forest)

La technique de la forêt aléatoire est une approche d'apprentissage supervisé, qui construit un ensemble d'arbres de décision pendant l'entraînement, ensuite réalise des prédictions en combinant les résultats de ces arbres [56]. Cette méthode est robuste face aux nombreuses variables d'entrée et permet d'éviter le surapprentissage. La figure III.8 illustre le fonctionnement de la forêt aléatoire.

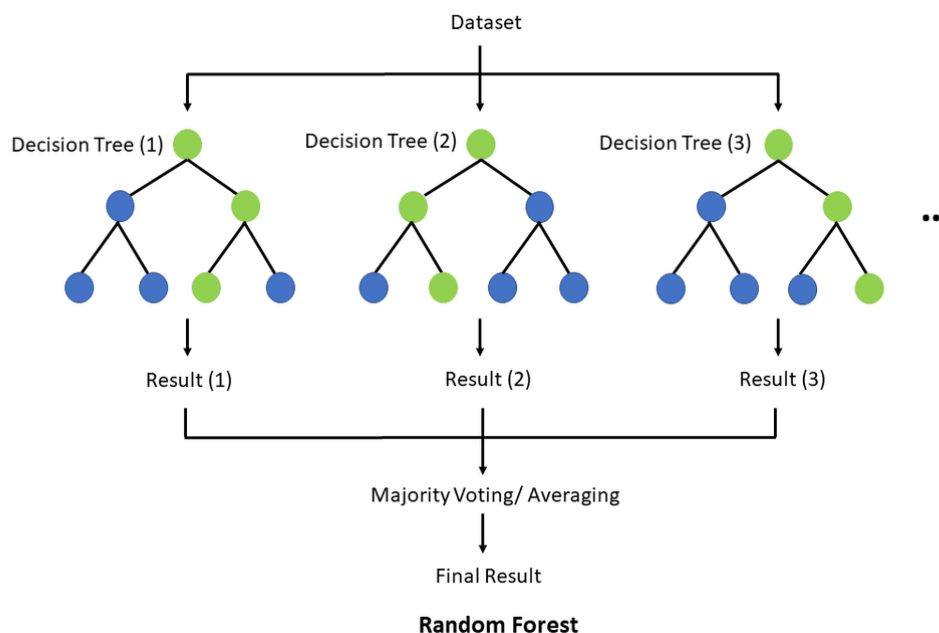


FIGURE III.8 – Illustration de la forêt aléatoire.

III.5.6 GNB (Gaussian Naive Bayes)

Selon le théorème de Bayes, le classificateur Naive Bayes Gaussien suppose que les caractéristiques sont autonomes les unes des autres [57]. L'estimation de la distribution des caractéristiques pour chaque classe, en supposant une distribution normale. L'équation du classificateur GNB est :

$$P(Y = k|X) = \frac{P(X|Y = k)P(Y = k)}{P(X)} \quad (\text{III.7})$$

où :

- $P(Y = k|X)$ représente la probabilité a posteriori de la classe k étant donné le vecteur d'entrée X ,
- $P(X|Y = k)$ est la vraisemblance de X sous l'hypothèse de la classe k ,
- $P(Y = k)$ correspond à la probabilité a priori de la classe k ,
- $P(X)$ est la probabilité de l'observation X .

Ces techniques d'apprentissage automatique sont fréquemment appliquées afin de développer des modèles qui peuvent prédire la présence de défauts dans de nouvelles données en s'appuyant sur des modèles entraînés. Cependant, leur efficacité dépend de dives facteurs, comme la qualité des données utilisées lors d'entraînement, et la sélection des paramètres d'entrée de l'algorithme d'apprentissage. De plus, bien que ces méthodes soient efficaces dans de nombreux contextes, elles présentent également des défis, tels que la sensibilité aux données bruitées, la possibilité de surapprentissage dans le cas des modèles très compliqués, et des exigences strictes et élevées sur le plan du temps et de ressources nécessaires au calcul pour le traitement d'un grand ensemble des données.

III.6 Application des techniques d'apprentissage automatique pour le diagnostic des défauts combinés dans les engrenages et les roulements

L'emploi des techniques d'apprentissage automatique pour identifier et diagnostiquer les défauts combinés des engrenages et des roulements représente un domaine de recherche en plein essor et prometteur. Des techniques tels que, les machines à vecteurs de support (SVM), les perceptrons multicouches (MLP) et les forêts aléatoires (RF) se sont avérées efficaces pour l'analyse des signaux vibratoires complexes issus de ces défauts, permettant ainsi une détection et un diagnostic précis.




FIGURE III.9 – Diagramme représentant l'application des techniques d'apprentissage automatique pour le diagnostic des défauts combinés.

La figure ?? illustre le processus d'application de ces méthodes. Les signaux vibratoires sont d'abord collectés via des capteurs positionnés sur les engrenages et les roulements. Ensuite, ces signaux sont soumis à des traitements pour l'extraction des caractéristiques spécifiques. Puis, ces caractéristiques sont utilisées comme des entrées pour les algorithmes d'apprentissage automatique, qui sont formés pour classer les signaux en fonction des types de défauts présents.

III.7 Défis et limitations associés à ces techniques dans le diagnostic des défauts combinés

Malgré leurs succès, ces techniques d'apprentissage automatique présentent certaines limitations et défis. Par exemple, les SVM et les MLP nécessitent un choix rigoureux des paramètres et des caractéristiques. Une sélection mauvaise peut causer un écart au niveau des performances, et la détermination des paramètres peut s'avérer fastidieuse, reposant souvent sur des essais et des erreurs.

En outre, ces méthodes peuvent être sensibles au bruit et les fluctuations des conditions d'exploitation. Prenons l'exemple, de changement de vitesse ou de charge pourraient modifier les signaux vibratoires, affectant ainsi la précision du diagnostic des défauts.

Les forêts aléatoires, bien qu'efficaces face au bruit et aux données insuffisantes, peuvent impliquer des moyens de calcul importants, en particulier en ce qui concerne le temps et la mémoire, surtout l'application sur une large quantité de données. Outre cela, il arrive parfois que ces algorithmes signalent un surajustement, limitant leur capacité à bien généraliser sur de données nouvelles.

III.8 Conclusion

Cette section a étudié l'application des CNN et des techniques d'apprentissage automatique dans le diagnostic des défauts combinés au niveau des engrenages et des roulements. Ces techniques révèlent un fort potentiel pour améliorer la précision de la lors de la phase de détection et de la classification des différents défauts, en offrant une analyse approfondie des signaux vibratoires complexes produits par ces systèmes mécaniques.

Les CNN, en particulier, se distinguent par leur capacité à extraire et traiter des informations complexes à la fois spatiales et temporelles, offrant ainsi une résolution diagnostique supérieure aux méthodes classiques. Néanmoins, leur efficacité liée fortement à la disponibilité de données d'entraînement en grande quantité et de haute qualité, ce qui peut poser un défi dans certaines situations. De plus, bien que puissants, les CNN restent des modèles "boîtes noires" du fait de leur transparence limitée et de leur difficultés à être interprétés.

Les techniques d'apprentissage automatique classiques offrent quant à elles une variété d'approches pour l'analyse des signaux vibratoires, chacune ayant ses avantages et inconvénients. Par exemple, les SVM, tout en étant capables de gérer des espaces à haute dimension, peuvent être sujettes au surajustement, tandis que les forêts aléatoires, bien que robustes contre ce dernier, peuvent être complexes et exigeantes en ressources. Ainsi, il est clair qu'aucune méthode unique ne peut couvrir tous les besoins de diagnostic des défauts combinés d'engrenages et de roulements. Le bon choix de la technique adéquate dépend de divers facteurs, y compris la nature des données, la complexité du système concerné, et les ressources disponibles pour l'analyse.

En conclusion, bien que les CNN et les techniques d'apprentissage automatique présentent des perspectives favorables dans le domaine de diagnostic des défauts, des travaux de recherche supplémentaire est nécessaire pour maximiser leur potentiel et surmonter les défis actuels. Il est crucial de continuer à développer et affiner ces outils, tout en renforçant une compréhension plus fine et approfondie des mécanismes des défauts dans les engrenages et des roulements, afin de rendre des diagnostics futurs plus précis et efficaces.

Chapitre IV

Méthodologie de Recherche et Mise en Place de l'Expérience

IV.1 Introduction

Dans ce chapitre, nous explorerons en profondeur la méthodologie de recherche que nous avons adoptée pour atteindre notre objectif fondamental : le diagnostic des défauts combinés d'engrenages et de roulements.

Notre processus de recherche est structurée de façon rigoureuse, couvrant l'application de réseaux de neurones convolutionnels bidimensionnels (CNN 2D) et unidimensionnels (CNN 1D) pour diagnostiquer les défauts des engrenages, jusqu'à une comparaison avec diverses techniques d'apprentissage automatique. Ces étapes mènent au diagnostic des défauts combinés d'engrenages et de roulements via les CNN.

Une explication approfondie des méthodes de recherche, des techniques d'analyse, et de l'exécution expérimentale utilisées dans cette étude, spécialisée sur le diagnostic des défaillances dans les systèmes de boîtes de vitesses. sont présentés dans cette section. Nous cherchons à obtenir un diagnostic précis en examinant les signaux de vibration provenant d'une boîte de vitesses opérant dans diverses situations, telles que l'état sain ou défectueux.

IV.2 Méthodologie de Recherche

La méthodologie que nous avons mise au point pour le diagnostic des défauts des engrenages et des roulements repose sur une série d'étapes clés, chacune jouant un rôle essentiel dans la réalisation de notre objectif. Dans cette section, nous détaillerons ces étapes et expliquerons comment elles s'articulent pour former notre approche globale. La Figure IV.1. décrit la structure global de la méthodologie de recherche, qui se divise essentiellement en trois parties :

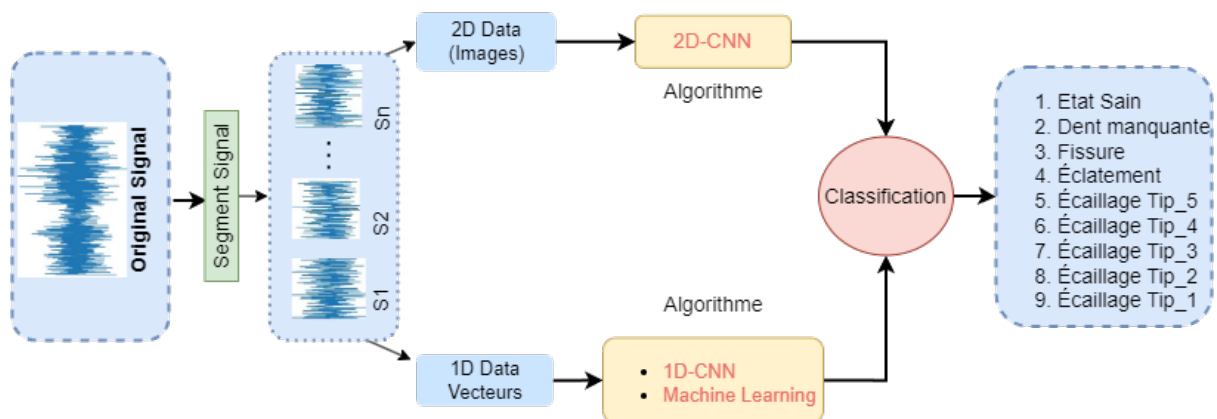


FIGURE IV.1 – Organigramme de la méthodologie de recherche.

IV.2.1 Collecte de Données

Notre méthodologie commence par recueillir les données vibratoires issues de véritables systèmes de boîtes de vitesses. Nous avons fait appel à l'ensemble de données sur les défauts d'engrenages fournies par l'Université du Connecticut (UoC) [58], couvrent différentes conditions de santé et de gravité des défauts. Une fréquence d'échantillonnage de 20 kHz a été élaborée pour récupérer ces données, ce qui favorise la collecte des données vibratoires en détail.

IV.2.2 Prétraitement des Données

Cette étape est cruciale afin de s'assurer de la qualité des signaux vibratoires utilisés pour le diagnostic. Cette phase comprend plusieurs sous-étapes, telles que le filtrage pour éliminer le bruit indésirable, la normalisation pour rendre les données comparables, le découpage en segments adéquats pour l'entraînement des modèles, en plus la gestion des données manquantes et l'élimination du bruit.

Chaque sous-étape sera expliquée en détail, en mettant en lumière les méthodes et techniques spécifiques que nous avons employées afin d'obtenir des données cohérentes et de haute qualité.

IV.2.3 Extraction de Caractéristiques

À cette étape, Les informations discriminantes sont extraites à partir des signaux vibratoires, utilisant nos modèles CNN 2D et 1D. La structure et les paramètres de ces modèles seront décrits, ainsi que leur application aux données.

IV.2.4 Classification des Défauts

Le cœur de notre méthodologie est la classification des défauts. Après avoir extrait les caractéristiques, nous utilisons des couches denses pour classifier les défauts dans les engrenages. Nous comparons également notre approche avec l'analyse synchrone en domaine angle-fréquence (AFS) suivie d'une classification par machine à vecteurs de support (SVM).

IV.2.5 Comparaison des Approches

Afin d'évaluer et comparer les performances de la méthode proposée, nous examinons plusieurs approches, notamment les modèles CNN 2D et 1D, ainsi que six techniques d'apprentissage automatique couramment utilisées : machine à vecteurs de support, perceptron multicouche, k-plus proches voisins, forêt aléatoire, régression logistique et Naive Bayes gaussien.

Nous présentons une analyse comparative approfondie des performances de ces méthodes pour mettre en lumière les bénéfices de l'apprentissage des caractéristiques via les CNN sur divers types de données. La deuxième approche utilisée pour la comparaison est l'analyse synchrone en domaine angle-fréquence (AFS), suivie de la classification par SVM [46].

IV.2.6 Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec CNN

Finalement, nous abordons notre objectif majeur qui est : le diagnostic des défauts combinés d'engrenages et de roulements en utilisant des CNN. Nous détaillons comment nous avons adapté notre méthodologie existante pour relever ce défi complexe et discutons des profits et des contraintes dans cette situation.

Les fondements de notre méthodologie de recherche sont posés dans ce chapitre. En offrant une description bien détaillée sur chaque étape de notre approche. Il servira de référence pour la suite de notre travail, où nous présenterons nos résultats et conclusions.

IV.3 Études Expérimentales

IV.3.1 Configuration Expérimentale de la Dynamique de Boîte de Vitesses

Il existe différents types de défauts et de pannes de nature mécanique pouvant se produire dans les engrenages au niveau de boîte de vitesses. Les signaux vibratoires collectés à partir d'un tel système sont en général utilisés pour révéler des informations sur leur état de fonctionnement.

Pour cette étude, des essais expérimentaux [58] ont été menés sur une boîte de vitesses à deux étages équipée d'engrenages remplaçables, comme le montre la Figure IV.2. La vitesse de rotation des engrenages est contrôlée par un moteur, tandis que le couple est appliqué par un frein magnétique dont l'intensité peut être ajustée en modifiant la tension d'entrée. Sur l'arbre d'entrée du premier étage, se trouve un pignon de 32 dents et un engrenage à dents de 80. L'étage deuxième est constitué d'un pignon à dents de 48 et d'un engrenage à dents de 64. La vitesse de rotation est mesurée par un tachymètre, et les signaux vibratoires des engrenages sont capturés par un accéléromètre. Ces signaux sont enregistrés à l'aide d'un système dSPACE (carte processeur DS1006, dSPACE Inc., Wixom, MI) à une fréquence d'échantillonnage de 20 kHz.

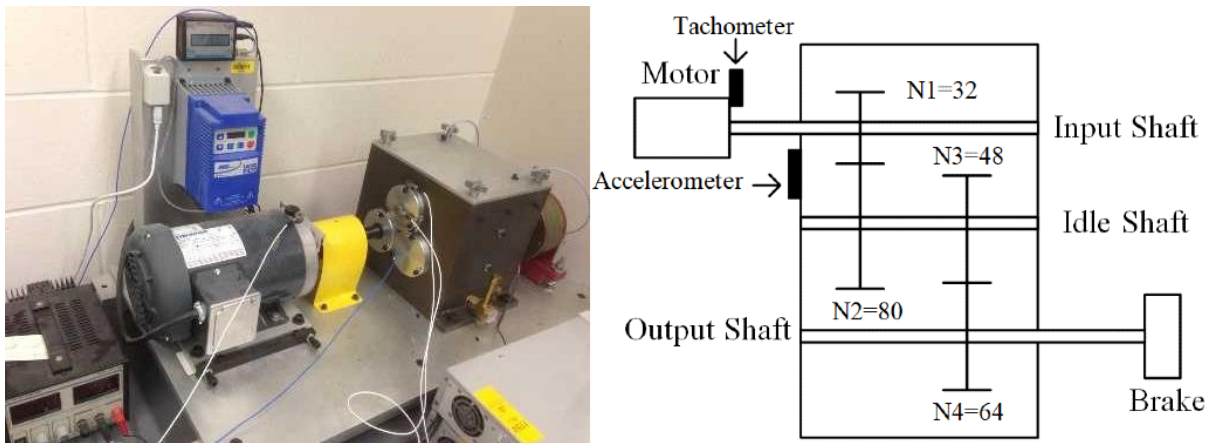


FIGURE IV.2 – Configuration du banc d'essai.

Comme illustré à la Figure IV.3, neuf types de défauts différents ont été introduits sur le pignon de l'arbre d'entrée, couvrant des états variés tels que la santé, une dent manquante, une fissure à la racine, de l'écaillage, et une cassure de pointe avec cinq différents niveaux de gravité. Le système de boîte de vitesses est généralement traité comme un système périodique en temps, tandis que la vitesse de rotation est supposée constante. Cependant, cette hypothèse n'est pas toujours exacte, suite aux variations de charge, aux tolérances géométriques, et des fautes de commande du moteur.

Dans l'original de la base de données, pour chaque condition d'engrenage, 104 signaux sont générés par le système de boîte de vitesses. Pour chaque signal, 3 600 échantillons d'angles pairs sont enregistrés au cours de 4 révolutions de l'engrenage.

IV.4 Méthode Proposée

La méthode utilisant un CNN bidimensionnel a été évaluée sur l'ensemble de données de vibrations unidimensionnelles des engrenages, fourni par l'Université du Connecticut



FIGURE IV.3 – Neuf pignons avec différents états de défaut (cinq niveaux de gravité pour la pointe éclatée).

(UoC). Comme décrit dans la section 3.3.1, pour chaque condition d'engrenage, 104 signaux ont été générés à l'aide du système de boîte de vitesses, Chacun de ces signaux est constitué de 3 600 angles pair. La totalité de données initial comprenait ainsi 936 échantillons. Toutefois, dans notre étude, nous avons divisé cet ensemble de données en deux. Cela signifie que pour chaque condition d'engrenage, 208 signaux ont été générés sur une période de 4 rotations d'engrenage, chaque signal comprenant 1 800 échantillons d'angles pairs, soit la moitié de l'ensemble original. Au total, 1 872 échantillons ont été obtenus, Cela a donné lieu à une plus grande précision lors de la phase de formation et de test. Les 208 échantillons premiers sont sains, les échantillons allant du 209^e au 313^e présentent un défaut, et ainsi de suite.

Chaque échantillon est représenté sous forme de tenseur de dimension $(1800 \times 1 \times 3)$, et le tenseur d'entrée pour chaque état de santé a une dimension de $(208 \times 1800 \times 3)$.

TABLE IV.1 – Nombre d'échantillons par état de santé de la boîte de vitesses.

Classe	État de la Boîte de Vitesses	Plage d'Échantillons	Nombre d'Échantillons
0	Sain	0 ^e à 207 ^e	208
1	Dent Manquante	208 ^e à 415 ^e	208
2	Fissure à la Racine	416 ^e à 623 ^e	208
3	Écaillage	624 ^e à 831 ^e	208
4	Pointe Ébréchée (Niveau 5)	832 ^e à 1039 ^e	208
5	Pointe Ébréchée (Niveau 4)	1040 ^e à 1247 ^e	208
6	Pointe Ébréchée (Niveau 3)	1248 ^e à 1455 ^e	208
7	Pointe Ébréchée (Niveau 2)	1456 ^e à 1663 ^e	208
8	Pointe Ébréchée (Niveau 1)	1664 ^e à 1871 ^e	208

Le tableau IV.1 montre le nombre d'échantillons ainsi que le numéro de classe associés à chaque condition de santé. Après avoir transformé et traité l'ensemble de données original, ainsi qu'extrait les caractéristiques, les signaux vibratoires ont été convertis en un échantillon de données utilisable pour l'entraînement et le test des modèles d'apprentissage automatique.

Tout ensemble de données destiné à un modèle d'apprentissage automatique doit être séparé en trois parties : un ensemble de formation, un ensemble de validation et un ensemble de test.

formation est utilisé pour ajuster les paramètres du modèle, tandis que l'ensemble de validation permet d'évaluer de manière impartiale l'ajustement du modèle sur les données de formation tout en définissant les hyperparamètres. D'autres détails de la préparation du modèle, comprenant l'extraction des caractéristiques et la sélection des seuils, sont également pris en compte.

Dans un premier temps, les données vibratoires temporelles brutes ont été issues de des ensembles de données de défauts d'engrenage de l'Université du Connecticut, Échantillonnées à une fréquence de 20 kHz. Ces groupes de données renferment des mesures effectuées sur des engrenages montés sur l'arbre d'entrée, testés dans neuf conditions différentes : une condition saine, une dent manquante, une fissure à la racine, de l'écaillage, ainsi qu'une pointe ébréchée, chacune avec cinq niveaux de gravité différents. Les données ont ensuite été classées en neuf catégories pour l'évaluation des performances (une condition saine et huit états défailants).

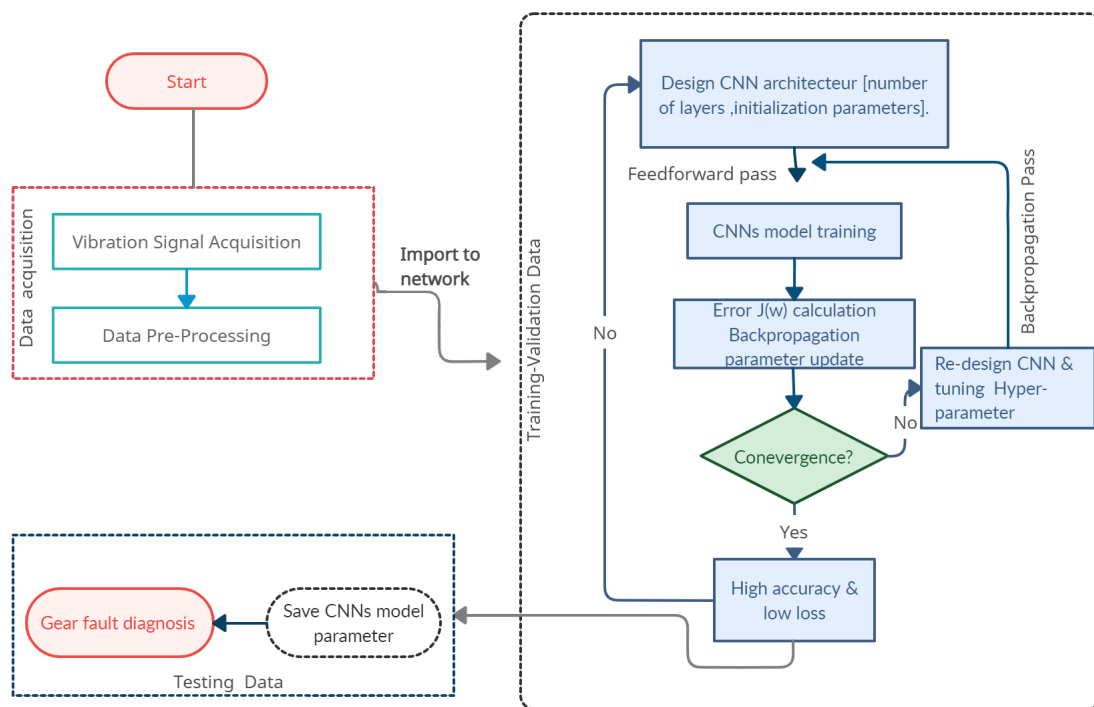


FIGURE IV.4 – Schéma général de la méthode proposée.

Comme illustré à la Figure IV.4, l'image du signal de vibration est directement introduite dans notre modèle CNN amélioré pour l'entraînement par rétropropagation. Ensuite, le modèle CNN ainsi entraîné est utilisé pour l'extraction des caractéristiques sur nouvelles données concernant des défauts. Finalement, les vecteurs de caractéristiques compactes extraits sont passés à la couche entièrement connectée pour la classification des différents défauts.

Nous exposons dans cette étude une approche novatrice pour le diagnostic des défauts, basée sur CNN, pour l'automatisation de l'identification des caractéristiques dans le spectre des signaux vibratoires afin de diagnostiquer les défauts d'engrenage. Différemment aux

CNN conventionnels, généralement appliqués à la reconnaissance d'images [59, 60], et à de nombreuses autres recherches précédentes qui ont utilisé des approches similaires pour diagnostiquer des défauts mécaniques [58, 61, 62], notre recherche a choisi d'utiliser des segments unidimensionnels de données brutes en entrée, ainsi que des filtres unidimensionnels dans les couches de convolution du modèle.

Cette approche s'appuie sur une connaissance approfondie de la nature des données vibratoires. Inversement aux images, où la corrélation spatiale 2D est essentielle, les données de vibration sont principalement temporelles, ce qui les rend essentiellement unidimensionnelles. Pour mieux capturer ces propriétés temporelles, nous avons regroupé des segments unidimensionnels des données vibratoires en entrée, cela permet au modèle de saisir de manière plus efficace les caractéristiques cruciales pour diagnostiquer les défauts d'engrenage. La présente méthode offre de nouvelles perspectives pour améliorer la précision et l'efficacité des techniques de diagnostic basées sur l'apprentissage automatique, notamment dans le domaine de la fiabilité des systèmes mécaniques et la maintenance prédictive.

Notre étude débute par le développement du modèle CNN, puis l'élaboration de principes généraux de conception. Nous avons examiné divers réglages des paramètres cruciaux du réseau, tels que la taille des segments de données, la dimension des filtres, le nombre de filtres dans les couches de convolution, et le nombre de nœuds dans les couches entièrement connectées. Ces paramètres ont été soigneusement évalués et analysés en fonction des résultats expérimentaux, et la configuration CNN offrant les meilleures performances a été retenue comme modèle cible.

Pour une évaluation plus approfondie des performances de notre méthode, nous avons comparé plusieurs méthodes alternatives.

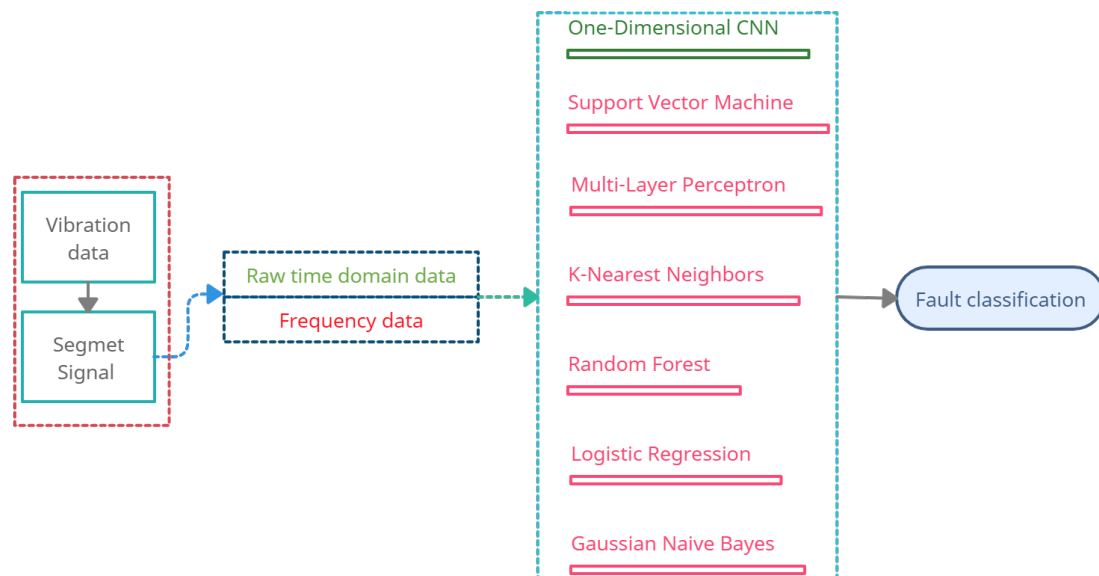


FIGURE IV.5 – Protocole des méthodes proposées.

La Figure IV.5 présente les différentes méthodes testées, en mettant en évidence le protocole développé dans notre étude à l'aide de couleurs distinctes. Afin de démontrer les capacités du CNN lorsque on parle de l'apprentissage des caractéristiques et de la classification des divers types de données, nous avons employé dans notre ensemble de données, des données

brutes dans le domaine temporel, des spectres de fréquence, des données combinées temps-fréquence, ainsi que diverses caractéristiques artisanales.

L'entraînement et le test des modèles d'apprentissage automatique repose essentiellement sur Le processus de transformation des signaux vibratoires en données d'échantillons . Suite à cette transformation, ainsi qu'au traitement des données et à l'extraction des caractéristiques, chaque ensemble de données est subdivisé en trois ensembles : formation, validation et test. L'ensemble de formation est employé pour régler les paramètres du modèle, l'ensemble de validation est destiné pour définir les hyperparamètres, et l'ensemble de test pour l'évaluation de la performance finale du modèle. Dans notre étude, Les données ont été réparties en 60% pour la formation, 20% pour la validation et 20% pour le test.

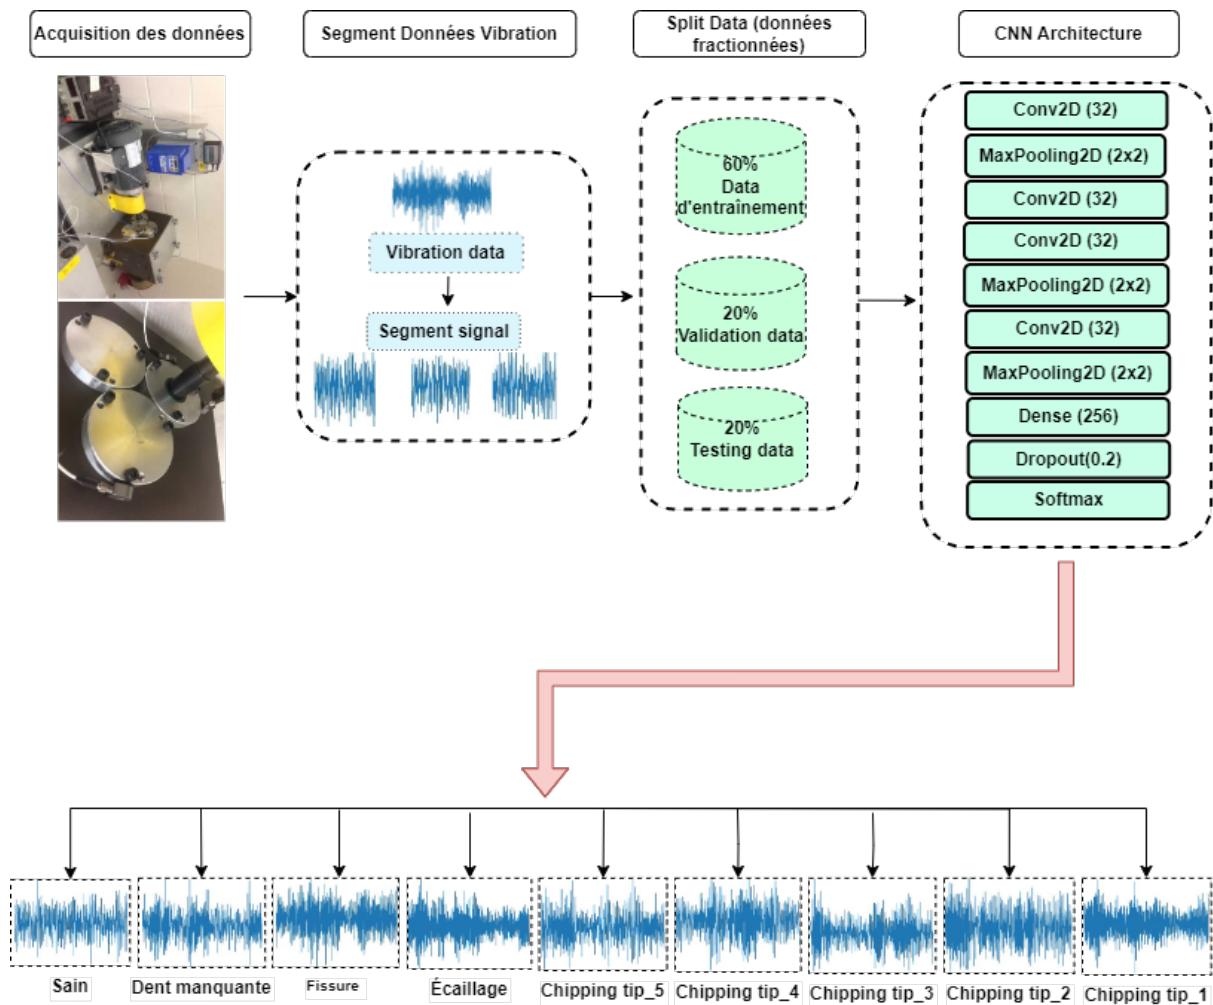


FIGURE IV.6 – Méthode de diagnostic des défauts basée sur un réseau neuronal CNN.

Nous avons également étendu notre analyse en incluant six techniques d'apprentissage automatique : la machine à vecteurs de support, le perceptron multicouche, les k-plus proches voisins, la forêt aléatoire, la régression logistique, et le bayésien naïf gaussien. Ces méthodes sont largement utilisées dans le diagnostic mécanique et ont prouvé leur efficacité. Leur inclusion dans notre étude a permis de comparer les performances de notre approche basée sur le CNN à celles de ces techniques connus, ce qui a entraîné à des conclusions significatives concernant l'efficacité de notre méthode proposée dans le secteur du diagnostic des défauts mécaniques.

IV.5 Résultats et discussion

IV.5.1 Méthode de diagnostic des défauts basée sur un réseau neuronal bidimensionnel (CNN-2D)

Dans cette partie, nous présentons les résultats tirées de notre approche de diagnostic des défauts, repose sur un réseau neuronal bidimensionnel (CNN-2D). Nous détaillons l'architecture du modèle CNN-2D, développé spécialement pour le diagnostic des défauts de boîtes de vitesses à partir de données vibratoires bidimensionnelles, comme démontré dans le Tableau IV.2.

Architecture du modèle

L'architecture du modèle CNN-2D joue un rôle crucial dans notre approche, influençant directement la capacité du modèle à extraire les caractéristiques significatives des signaux vibratoires. Chaque couche du modèle est conçue pour effectuer des opérations spécifiques, allant de l'extraction des caractéristiques jusqu'à la classification en plusieurs classes. L'architecture s'appuie sur des couches de convolution 2D, des couches complètement connectées, ainsi que des mécanismes de régularisation pour optimiser les performances.

TABLE IV.2 – Illustration détaillée de l'architecture du modèle CNN-2D.

Étape	Couche	Opérations	Caractéristiques
1	Convolution 2D Activation Normalisation Max pooling	Filtres 11x11x96 ReLU 5 canaux/élément 3x3	Extraction de caractéristiques initiale Activation pour la non-linéarité Normalisation pour la stabilité Échantillonnage spatial maximal
2	Convolution 2D Activation Normalisation Max pooling	Filtres 5x5x256 ReLU 5 canaux/élément 3x3	Détection de motifs complexes Activation pour l'apprentissage Normalisation pour la convergence Échantillonnage spatial maximal
3	Convolution 2D Activation	Filtres 3x3x384 ReLU	Extraction de caractéristiques profondes Activation pour la non-linéarité
4	Convolution 2D Activation	Filtres 3x3x384 ReLU	Extraction de caractéristiques continues Activation pour l'apprentissage
5	Convolution 2D Activation Max pooling	Filtres 3x3x256 ReLU 3x3	Extraction de caractéristiques complexes Activation non-linéaire Échantillonnage spatial maximal
6	Couche dense Activation Dropout	4096 neurones ReLU 50%	Apprentissage des caractéristiques Activation pour l'apprentissage Régularisation pour éviter le surapprentissage
7	Couche dense Activation Dropout	4096 neurones ReLU 50%	Apprentissage des caractéristiques avancées Activation pour l'apprentissage Régularisation pour éviter le surapprentissage
8	Couche dense Activation	9 neurones Softmax	Classification multi-classes

Dans le cadre de notre analyse, nous avons divisé les signaux en sous-ensembles aléatoires pour l'entraînement et la validation. L'ensemble d'entraînement a varié de 60% des données

(soit 125 données par condition, pour un total de 1125 données) à 20% pour la validation (soit 42 données par condition, totalisant 378 données). L'ensemble de test a constitué environ 20% du total, avec 41 données par condition, ce qui représente 369 données pour chaque état de santé. Pour la classification de nombreux défauts, des modèles CNN empilés ont été entraînés en utilisant une fonction de perte basée sur l'entropie croisée.

Le Tableau IV.3 montre les résultats des tests effectués en utilisant diverses combinaisons d'optimiseurs et de tailles de lot.

TABLE IV.3 – Résultats des tests pour différentes configurations d'optimiseurs et tailles de lot.

Test	Optimiseur	Taille du lot	Précision (%)	Précision de test (%)
1	SGD	2	56	54,2
2	SGD	4	88,9	88,9
3	RMSprop	8	92,1	92,0
4	Adam	16	100	99,65
5	SGD	16	97,3	97,0

Les résultats montrent que l'optimiseur Stochastic Gradient Descent (SGD) avec une taille de lot de 2 a produit une précision relativement faible pour l'apprentissage et le test. L'augmentation de la taille de lot à la valeur 4 a conduit à une amélioration notable de la précision, ce qui indique une meilleure capacité d'apprentissage et de généralisation du modèle. Lors du test avec l'optimiseur RMSprop et une taille de lot de 8, les performances ont montré un niveau élevé et une grande stabilité. Adam, un optimiseur avec une taille de lot de 16 a atteint un niveau de précision parfait, alors que l'emploi de SGD avec une taille de lot de 16 a également présenté des résultats solides. Les résultats obtenus montrent l'importance du choix de l'optimiseur et de la taille de lot sur les performances du modèle, ce qui offre des options flexibles selon les spécificités du problème et des ressources à disposition.

La précision et la perte du modèle lors des tests sont illustrées dans la Figure La Figure IV.7. Ces graphiques permettent d'apprécier visuellement la performance du modèle CNN-2D, dans le cadre de la classification des défauts.




FIGURE IV.7 – Évolution de la précision et de la perte du modèle au cours des époques pour CNN-2D.

Interprétation des résultats :

Les résultats révèlent que le modèle a été formé sur des images de 512x512 pixels et un lot de taille 16, ayant ainsi suivi un entraînement sur 10 époques.

À la fin de la dixième époque, la perte moyenne sur les données d'entraînement était de 0,0039, ce qui reflète une performance très satisfaisante, avec une précision moyenne de 100%. Pour l'ensemble de validation, la perte moyenne était légèrement supérieure à 0,0092, mais toujours faible, avec une précision de 99,65%. Le taux d'apprentissage final était de 0,0005 (ou 5×10^{-4}), ce qui est une valeur courante pour l'entraînement de réseaux de neurones.

Les résultats sont très positifs, montrant une précision élevée pour les ensembles d'entraînement et de validation. Cependant, la précision de validation n'a pas montré d'amélioration notable par rapport aux époques précédentes peut indiquer que le modèle a atteint son seuil d'apprentissage optimal avec l'architecture et les données actuelles. La petite différence entre les pertes d'entraînement et de validation suggère un léger surapprentissage, mais cela reste marginal et n'affecte pas de manière significative les performances sur des nouvelles données.

Matrice de confusion du modèle CNN-2D

La matrice de confusion, visible à la Figure IV.8, indique la performance de notre modèle de classification pour les neuf classes différentes.




FIGURE IV.8 – Matrice de confusion pour le modèle CNN-2D.

Chacune des lignes de la matrice correspond à une classe réelle, tandis que chaque colonne

représente une classe prédite par le modèle. Les chiffres dans la matrice montrent le nombre d'échantillons classifiés dans chaque paire de classe réelle/prédite. Par exemple, le chiffre 42 dans la case (0-Healthy, 0-Healthy) indique que le modèle a correctement identifié 42 échantillons comme étant "0-Healthy". L'examen de la matrice révèle que la diagonale principale, où les classes réelles et prédites sont identiques, affiche des valeurs élevées de 42, ce qui signifie que la majorité des échantillons ont été correctement classifiés dans leurs catégories respectives.

Aucun autre élément en dehors de la diagonale principale n'indique de confusion entre les classes, ce qui montre que le modèle n'a pas mélangé les différentes classes.

En conclusion, les résultats montrent que le modèle CNN-2D s'avère très performant pour prédire les défauts de boîtes de vitesses via les données de vibration 2-D. Les résultats révèlent que notre approche pourrait être adaptée aux applications réelles. Il est cependant important de continuer à tester le modèle avec de nouvelles données pour valider son efficacité en situations réelles et évaluer sa capacité à généraliser au-delà des données actuelles.

Conclusion

Il apparaît que le modèle CNN-2D affiche des performances exceptionnelles pour la classification des défauts utilisant des données de vibration bidimensionnelles. Ces performances particulières ont été spécifiquement observées sur l'optimiseur Adam et une taille de lot de 16. D'autres configurations d'optimiseurs et de tailles de lot ont aussi révélé une bonne robustesse, illustrant la flexibilité de notre approche. La matrice de confusion révèle l'aptitude du modèle à classer avec exactitude les échantillons dans leurs catégories respectives, avec peu ou pas de confusion entre les classes.

En résumé, le modèle CNN-2D apparaît comme une solution prometteuse pour le diagnostic des défauts de boîtes de vitesses à partir de données de vibration bidimensionnelles. Néanmoins, une évaluation continue avec des données nouvelles est nécessaire pour confirmer son efficacité dans des contextes réels et tester sa capacité à généraliser au-delà des données actuellement disponibles.

IV.5.2 Méthode de diagnostic des défauts basée sur un réseau neuronal unidimensionnel (CNN-1D)

Cette sous-section explore les résultats obtenus avec notre méthode de diagnostic des défauts utilisant un réseau neuronal unidimensionnel (CNN-1D). Nous décrivons également l'architecture du modèle CNN-1D développé pour diagnostiquer les défauts à partir de données de vibration unidimensionnelles, tel qu'il est indiqué dans le tableau IV.4.

Architecture du modèle :

Le modèle CNN (Convolutional Neural Network) est constitué de plusieurs couches. Il commence par trois couches de convolution (Conv1D), suivies de couches de max-pooling et de dropout pour réduire le dimensionnement et d'éviter le surapprentissage. Par la suite, il est composé d'une couche dense de 1024 neurones et d'une couche de sortie avec 9 neurones, correspondant aux 9 classes possibles. En tout, le modèle comporte environ 3 338 569 paramètres entraînaibles.

TABLE IV.4 – Détails des couches du modèle.

Couche	Forme de Sortie	Paramètres Entraînables
conv1d_54 (Conv1D)	(None, 900, 64)	1,984
max_pooling1d_54 (MaxPooling1D)	(None, 300, 64)	0
dropout_54 (Dropout)	(None, 300, 64)	0
conv1d_55 (Conv1D)	(None, 150, 128)	245,888
max_pooling1d_55 (MaxPooling1D)	(None, 50, 128)	0
dropout_55 (Dropout)	(None, 50, 128)	0
conv1d_56 (Conv1D)	(None, 25, 256)	983,296
max_pooling1d_56 (MaxPooling1D)	(None, 8, 256)	0
flatten_18 (Flatten)	(None, 2048)	0
dense_36 (Dense)	(None, 1024)	2,098,176
dropout_56 (Dropout)	(None, 1024)	0
dense_37 (Dense)	(None, 9)	9,225

Ces couches sont organisées en séquence pour former le modèle complet. Chacune de ces couche a un rôle particulier dans l'extraction et la transformation des caractéristiques pour les classer. Les couches de dropout permettent la prévention du surapprentissage en désactivant certaines activations pendant l'entraînement, ce qui renforce la généralisation du modèle. Le modèle global a une capacité à apprendre et à classifier efficacement les données, comme en témoigne sa performance élevée lors des tests.

Résultats de l'entraînement :

Notre modèle a été entraîné sur 10 époques avec un taux d'apprentissage fixé à 0,001. Durant cette période, il a atteint une précision de 99,83%, démontrant ainsi une excellente capacité à classer les données d'entraînement. La Figure IV.9 au dessous présente la précision et la perte du modèle sur l'ensemble de test, ce qui donne un aperçu visuel de la performance du modèle CNN-1D dans la classification des défauts.




FIGURE IV.9 – Évolution de la précision et de la perte du modèle au fil des époques pour CNN-1D.

L'ensemble lié au validation a montré des résultats remarquables, atteignant une précision finale de 99,67%. Ces résultats indiquent que notre modèle est capable de généraliser efficacement sur des données qu'il n'a jamais connus auparavant.

Résultats des tests :

Afin d'optimiser la précision du diagnostic des défauts au niveau de boîtes de vitesses, différentes architectures de modèles CNN ont été conçues, chacune avec différents hyperparamètres, pour identifier la meilleure combinaison possible. En appliquant les procédures décrites dans cette section, plusieurs paramètres clés du CNN ont été examinés, comme la taille des segments d'entrée et de filtres, le nombre de filtres dans les couches convolutionnelles, et le nombre de nœuds dans la couche entièrement connectée. Après avoir testé diverses configurations de CNN, le modèle offrant les résultats les plus satisfaisants a été retenu comme modèle final.

Les performances de différents modèles de réseaux de neurones convolutionnels (CNN) avec des architectures différentes sont comparées dans le tableau IV.5.

TABLE IV.5 – Performances des différents modèles CNN.

Architecture	Accuracy%	Precision %	Recall%	F1 Score%	AUC%
Modèle 1	0.837	0.804	0.572	0.674	0.596
Modèle 2	0.997	0.946	0.984	0.965	0.987
Modèle 3	0.985	0.932	0.979	0.958	0.983

Différents modèles de réseaux de neurones CNN-1D :

La première ligne représente un modèle CNN avec une architecture "Conv1D-Conv1D-MaxPool-FC-FC".

La deuxième ligne décrit un modèle avec une architecture "Conv1D-MaxPool-Conv1D-MaxPool-FC-FC".

La troisième ligne correspond à un modèle avec une architecture "Conv1D-MaxPool-Conv1D-MaxPool-Conv1D-MaxPool-FC-FC".

Métriques d'évaluation :

Les métriques d'évaluation utilisées comprennent :

- Précision (Accuracy) : la fraction de prédictions correctes par rapport à l'ensemble des échantillons.
- Précision (Precision) : le taux de vrais positifs par rapport au total des prédictions positives.
- Rappel (Recall) : la part de vrais positifs dans le total des exemples positifs réels.
- F1 Score : une mesure conjointe du rappel et de la précision.
- AUC (Area Under the Curve) : l'aire sous la courbe ROC, qui juge la capacité du modèle à classer correctement les classes.

Interprétation des résultats :

Pour la première architecture, le modèle affiche une précision globale de 83,7%, une précision de 80,4% avec un rappel de 57,2% et un score F1 de 67,4%. Les derniers chiffres montrent que le modèle a une performance modérée, mais il éprouve des difficultés à identifier correctement les exemples positifs, comme l'indique son faible rappel.

La deuxième architecture montre une amélioration significative des performances. Une précision de 99,73%, une précision de 94,6%, un rappel de 98,4% et un score F1 de 96,5%.

La configuration semble bien équilibrée et parvient à classifier efficacement les exemples positifs.

La troisième architecture révèle une performance excellente, avec une précision de 98,5%, une précision de 93,2%, un rappel de 97,9% et un score F1 de 95,8%. Malgré cela, l'AUC légèrement inférieure à 1 suggère une légère imperfection dans la capacité du modèle à distinguer entre les classes.

Conclusion :

Les résultats montrent le rôle crucial de la conception de l'architecture des réseaux neuronaux unidimensionnels. La deuxième architecture, intégrant deux couches de convolution suivies de max-pooling, dépasse clairement les autres en termes de performances globales.

Bien que la troisième architecture affiche des performances presque parfaites sur les métriques standard (précision, précision, rappel, score F1), l'AUC légèrement inférieure indique une certaine incertitude dans les prédictions du modèle.

Il est crucial de noter que ces résultats peuvent être spécifiques aux données et à la tâche de classification choisie. Il serait pertinent d'explorer davantage d'architectures et de techniques d'optimisation pour déterminer celle qui convient le mieux à votre problème.

En résumé, le deuxième modèle semble être le choix optimal en termes de performances globales, mais une analyse plus poussée des caractéristiques des données et une validation croisée sont nécessaires pour confirmer ces résultats.

IV.5.3 Méthode de diagnostic des défauts basée sur l'apprentissage automatique (Machine Learning)

Dans cette partie, nous analyserons les résultats obtenus grâce à notre approche de diagnostic des défauts reposant sur l'apprentissage automatique. Nous explorerons une variété de modèles d'apprentissage automatique que nous avons adoptés et leur performance dans le domaine de diagnostic des défauts des boîtes de vitesses.

L'apprentissage automatique est devenu fondamental dans le domaine de diagnostic des défauts d'engrenages. Une étape importante de ce processus est l'extraction et la sélection des caractéristiques, qui rendent possible la réduction de la dimensionnalité du signal et d'identifier les propriétés pertinentes pour l'analyse.

Dans ce travail, des méthodes d'apprentissage automatique courantes et efficaces, comme la Machine à Vecteurs de Support (SVM), le Perceptron Multi-Couches (MLP), les K-Plus Proches Voisins (KNN), la Forêt d'Arbres Décisionnels (Random Forest), la Régression Logistique et le Bayésien Naïf Gaussien, sont utilisées pour la classification des défauts des engrenages. La fusion des caractéristiques soigneusement choisies avec des techniques d'apprentissage automatique puissantes, permet d'obtenir un diagnostic précis et fiable des défauts d'engrenages.

Extraction et Sélection des Caractéristiques

L'extraction de caractéristiques permet de réduire la dimensionnalité du signal d'entrée. Généralement, le signal d'entrée à analyser est trop volumineux, rendant son traitement compliqué. L'extraction de caractéristiques implique la transformation d'un signal de base en un ensemble de caractéristiques. Avoir trop grand nombre de variables en jeu entraîne des

problèmes majeurs lors de l'analyse de données complexes. Pour atténuer ces problèmes, l'extraction de caractéristiques est utilisée pour combiner des variables.

Dans cette étude, nous avons utilisé des caractéristiques statistiques du domaine temporel telles que le Pic (Peak), l'Écart quadratique moyen (RMS), le Facteur de crête (Crest factor), l'Écart-type (STD), l'Asymétrie (Skewness) et l'Excess kurtosis (Kurtosis).

La Figure IV.10 présente la visualisation bidimensionnelle des caractéristiques des données d'échantillon. Ces caractéristiques statistiques sont employées pour calculer diverses propriétés à partir des signaux de vibration.

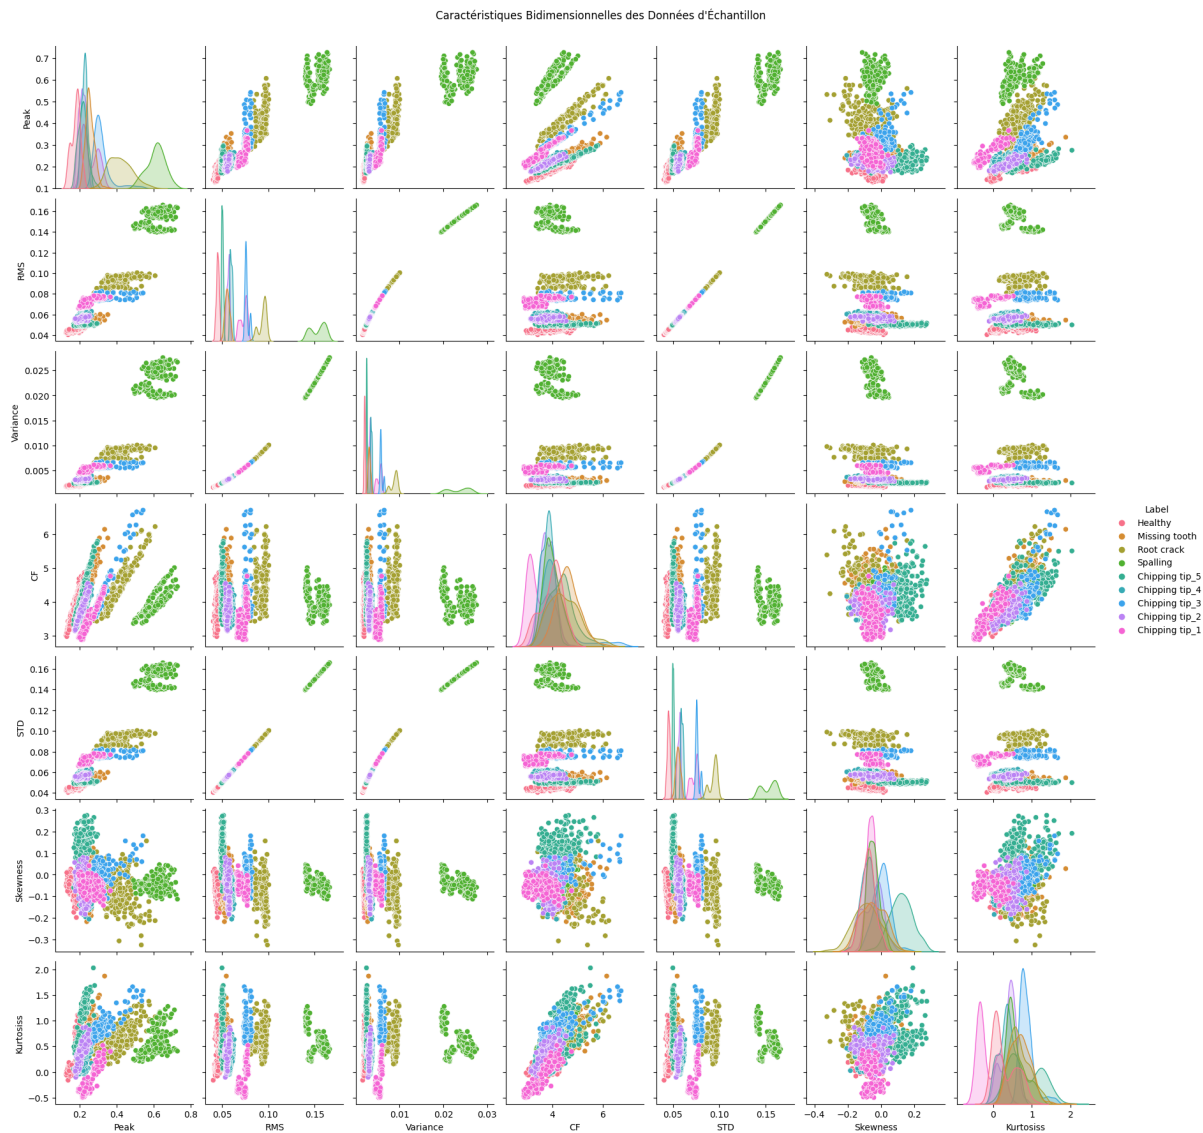


FIGURE IV.10 – Visualisation des caractéristiques bidimensionnelles des données d'échantillon.

Distributions univariées (Diagonale)

Les graphiques sur la diagonale (de haut en bas à gauche) dans la matrice bidimensionnelle représentent la distribution uni-variée d'une caractéristique. Ils montrent comment les valeurs de chaque caractéristique sont réparties. Une distribution normale ou gaussienne (en forme

de cloche) est souhaitable. Par exemple, en consultant le graphique de la dernière diagonale, qui indique la distribution des valeurs de "Skewness", on observe une distribution centrée et normale, ce qui indique que les valeurs de cette caractéristique sont équilibrées et réparties uniformément. Si les distributions semblent légèrement décalées de la normale, cela peut indiquer des divergences légères au niveau des caractéristiques pour différents types de défauts.

Graphiques de dispersion (Hors diagonale)

Les graphiques en dehors de la diagonale principale (au-dessus et en dessous de celle-ci) représentent les dispersions bidimensionnelles entre chaque paire de caractéristiques. Chaque point sur ces graphiques correspond à un échantillon individuel, coloré en fonction du type de défaut d'engrenage (par exemple, sain, dent manquante, etc.). Ces graphiques sont essentiels pour mieux appréhender les relations entre les caractéristiques. Si les points créent une ligne ou un modèle, cela indique une corrélation linéaire positive ou négative entre ces caractéristiques. Par exemple, le graphique de dispersion entre "RMS" et "STD" montre une tendance croissante (les points montent de gauche à droite), ce qui signifie que lorsque "RMS" augmente, "STD" tend à augmenter également. Si les points semblent dispersés aléatoirement, il n'y a probablement pas de corrélation linéaire évidente entre ces caractéristiques. Si les points forment un motif circulaire ou ovale, cela pourrait indiquer une corrélation non linéaire, suggérant une relation plus complexe entre les caractéristiques.

Interprétation des résultats

TABLE IV.6 – Résultats des modèles avec caractéristiques sélectionnées.

Modèle	Caractéristiques Sélectionnées	Exactitude
SVM (Polynomial Kernel)	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	82.13%
SVM (RBF Kernel)	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	91.47%
Logistic Regression	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	70.40%
Gaussian Naive Bayes	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	94.40%
K-Nearest Neighbors	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	81.60%
Decision Tree	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	93.87%
Random Forest	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	94.93%
Multi Layer Perceptron	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis	96.27%

La synthèse des performances des différents modèles de machine learning en fonction des caractéristiques choisies est affichée au tableau IV.6. Le Perceptron Multi-Couches (MLP) se distingue par une précision élevée de 96,27% avec les sept caractéristiques sélectionnées : Peak, RMS, Variance, CF, STD, Skewness et Kurtosis. Cette précision exceptionnellement élevée suggère que ce modèle s'avère très performant et efficace pour faire la distinction entre les divers types de défauts des engrenages au niveau des données.

Les modèles Bayésien Naïf Gaussien, Forêt d'Arbres Décisionnels et Arbre de Décision indiquent aussi de bonnes performances, présentent des taux de précision de 94,40%, 94,93% et 93,87%. Ces résultats montrent leur capacité à généraliser des schémas compliqués dans les données, leur permettant de faire des prédictions précises.

Les modèles SVM (Noyau RBF) et K-Plus Proches Voisins montrent des performances moyennes avec des précisions de 91,47% et 81,60%. Bien qu'ils aient correctement classé une grande proportion des données, il existe une marge d'amélioration pour optimiser leur performance.

En revanche, le modèle de Régression Logistique montre des performances relativement faibles avec une précision de 70,40%. Cela indique que ce modèle n'a pas réussi à capter la complexité des schémas dans les données, ce qui a conduit à des prédictions moins précises.

Modèle de Perceptron Multi-Couches (MLP)

Le tableau IV.7 et la Figure IV.11 montrent les performances du modèle de Perceptron Multi-Couches (MLP) selon le nombre de caractéristiques choisies (k) dans le processus de sélection des caractéristiques.

En considérant uniquement la caractéristique (RMS), le modèle atteint une précision de 78,4%. L'ajout de l'écart-type (STD) augmente légèrement le niveau de précision à 78,7%. Avec la Variance incluse la précision atteint 79,2%. L'incorporation de la caractéristique Peak améliore significativement la précision à 81,3%. L'introduction de Kurtosis conduit à une augmentation notable de la précision à 88,8%. L'ajout de Skewness améliore encore la précision à 92,5%. Enfin, l'intégration de la Fréquence Centrale (CF) porte la précision à un impressionnant 96,3%. Ces résultats suggèrent que les caractéristiques Peak, RMS, Variance, STD, Kurtosis, Skewness et CF sont cruciales pour une classification précise. L'inclusion de caractéristiques supplémentaires au-delà de ces sept n'apporte pas de gain significatif en précision, ce qui indique que ces sept caractéristiques sont les plus informatives pour ce modèle de classification particulier.

TABLE IV.7 – Performances du modèle en fonction du nombre de caractéristiques sélectionnées.

K Value	Accuracy	Selected Features
k=1	0.784	RMS
k=2	0.787	RMS, STD
k=3	0.792	RMS, Variance, STD
k=4	0.813	Peak, RMS, Variance, STD
k=5	0.888	Peak, RMS, Variance, STD, Kurtosis
k=6	0.925	Peak, RMS, Variance, STD, Skewness, Kurtosis
k=7	0.963	Peak, RMS, Variance, CF, STD, Skewness, Kurtosis

Matrice de confusion du modèle Multi-Layer Perceptron (MLP)

La matrice de confusion décrite dans la Figure IV.12 présente le nombre d'échantillons pour chaque classe (colonnes) et leur classification par le modèle (lignes). Par exemple, dans la deuxième ligne, on observe que sur 39 échantillons de la classe "Missing tooth", le modèle en a correctement classé 36. Cependant, il a classé incorrectement 2 à la quatrième classe et 1 à la septième classe.

Courbes ROC et AUC du modèle MLP

Les courbes ROC (Receiver Operating Characteristic) présentées dans la Figure IV.13 révèlent la performance du modèle en représentant le taux de vrais positifs en fonction du taux de faux positifs pour différents seuils de classification. L'aire sous la courbe (AUC) indique la performance globale du modèle, où une AUC proche de 1 indique une excellente performance.




FIGURE IV.11 – Performances du modèle MLP en fonction du nombre de caractéristiques sélectionnées.

Healthy (Sain) : Le modèle a correctement classé la majorité des échantillons de cette classe (41 sur 42), ce qui se traduit par une AUC relativement faible de 0,22, suggérant une certaine difficulté à différencier cette classe des autres.

Missing tooth (Dent manquante) : Le modèle a montré une bonne performance pour cette classe, avec une AUC de 0,73, démontrant sa capacité à bien distinguer les échantillons de cette classe, malgré quelques erreurs de classification (9 échantillons mal classés).

Root crack (Fissure de racine) : Cette classe a également été bien identifiée par le modèle, avec une AUC de 0,70 et seulement deux erreurs de classification, indiquant une bonne capacité à distinguer cette classe.

Spalling (Écaillage) : Le modèle a rencontré des difficultés avec cette classe, comme le montre une AUC nulle. Tous les échantillons de cette classe ont été mal classés, soulignant une faiblesse du modèle dans l'identification de ce type de défaut.

Chipping tip (Éclat de pointe) : Les performances varient selon les sous-classes de "Chipping tip", certaines ayant des AUC élevées, indiquant une bonne distinction, tandis que d'autres affichent des AUC moins élevées, indiquant la difficulté du modèle à les séparer par rapport aux autres classes.

En résumé, bien que le modèle présente une performance globale satisfaisante, il éprouve des difficultés spécifiques avec la classe "Spalling" et certaines sous-classes de "Chipping tip".

Conclusion

En conclusion, les résultats obtenus mettent en évidence l'efficacité des caractéristiques sélectionnées (Peak, RMS, STD, etc.) pour différencier divers types de défauts d'engrenages (Healthy, Missing tooth, etc.). Le choix du modèle dépendra du niveau de précision requis pour l'application spécifique, mais dans ce cas, le modèle Multi-Layer Perceptron a été retenu comme le plus performant pour la détection des défauts d'engrenages, grâce à sa capacité à capturer des corrélations complexes et à distinguer de manière efficace les différents types de défauts.




FIGURE IV.12 – Matrice de confusion du modèle MLP.

IV.6 Comparaison des approches de diagnostic

Cette étude de comparaison se focalise sur trois méthodes avancées : les réseaux de neurones convolutionnels bidimensionnels (CNN-2D), les réseaux de neurones convolutionnels unidimensionnels (CNN-1D), et l'apprentissage automatique. Nous les comparons avec la méthode traditionnelle AFS suivie de la classification par machine à vecteurs de support (SVM). L'objectif est de sélectionner la méthode assurant le meilleur niveau de précision et de fiabilité pour le diagnostic des défauts. Cette analyse fournira des informations précieuses pour aider les professionnels et les chercheurs à choisir la méthode la plus adaptée à leurs exigences particulières en diagnostic.

Discussion

L'analyse du tableau IV.8 met en lumière plusieurs observations importantes :

- Le "Réseau neuronal bidimensionnel (CNN-2D)" se distingue par une performance optimale, atteignant une précision de 100% tant pour l'entraînement que pour les tests.




FIGURE IV.13 – Courbes ROC du modèle MLP.

- — Les méthodes fondées sur les "Caractéristiques Manuelles" présentent une vaste gamme de performances, avec des niveaux de précision d'entraînement oscillant entre 68,74% et 96,33%, et des précisions de test variant de 70,40% à 96,27%.
- — Les structures CNN-1D démontre des résultats variés, indiquant que la structure du réseau joue un rôle crucial dans l'obtention de bonnes précisions.
- — La méthode "Local CNN Accuracy" n'affiche aucune précision de test, ce qui pourrait suggérer qu'elle n'a pas été évaluée ou que les données ne sont pas disponibles.

Interprétation du Diagramme

Le diagramme à points connectés (Figure IV.14) compare la précision de test et la précision d'entraînement pour diverses approches de diagnostic des défauts d'engrenages.

1. **Consistance des modèles :** "CNN-2D", "CNN-1D", et "MLP" affichent une faible différence entre les précisions d'entraînement et de test, ce qui montre que ces modèles sont bien généralisés et ne souffrent pas de surapprentissage.
2. **Performances élevées :** "CNN-2D" et "CNN-1D" se distinguent par des précisions d'entraînement et de test avoisinant les 100%, ce qui suggère une efficacité notable pour le diagnostic des défauts d'engrenages.
3. **Variabilité des performances :** Certaines méthodes, comme "CNN-1D Arch1", présentent une différence significative entre les précisions d'entraînement et de test, ce qui pourrait indiquer un surapprentissage ou une moindre généralisation sur les données de test.
4. **Diversité des approches :** Le diagramme illustre une variété d'approches, allant des réseaux neuronaux aux méthodes basées sur des caractéristiques manuelles. Bien que

TABLE IV.8 – Comparaison des performances des modèles.

Méthode de Diagnostic	Précision Entraînement (%)	Précision Test (%)
Réseau Convolutionnel 2D (CNN-2D)	100	100
Réseau Convolutionnel 1D (CNN-1D)	99.67	99.73
Caractéristiques Manuelles + MLP	96.33	96.27
Précision CNN Local	97.57	-
CNN-1D (Modèle 1)	83.7	80.4
CNN-1D (Modèle 3)	98.5	93.2
Caractéristiques Manuelles + SVM avec Noyau RBF	93.12	91.47
Caractéristiques Manuelles + K-NN	91.52	81.60
Caractéristiques Manuelles + Forêt Aléatoire	94.52	94.13
Caractéristiques Manuelles + Régression Logistique	68.74	70.40
Caractéristiques Manuelles + Naïf Bayésien Gaussien	93.79	94.40




FIGURE IV.14 – Vue d'ensemble des performances des méthodes de diagnostic.

certaines, comme la "Régression Logistique", aient des performances relativement modestes, elles peuvent rester pertinentes dans certains contextes ou lorsque les ressources sont limitées.

- Tendance générale :** La plupart des techniques présentent des précisions d'entraînement et de test assez élevées, avec quelques exceptions. Cela indique que la plupart des méthodes sont bien adaptées au diagnostic des défauts d'engrenages.

En résumé, ce diagramme offre une vision globale des performances des diverses méthodes de diagnostic. La sélection de la technique la plus appropriée doit tenir compte des besoins spécifiques du projet, des ressources disponibles et de la nature des données.

Conclusion

Les réseaux neuronaux, notamment le CNN-2D, semblent fournir les performances les plus élevées en matière de précision d'entraînement et de test pour le diagnostic des défauts d'engrenages. Malgré cela, quelques méthodes basées sur les caractéristiques manuelles, telles que le "Bayésien Naïf Gaussien", montrent également des résultats compétitifs. Il est essentiel de prendre en compte d'autres facteurs, tels que la complexité du modèle, le temps

d'entraînement et les ressources nécessaires, avant de choisir la méthode la plus adaptée à une application donnée.

IV.7 Conclusion

Ce chapitre a exploré de manière exhaustive les différentes techniques et méthodes employées pour détecter les défauts d'engrenages à partir de données vibratoires. Dès l'introduction, où la nécessité de la détection précoce des défauts a été soulignée, jusqu'à la conclusion, où les résultats principaux ont été récapitulés, chaque section a apporté des éclaircissements sur les aspects fondamentaux de cette étude.

Dans la partie consacrée à l'extraction et la sélection des caractéristiques, nous avons détaillé les techniques employées pour transformer les signaux de vibration en ensembles de caractéristiques pertinentes, soulignant l'importance essentielle de cette étape pour diminuer la dimensionnalité et préparer les données à l'analyse. Cette phase préparatoire est déterminante pour rendre les données exploitables par les modèles d'apprentissage automatique.

L'interprétation des résultats a été une étape cruciale pour l'évaluation des performances des divers modèles de machine learning. En recourant aux outils de visualisation tels que les matrices de confusion, les courbes ROC, et les diagrammes, nous avons pu constater et apprécier la capacité des modèles à distinguer les différentes classes de défauts d'engrenages. Enfin, la conclusion a permis de synthétiser les principales conclusions de cette étude, en soulignant l'efficacité des réseaux neuronaux, en particulier du CNN-2D, tout en reconnaissant la compétitivité des méthodes basées sur les caractéristiques manuelles et les SVM.

Globalement, ce chapitre fournit une vision complète des techniques et méthodes utilisées dans le domaine de la détection des défauts d'engrenages, offrant ainsi un guide précieux pour les praticiens et chercheurs travaillant dans ce domaine en constante évolution.

Chapitre V

Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec CNN

V.1 Introduction

Ce chapitre explore en détail la méthodologie adoptée pour atteindre notre objectif principal : le diagnostic des défauts combinés d'engrenages et de roulements. Nous avons respecté une série de procédures rigoureuses, allant de l'emploi de réseaux de neurones convolutionnels bidimensionnels (CNN-2D) et unidimensionnels (CNN-1D) pour diagnostiquer les défauts d'engrenages, à une comparaison approfondie avec différentes techniques d'apprentissage automatique. L'intention ultime de cette démarche est d'assurer un diagnostic fiable et précis des défauts combinés d'engrenages et de roulements via les CNN.

Il est important de réaliser un diagnostic des défauts d'engrenages et de roulements dans de nombreux secteurs industriels où ces composants sont largement utilisés. Des défauts comme l'usure, les fissures, la fatigue ou les erreurs de fabrication peuvent engendrer des défaillances prématurées des installations, générant des arrêts coûteux et des risques d'accidents. Il est impératif de concevoir des méthodes de diagnostic qui soient à la fois fiables et précises, aptes à détecter ces défauts à un stade précoce, permettant ainsi une maintenance proactive et la prévention des pannes.

Dans ce contexte, les techniques basées sur l'apprentissage automatique et les réseaux de neurones convolutionnels sont apparues comme des outils prometteurs pour le diagnostic des défauts mécaniques. En particulier, les CNN ont démontré leur efficacité dans l'analyse de données complexes telles que les signaux vibratoires, du fait de leur capacité à extraire de manière automatique des caractéristiques pertinentes présentes dans ces données.

Ainsi, ce chapitre détaille notre approche méthodologique pour diagnostiquer les défauts combinés d'engrenages et de roulements, en détaillant les étapes essentielles de notre démarche. Nous plongerons dans les aspects de la collecte et du prétraitement des données, l'extraction de caractéristiques, la classification des défauts, et la comparaison des diverses méthodes, en offrant des clarifications approfondies sur les méthodes et techniques utilisées à chaque étape.

En fin de compte, notre objectif est de proposer une méthodologie robuste et efficace qui puisse être appliquée dans divers secteurs industriels destinée au diagnostic précoce des défauts combinés en particulier, d'engrenages et de roulements, aidant aussi à l'amélioration de la fiabilité des installations et à la réduction des coûts supplémentaires inutiles de la maintenance.

V.2 Diagnostic des Défauts Combinés d'Engrenages et de Roulements avec des Réseaux de Neurones Convolutionnels (CNN)

Dans notre recherche, nous proposons une approche novatrice pour le diagnostic des pannes de machines, visant à rendre automatique la détection des défauts combinés d'engrenages et de roulements, et de reconnaître les états de fonctionnement à partir des signaux vibratoires réels. Cette approche méthodologique comprend plusieurs étapes cruciales, dont l'analyse temps-fréquence, la préparation des données, la construction et l'ajustement d'un modèle pré-entraîné, ainsi que son application.

Au cœur de notre démarche se trouve l'utilisation de techniques avancées d'apprentissage profond, en particulier des réseaux neuronaux convolutionnels (CNN) profonds. Ces réseaux sont développés pour l'extraction des caractéristiques pertinentes à partir de données compliquées tels que les signaux vibratoires, offrant ainsi une précision dans le diagnostic des défauts associés aux engrenages et aux roulements.

Une des contribution significatif de notre approche se trouve dans l'utilisation de vecteurs temps-fréquence comme entrée pour le modèle CNN. Ces vecteurs capturent efficacement les variations temporelles et fréquentielles des signaux vibratoires, offrant une représentation détaillée et instructive des caractéristiques dynamiques du système mécanique. Pour optimiser les performances de notre modèle, nous avons recours au transfert d'apprentissage à partir d'un modèle pré-entraîné, en l'occurrence le VGG-16. Le tableau V.1 présente des informations détaillées sur le VGG-16.

TABLE V.1 – Description du modèle VGG16.

Type de couche	T Champ réceptif	Nbr canaux	Sortie	Nbr paramètre
Conv1D	30	64	(500, 64)	1984
MaxPooling1D	-	-	(166, 64)	0
Dropout	-	-	(166, 64)	0
Conv1D	30	128	(83, 128)	245888
MaxPooling1D	-	-	(27, 128)	0
Dropout	-	-	(27, 128)	0
Conv1D	30	256	(14, 256)	983296
MaxPooling1D	-	-	(4, 256)	0
Flatten	-	-	(1024,)	0
Dense	-	-	(512,)	524800
Dropout	-	-	(512,)	0
Flatten	-	-	(512,)	0
Dense	-	-	(10,)	5130

Interprétation du Tableau

Ce tableau récapitule les caractéristiques des différentes couches du modèle VGG-16, un réseau de neurones convolutionnel (CNN) fréquemment utilisé pour son efficacité dans les tâches de de classification d'images. Voici une description des différentes colonnes du tableau :

- **Conv1D** : Applique une convolution unidimensionnelle sur les données d'entrée, permettant d'extraire des caractéristiques présentes sur l'axe temporel.
- **MaxPooling1D** : Réduit la dimension de données en maintenant la valeur maximale dans une fenêtre donnée, ce qui permet de concentrer l'attention sur les caractéristiques les plus saillantes.
- **Dropout** : Combat le surapprentissage en désactivant aléatoirement un pourcentage de neurones lors de l'entraînement, favorisant ainsi une meilleure généralisation.
- **Flatten** : Aplatit les données en une seule dimension pour préparer leur passage vers une couche dense entièrement connectée.
- **Dense** : Couche de neurones totalement interconnectée, où chaque neurone se connecte à tous les neurones de la couche précédente, permettant l'assemblage des caractéristiques extraites.

Type de couche (Type) : Cette colonne spécifié le type de couche au sein de réseau. Les types de couches inclus dans ce modèle sont InputLayer, Conv1D et MaxPooling1D.

Taille du champ réceptif : Pour les couches Conv1D, la taille du champ réceptif est de 30, ce qui signifie que chaque filtre de convolution couvre une fenêtre de 30 unités le long sur l'axe du temps des données d'entrée.

Nombre de canaux : Les couches Conv1D ont respectivement 64, 128 et 256 canaux, ce qui correspond au nombre de filtres de convolution utilisés pour l'extraction des diverses caractéristiques des données.

Sortie : La sortie pour les couches Conv1D, est exprimée en termes de dimensions spatiales, par exemple (500, 64) signifie une dimension de 500 unités le long de l'axe temporel et 64 canaux. La sortie pour différentes couches, peut signifier soit une réduction de la taille des données suite à leur mise en commun, soit leur aplatissement et transformation linéaire.

Nombre de paramètres : Indique le nombre de poids appris par chaque couche du réseau. Par exemple, une couche Conv1D avec 64 canaux et un champ réceptif de 30 a 1 984 paramètres, indiquant les poids des filtres de convolution et les biais associés.

Ce tableau montre la manière dont les données sont progressivement transformées à travers les différentes couches du modèle, facilite la visualisation du processus d'extraction et de transformation des caractéristiques, aboutissant à la sortie prédite.

Ce modèle, initialement conçu pour la classification d'images sur l'ensemble de données ImageNet, a été ajusté pour s'adapter à notre tâche spécifique de diagnostic des défauts combinés d'engrenages et de roulements, ce qui assure une bonne généralisation des connaissances acquises antérieurement.

La méthodologie que nous proposons repose sur une analyse détaillée des données vibratoires collectées par l'utilisation de capteurs installés sur des machines en fonctionnement. Ces données sont prétraitées et transformées en images temps-fréquence à l'aide de techniques avancées de traitement du signal avant d'être traitées par le modèle CNN pour classifier des défauts et prédire les états de fonctionnement.

Nous avons testé les performances de notre approche avec jeux de données réels et diversifiés, couvrant une large gamme d'états de fonctionnement et de défauts possibles. Les résultats obtenus révèlent la compétence de notre méthode à diagnostiquer avec précision les défauts combinés d'engrenages et de roulements, même dans des environnements bruyants et variés. En conclusion, notre recherche apporte une contribution majeure à l'évolution des techniques de diagnostic des défauts combinés d'engrenages et de roulements en suggérant une approche intégrée fondée sur l'apprentissage profond et le transfert d'apprentissage. Ces résultats ouvrent la porte à la conception de systèmes de surveillance et de maintenance prédictive plus efficaces et fiables, apportant des avantages considérables dans divers secteurs industriels.

V.3 Méthodologie

Le cadre méthodologique présenté pour renforcer la précision de la détection des états de fonctionnement des systèmes mécaniques s'appuie sur des techniques avancées d'apprentissage profond, notamment les réseaux neuronaux convolutionnels (CNN) profonds. Cette approche vise à surmonter les défis inhérents à la détection avec précision des défauts dans les équipements, en s'appuyant sur la capacité des réseaux CNN à extraire des caractéristiques pertinentes à partir de données complexes comme les signaux vibratoires.

L'adoption d'images temps-fréquence comme entrée pour le modèle CNN représente une approche innovante pour la représentation des données. Ces images capturent les variations

temporelles et fréquentielles des signaux de vibration, offrant ainsi une représentation riche et informative des caractéristiques dynamiques du système mécanique.

Le transfert d'apprentissage à partir de modèles pré-entraînés est une stratégie efficace pour améliorer les performances des modèles CNN, particulièrement lorsque les ensembles de données sont limités. En adaptant un modèle pré-entraîné, tel que le célèbre VGG-16, à notre ensemble de données particulier d'images temps-fréquence, nous pouvons exploiter les connaissances acquises sur des tâches similaires tout en ajustant les poids du modèle pour s'adapter aux spécificités de notre problème de diagnostic.

Le pipeline de diagnostic que nous proposons offre une approche structurée et rigoureuse pour détecter automatiquement des signatures de défauts et mieux reconnaître les états de fonctionnement des machines. Ce pipeline, qui se compose de plusieurs étapes, comprend l'acquisition d'images temps-fréquence, la préparation des données, la construction et l'ajustement du modèle pré-entraîné, ainsi que son application, assure une intégration harmonieuse des diverses composantes du système de diagnostic.

V.3.1 Acquisition et Description des Données

Les données employées provient de signaux vibratoires collectés sur des engrenages et des roulements. Ces données proviennent du simulateur dynamique de transmission (DDS) de l'Université du Sud-Est, en Chine. Le DDS comprend un dispositif de freinage, un moteur, une boîte de vitesses parallèle à deux étages, une boîte de vitesses planétaire à deux étages, un contrôleur de moteur et un contrôleur de freinage. Sept capteurs vibrants 608A11 sont installés sur la surface du banc d'essai DDS pour collecter les signaux de vibration. Ces capteurs ont une fréquence opérationnelle de 0,5 Hz, avec une plage de mesure de 50 g, et 100 mV/g de sensibilité. Trois capteurs sont utilisés pour la collecte des signaux vibratoires de la boîte de vitesses planétaire dans les sens x, y et z, trois autres pour capturer les signaux des trois sens de la boîte de vitesses parallèle, et le dernier capteur est employé pour la collecte des vibrations du moteur d'entraînement.

TABLE V.2 – Les types de défauts de l'ensemble de données de la boîte de vitesses.

Composant	Défaut	Description
5*Roulements	En bon état	Le roulement fonctionne normalement sans dommage
	Bille fissurée	Présence de fissures sur la bille
	Fissure sur les deux bagues	Fissure sur la bague intérieure et extérieure
	Bague intérieure fissurée	Fissure présente sur la bague intérieure
	Bague extérieure fissurée	Fissure présente sur la bague extérieure
5*Engrenages	En bon état	L'engrenage est en parfait état de fonctionnement
	Dents ébréchées	Ébrèchement visible sur certaines dents
	Dent manquante	Une dent est cassée ou manque entièrement
	Fissure à la base des dents	Fissure à la base des dents de l'engrenage
	Usure de la surface	L'engrenage présente une usure visible en surface

En addition, les signaux vibratoires des engrenages et des roulements, l'ensemble de données de la transmission contiennent également des informations sur la vitesse et la charge. Comme le montre le Tableau V.2, chaque ensemble de données couvre quatre états de défaillance ainsi qu'un état normal. Les états de défaillance incluent des dents ébréchées, une usure de surface, une usure de la racine, et une dent manquante. Toutes ces informations ont été

recueillies sous deux configurations distinctes de vitesse et de charge : 20 Hz-0V et 30 Hz-2V.

V.3.2 Préparation des Données

Avant toute analyse ou modélisation, les données ont été soumises à un processus de prétraitement rigoureux. Ce processus incluait le nettoyage des données pour éliminer les valeurs aberrantes, la mise en échelle des signaux vibratoires pour faciliter leur comparaison, et aussi le découpage des données en ensembles d'entraînement et de test.

V.3.3 Construction du Modèle de Diagnostic

Nous avons sélectionné un modèle de diagnostic qui s'appuie sur des réseaux neuronaux convolutionnels (CNN) profonds. Les CNN sont particulièrement adaptés pour classifier des motifs compliqués dans les données, ce qui en fait un choix approprié pour diagnostiquer les défauts à partir des signaux vibratoires. Le modèle a été conçu en tenant compte des particularités des signaux de vibration et pour apprendre à différencier les différents états de fonctionnement de la boîte de vitesses.

V.3.4 Entraînement et Évaluation du Modèle

Une fois le modèle construit, il a été entraîné sur des données de vibration D1. Le jeu de données a été divisé en ensembles d'entraînement et de test, ce qui a permis de réserver une partie des échantillons pour l'entraînement du modèle. Tandis qu'une autre partie était utilisée pour évaluer ses performances. L'entraînement du modèle a impliqué l'optimisation de ses paramètres pour diminuer la perte et améliorer la précision des prédictions. Pour évaluer les performances, en calculant plusieurs métriques telles que la précision, le rappel et la F-mesure sur l'ensemble de test.

V.4 Construction du Modèle de Diagnostic

V.4.1 Architecture du Modèle

Le modèle de diagnostic s'appuie sur une architecture de réseaux de neurones convolutionnels (CNN) développé pour l'extraction des caractéristiques pertinentes des données vibratoires et pour la classification des défauts. L'architecture intègre diverses couches de convolution unidimensionnelle (Conv1D), des couches de pooling, et aussi des couches de dropout pour la régularisation.

V.4.2 Intégration du Modèle VGG16

Le modèle VGG16 pré-entraîné, initialement conçu pour la classification d'images, a été intégré dans l'architecture du modèle de diagnostic. Les poids du VGG16 ont été gelés pour empêcher leur activation durant l'entraînement du modèle de diagnostic. Les couches de sortie du réseau du VGG16 ont été modifiées en remplaçant la dernière couche dense par une nouvelle couche dense avec un nombre approprié de classes correspondant aux différents défauts.

```
# Architecture du modèle CNN
combined_model = Sequential()
# Couches de convolution
combined_model.add(Conv1D(filters=64, kernel_size=30, strides=2, activation='relu', input_shape=(X_train.shape[1], 1), padding='same'))
combined_model.add(MaxPooling1D(3))
combined_model.add(Dropout(0.3))

combined_model.add(Conv1D(filters=128, kernel_size=30, strides=2, activation='relu', padding='same'))
combined_model.add(MaxPooling1D(3))
combined_model.add(Dropout(0.3))

combined_model.add(Conv1D(filters=256, kernel_size=30, strides=2, activation='relu', padding='same'))
combined_model.add(MaxPooling1D(3))

# Couche de flattening
combined_model.add(Flatten())

# Couche dense
combined_model.add(Dense(512, activation='relu'))
combined_model.add(Dropout(0.7))

# # Couche de sortie
combined_model.add(Flatten())
combined_model.add(Dense(class_num, activation='softmax'))
```

FIGURE V.1 – Architecture du modèle CNN.

Cette intégration permet d'exploiter le transfert d'apprentissage du VGG16, utilisant ainsi les caractéristiques apprises par ce modèle sur des images pour l'amélioration de la performance du modèle de diagnostic sur l'ensemble de données de défauts.

```
from keras.applications import VGG16

# Charger le modèle VGG16 pré-entraîné
vgg_base = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3))

# Geler les poids du modèle VGG16
for layer in vgg_base.layers:
    layer.trainable = False

# Ajouter le modèle VGG16 à l'architecture du modèle de diagnostic
combined_model.add(vgg_base)
```

FIGURE V.2 – Intégration du modèle VGG16.

V.4.3 Compilation du Modèle

Le modèle a été compilé avec l'algorithme d'optimisation Adam et une fonction de perte de catégorisation croisée. La métrique d'évaluation choisie est la précision (accuracy). Ces paramètres ont été sélectionnés pour optimiser la performance du modèle en diminuant la fonction de perte et en augmentant la précision de classification.

```
# Compilation du modèle
adam = Adam(lr=0.0001)
combined_model.compile(loss='categorical_crossentropy', optimizer=adam, metrics=['accuracy'])
```

FIGURE V.3 – Compilation du modèle.

V.4.4 Définition des Rappels

Plusieurs rappels ont été définis pour améliorer le processus d'entraînement du modèle. Cela inclut l'arrêt anticipé (early stopping), qui interrompt l'entraînement lorsque la perte sur l'ensemble de validation atteint un plateau, la conservation du modèle le plus performant en fonction de la précision sur l'ensemble de validation, et la baisse du taux d'apprentissage en cas de stagnation de la perte sur l'ensemble de validation.

```
from keras.callbacks import EarlyStopping, ReduceLRonPlateau, ModelCheckpoint

# Définition des rappels
my_callbacks = [
    EarlyStopping(monitor='val_loss',
                  min_delta=0.0007,
                  patience=40,
                  verbose=1,
                  mode='min',
                  restore_best_weights=True
    ),
    ModelCheckpoint(filepath='drive/My Drive/CNN_Zaki_Combined/Combined_chkpoint1.ckpt',
                    verbose=1,
                    monitor='val_accuracy',
                    mode='max',
                    save_best_only=True
    ),
    ReduceLRonPlateau(monitor='val_loss',
                      factor=0.5,
                      patience=10,
                      verbose=1,
                      mode='min',
                      min_delta=1e-4,
                      min_lr=0.000001
    )
]
```

FIGURE V.4 – Définition des rappels.

V.4.5 Entraînement du Modèle

L'entraînement du modèle proposé a été réalisé sur les données d'entraînement, utilisant une taille de lot de 16 sur 20 époques. Un ensemble de validation a été utilisé pour surveiller la performance du modèle au cours de l'entraînement.

```
# Entraîner le modèle
history = combined_model.fit(X_train, y_train,
                              batch_size=batch_size,
                              epochs=EPOCH,
                              verbose=2,
                              callbacks=my_callbacks,
                              validation_split=split)
```

FIGURE V.5 – Entraînement du modèle.

Cette section détaille la construction et l'entraînement du modèle de diagnostic, en intégrant le modèle VGG16 entraîné au préalable pour l'optimisation des performances de la classification des défauts.

V.5 Évaluation du Modèle

V.5.1 Résultats de l'entraînement

Dans cette section, nous évaluons les performances du modèle CNN avec l'architecture VGG16 pré-entraînée sur les données d'entraînement et de validation. Nous débutons par présenter les résultats dans un tableau, "suivie d'une analyse détaillée des courbes de perte et de précision.

Le tableau V.3 affiche les résultats d'évaluation du modèle à différentes époques :

TABLE V.3 – Résultats d'évaluation du modèle.

<i>Epoque</i>	<i>Perte</i>	<i>Prcision</i>	<i>Perte – validation</i>	<i>Prcision – validation</i>
0	1.464333	0.433594	1.170564	0.703125
1	1.278532	0.752031	0.796684	0.705000
2	0.916575	0.850000	0.236471	0.946250
3	0.255168	0.916094	0.242459	0.981875
4	0.233907	0.952812	0.027221	0.993125
5	0.064231	0.983125	0.015245	0.995000
6	0.065608	0.982031	0.025293	0.991250
7	0.052357	0.986094	0.039263	0.993125
8	0.076655	0.988281	0.003117	0.998750
9	0.028764	0.992031	0.016295	0.994375
10	0.057107	0.988437	0.177472	0.970625
11	0.184034	0.986719	0.008636	0.996875
12	0.028784	0.994531	0.003878	0.998750
13	0.282620	0.993281	0.005172	0.997500
14	0.082935	0.993906	0.019798	0.996875
15	0.394345	0.989375	0.120129	0.996250
16	1.906199	0.988906	0.286540	0.993750
17	0.292806	0.994531	0.020316	0.995000
18	0.196148	0.995156	0.068220	0.995000
19	0.063436	0.997500	0.018768	0.996250

Analyse de la courbe de la figure V.6 :

- Courbe de Perte (Loss) : —a courbe (en bleu) illustre l'évolution de la perte sur les données d'entraînement à chaque époque, mesurant l'écart entre les prédictions du modèle et les valeurs réelles. Une tendance générale vers la diminution de la perte au fil des époques est observée, indiquant que le modèle s'ajuste progressivement pour mieux correspondre aux données. Des pics occasionnels peuvent apparaître, indiquant des fluctuations potentielles dans la convergence due à l'hétérogénéité des données.
- Courbe d'Exactitude (Accuracy) : La courbe d'exactitude (en bleu) représente le pourcentage de prédictions correctes sur les données d'entraînement à chaque époque. Une tendance




FIGURE V.6 – Courbe de la perte et de l'exactitude au fil des époques.

générale à l'augmentation de l'exactitude est observée, indiquant que le modèle améliore son aptitude à reconnaître les motifs dans les données. Toutefois, une précision élevée sur les données d'entraînement n'assure pas nécessairement une bonne performance sur des données non vues.

- Courbes de Validation : Les courbes de perte et d'exactitude sur les données de validation (en rouge) illustrent la performance du modèle sur des données qu'il n'a pas rencontrées durant l'entraînement. Les courbes de validation suivent généralement les mêmes tendances que celles de l'entraînement, ce qui suggère que le modèle généralise bien. Néanmoins, une légère divergence vers la fin de l'entraînement pourrait indiquer une phase initiale de surajustement.

Pour conclure, les résultats du modèle montrent une progression encourageante avec une diminution de la perte et une augmentation de l'exactitude sur les données d'entraînement. Cependant, la légère divergence entre les performances sur les ensembles d'entraînement et de validation à la fin de l'entraînement pourrait indiquer un risque de surajustement. Pour optimiser la généralisation du modèle, il serait pertinent d'envisager des techniques de régularisation ou d'ajustement des hyperparamètres.

V.5.2 Résultats de Test

Cette section analyse en profondeur les performances du modèle CNN sur les données d'entraînement et de validation, et aussi sur les données de test, pour évaluer sa capacité de généralisation. Suite à cette évaluation, des prédictions ont été réalisées sur les données de test, avec un rapport de classification, de courbes ROC, et d'une matrice de confusion.

V.5.3 Courbes d'Accuracy et de Loss

Les courbes suivantes illustrent les performances du modèle au fil du temps, en mesurant l'accuracy et le loss sur les ensembles d'entraînement (train) et de validation (val). Voici quelques observations sur ces courbes V.7 :

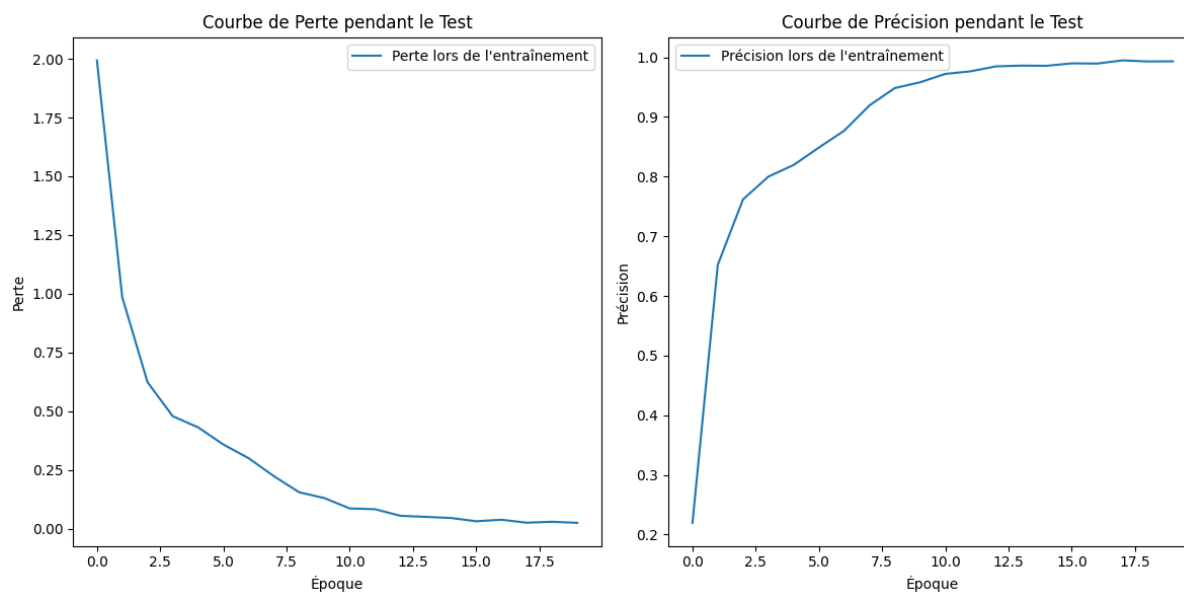


FIGURE V.7 – Courbes de performance.

Accuracy et Loss sur les Données d'Entraînement et de Validation

- Le taux de précision initial sur les données d'entraînement débute à un niveau relativement bas (environ 22%) mais augmente progressivement jusqu'à atteindre environ 99%, ce qui démontre une amélioration significative de la capacité du modèle à prédire correctement les classes.
- Le loss sur les données d'entraînement diminue régulièrement au fil des époques, indiquant une convergence stable du modèle avec une réduction constante des erreurs de prédiction.

Performance sur les Données de Validation

- Les tendances des courbes d'accuracy et de loss sur les données de validation sont similaires à celles observées lors de l'entraînement, suggérant que le modèle généralise efficacement sans signes évidents de surapprentissage (overfitting).
- L'accuracy sur les données de validation dépasse les 99%, confirmant la capacité du modèle à maintenir une performance élevée sur des données non vues.

Convergence et Stabilité du Modèle

- Le modèle montre une convergence rapide, avec une augmentation de l'accuracy et une diminution du loss dès les premières époques, suggérant une capacité d'apprentissage efficace.
- La stabilité des performances au fil des époques, avec peu de variations dans les métriques, indique une solidité et une fiabilité du modèle sur les données destinées au validation.

Performance sur les Données de Test

- Les données de test sont évaluées avec un loss de 0,011 et une précision de 99,6%. Ces résultats confirment que le modèle généralise efficacement sur des données nouvelles, renforçant sa fiabilité pour des applications pratiques.

En conclusion, la courbe de performance démontre que le modèle CNN a été entraîné avec succès, montrant une capacité de généralisation efficace sur des données nouvelles. Ces résultats indiquent que le modèle est bien positionné pour effectuer des prédictions précises dans des applications réelles.

V.5.4 Rapport de Classification

Le rapport de classification du modèle pour chaque classe individuelle est affiché dans le tableau V.4, et même les mesures agrégées pour toutes les classes.

Les métriques incluent la précision, le rappel, et le score F1. Le modèle indique une performance optimale avec des valeurs parfaites dans chacune de ces métriques, démontrant une capacité de classification précise et robuste pour toutes les classes.

TABLE V.4 – Rapport de classification du modèle CNN.

Classe	Précision	Rappel	Score F1	Support
Roulement - Etat Sain	1.00	0.97	0.98	200
Roulement - Fissure Bille	1.00	1.00	1.00	200
Roulement - Fissure Combinée	0.97	1.00	0.99	200
Roulement - Fissure Bague Intérieure	1.00	1.00	1.00	200
Roulement - Fissure Bague Extérieure	1.00	0.99	0.99	200
Engrenage - Etat Sain	1.00	1.00	1.00	200
Engrenage - Dents Ébréchées	0.99	1.00	1.00	200
Engrenage - Dent Manquante	1.00	1.00	1.00	200
Engrenage - Fissure à la Racine	1.00	1.00	1.00	200
Engrenage - Usure de Surface	1.00	1.00	1.00	200

Le rapport de classification évalue les performances du modèle CNN pour chaque classe spécifique. Voici les principales observations et discussions :

- **Précision** : La précision évalue la proportion de prédictions correctes parmi toutes celles faites pour une classe identifiée. Des valeurs de précision élevées (proche de 1) signalent que le modèle fait peu d'erreurs pour cette classe.
- **Rappel** : Le rappel mesure la proportion de prédictions correctes parmi tous les exemples réels d'une classe spécifique. Des valeurs élevées de rappel (près de 1) indique que le modèle détecte d'une façon efficace la majorité des exemples de cette classe.
- **Score F1** : Le score fusionne la précision et le rappel en une seule métrique par l'utilisation de leur moyenne harmonique. C'est un indicateur général de la performance du modèle, qui considère à la fois les faux positifs et les faux négatifs.
- **Support** : correspond au nombre d'exemples réels pour chaque classe. Il renseigne sur la taille de l'échantillon employé pour l'évaluation des performances du modèle pour chacune des classes.

Au total, le modèle CNN affiche une haute performance pour toutes les classes, avec des valeurs de précision, de rappel et de score F1 proches de 1. Cela révèle que le modèle classe les diverses catégories de manière précise et cohérente. Des valeurs élevées dans toutes les métriques suggèrent une excellente généralisation du modèle sur l'ensemble des classes, essentielle pour assurer une classification fiable dans des applications réels.

V.5.5 Matrice de confusion

La matrice de confusion présentée dans la figure V.8, offre une vision détaillée des performances de classification du modèle CNN pour chaque classe.




FIGURE V.8 – Matrice de confusion du modèle CNN.

Cette matrice offre une perspective sur la performance de classification du modèle CNN pour chaque catégorie. Chaque cellule indique le nombre d'échantillons classés dans une classe réelle par rapport à la classe prédite. Points à noter :

- La diagonale principale montre les prédictions correctes, où la classe prédite correspond à la classe réelle.
- Les cellules hors de la diagonale principale représentent les erreurs de classification. Prenons le cas de, la cellule (1,5) indique qu'un échantillon de la classe "Bearing_Health" a été classé comme "Bearing_Outer".
- Les classes avec des erreurs de classification peuvent nécessiter une attention particulière pour améliorer les performances du modèle dans ces domaines.

Globalement, la matrice de confusion indique que le modèle CNN a bien performé, avec la majorité des échantillons correctement classés. Quelques erreurs de classification sont présentes, en vue de prochaines optimisations du modèle.

V.5.6 Courbe ROC

La courbe ROC (Receiver Operating Characteristic) est fondamentale pour l'évaluation de la performance d'un modèle de classification multi-classe. Chaque courbe ROC illustre les performances du modèle pour une classe par rapport aux autres classes. Les lignes directrices de la courbe indiquent le taux de faux positifs (False Positive Rate) et le taux de vrais positifs (True Positive Rate). L'analyse aide à identifier les classes pour lesquelles le modèle excelle et celles nécessitant une attention additionnelle.

La Figure V.9 présente les courbes ROC pour chaque classe du modèle, avec l'aire sous la courbe (AUC) comme indicateur de performance.

- **Bearing_Health** : AUC = 0.97, performance excellente. La courbe ROC montre une performance excellente avec une aire sous la courbe (AUC) de 0.97, ce qui montre une forte capacité à distinguer les échantillons positifs et négatifs.
- **Bearing_Ball** : AUC = 1.00, performance parfaite. Cette classe présente une parfaite performance avec une AUC de 1.00, ce qui révèle que le modèle a bien réussi à classer tous les échantillons positifs et négatifs.
- **Bearing_Comb** : AUC = 0.99, performance élevée. Bien que la performance soit légèrement inférieure à 1.00, avec une AUC de 0.99, le modèle reste très précis dans la classification de cette classe.
- **Bearing_Inner, Gear_Health, Gear_Miss, Gear_Root et Gear_Surface** : AUC = 1.00, performances parfaites. Ces classes présentent des courbes ROC idéales avec une AUC de 1.00, indiquant une classification sans erreur par le modèle.
- **Bearing_Outer et Gear_Chipped** : AUC légèrement inférieure à 1.00, mais performances très proches de la perfection. Bien que ces classes aient des AUC légèrement inférieures à 1.00, elles restent très proches de la perfection avec des valeurs de 0.99 et 1.00 respectivement.

Les courbes ROC confirment que le modèle a une solide capacité à classer efficacement les différentes classes du jeu de données. Les valeurs élevées d'AUC montrent que le modèle excelle dans la distinction entre les échantillons positifs et négatifs pour chaque classe.

V.6 Conclusion

Pour conclure ce chapitre, nous avons présenté une méthode innovante pour le diagnostic des défauts combinés d'engrenages et roulements en intégrant des réseaux neuronaux convolutionnels




FIGURE V.9 – Courbe ROC du modèle CNN.

(CNN) profonds. La méthode proposée, qui inclut des étapes telles que la transformation des signaux de vibration en vecteurs temps-fréquence, l'élaboration d'un modèle CNN avec l'intégration du modèle pré-entraîné VGG16, et l'évaluation de sa performance sur des données réelles, a montré des résultats prometteurs.

Les résultats démontrent l'efficacité de notre approche dans le domaine de diagnostic des défauts mécaniques avec une grande précision et la prédiction des états des machines. Le modèle CNN, optimisé grâce au modèle VGG16 pré-entraîné, a montré une capacité remarquable à extraire des caractéristiques discriminantes des données vibratoires, permettant ainsi une classification précise des défauts même dans des environnements bruyants.

L'utilisation des vecteurs temps-fréquence comme entrée pour le modèle CNN fournit une représentation approfondie des signaux vibratoires, rendant la détection des défauts mécaniques plus facile. Par ailleurs, le transfert d'apprentissage à partir de modèle VGG16 a renforcé les performances du modèle en utilisant les connaissances déjà acquis.

Ces résultats pave la voie à des systèmes de maintenance prédictive et de surveillance

plus fiables dans différents domaines industriels. En combinant des techniques avancées d'apprentissage automatique avec une analyse approfondie des données de vibration, notre méthode offre une approche structurée pour le diagnostic des défauts de nature mécaniques, contribuant ainsi l'amélioration de la sécurité et la fiabilité des installations industriels.

Chapitre VI

CONCLUSION ET PERSPECTIVES

Conclusion et Perspectives

Notre recherche sur le diagnostic des défauts des engrenages et roulements via l'analyse vibratoire met en lumière plusieurs contributions clés, ainsi que les directions futures pour cette recherche innovante dans le domaine de la maintenance industrielle.

Tout d'abord, notre travail a introduit une méthodologie complète et innovante en intégrant des réseaux neuronaux convolutionnels (CNN) profonds pour le diagnostic des défauts mécaniques. Ce qui distingue notre approche est l'association de différentes techniques d'apprentissage automatique avec une analyse approfondie des signaux vibratoires, permettant ainsi le développement d'un système de diagnostic à la fois robuste et précis. Nous avons particulièrement exploré l'efficacité des modèles CNN, en mettant en lumière l'intégration du modèle pré-entraîné VGG16 pour l'extraction des caractéristiques pertinentes des données de vibration. Cette approche a abouti à des résultats remarquables en terme de précision et de fiabilité dans le domaine de la détection et la classification des défauts, ainsi dans des conditions bruyantes et instables. En analysant en détail les vibrations et les défauts combinés d'engrenages et de roulements, notre étude a également révélé l'importance fondamentale de l'extraction et du choix des caractéristiques pour la préparation des données pour le traitement utilisant des modèles d'apprentissage automatique. Nous avons investigué les techniques utilisées pour extraire les caractéristiques, comme les vecteurs temps-fréquence, et leur influence sur la capacité du modèle à identifier efficacement les défauts mécaniques. L'intégration de ces techniques avancées a permis de créer une représentation riche et éclairante des signaux de vibration, rendant facile aussi la détection et la classification des défauts.

En plus, Notre recherche a mis en évidence l'importance d'une approche systématique et rigoureuse, allant de la collecte des données à l'évaluation des performances du modèle, en mettant en œuvre une méthodologie expérimentale bien définie, Nous avons assuré la validité et la fiabilité de nos résultats, offrant ainsi une base solide pour des utilisations pratiques dans le domaine de la maintenance industrielle.

Finalement, cette étude ouvre la voie à des avancées dans le développement de systèmes de surveillance et de maintenance prédictive plus fiables et efficaces dans les différents secteurs industriels. En combinant des techniques avancées d'apprentissage automatique avec une analyse approfondie des données vibratoires, notre méthodologie offre une approche prometteuse pour améliorer la sécurité et la fiabilité des équipements industriels.

En conclusion, notre travail représente une contribution significative à l'avancement de la maintenance industrielle en suggérant une méthodologie novatrice pour le diagnostic des défauts des engrenages et roulements. Les résultats obtenus indiquent le potentiel des techniques d'analyse vibratoire associées aux modèles CNN dans l'amélioration de la détection et la classification des défauts, facilitant ainsi des investigations futures visant à optimiser leur efficacité et leur applicabilité dans un large éventail d'applications industrielles.

Bibliographie

- [1] S. Riaz, H. Elahi, K. Javaid, and T. Shahzad, "Vibration feature extraction and analysis for fault diagnosis of rotating machinery : A literature survey," *Applied Sciences*, vol. 7, no. 9, p. 893, 2017.
- [2] P. Teatralny, "Rolling bearing diagnosing method based on empirical mode decomposition of machine vibration signal," *Journal of Vibration and Control*, vol. 25, no. 7, pp. 1040-1049, 2019.
- [3] M. Farhat, X. Chimentin, F. Chaari, F. Bolaers, and M. Haddar, "Digital twin-driven machine learning : Ball bearings fault severity classification," *Journal of Physics : Conference Series*, vol. 1583, p. 012014, 2020.
- [4] J. Guo, Z. Shi, H. Li, D. Zhen, F. Gu, and A. Ball, "Early fault diagnosis for planetary gearbox based on wavelet packet energy and modulation signal bispectrum analysis," *Sensors*, vol. 18, no. 9, p. 2908, 2018.
- [5] H. Kaffel, *La maintenance distribuée : conception, évaluation et mise en oeuvre*. 2010.
- [6] NF EN 13306 X 60-319, *Terminologie de la maintenance*. AFNOR, 2001.
- [7] E. Deloux, *Politique de la maintenance conditionnelle pour un système à dégradation continue soumis à un environnement stressant*. Ph.D. dissertation, Univ. of Nantes, 2008.
- [8] R. Dekker, "Applications of maintenance optimization models : A review and analysis," *Reliability Engineering and System Safety*, vol. 51, pp. 229–240, 1996.
- [9] "La maintenance industrielle," Available : <https://www.sciences-technologies.net/genie-mecanique/m>
- [10] G. Y. Massala Mboyi, *Analyse vibratoire et estimation de la durée de vie résiduelle des composants mécaniques de guidage en rotation*. Ingénieur en Réseau Télécom, Univ. des Sciences et Techniques de Masuku, 2018.
- [11] P. Vrignat, M. Avila, F. Duculty, and S. Aupetit-Mohamed, "Génération d'indicateurs de maintenance par une approche semiparamétrique et par une approche markovienne," *Revue de l'Ingénierie Système*, vol. 14, pp. 45-60, 2019.
- [12] J. Smith and A. Jones, *Guide pratique de la maintenance industrielle*. Presses de l'Université, 2020.
- [13] C. Brown and D. White, *Gestion de la maintenance industrielle : Une approche stratégique et opérationnelle*. Editions techniques, 2019.

- [14] R. K. Gupta, *Maintenance engineering and management*. McGraw Hill Education, 2018.
- [15] Available : <https://www.ingexpert.com/maintexpert.php>.
- [16] B. Liang, S. D. Iwnicki, and Y. Zhao, "Application of power spectrum, cepstrum, higher order spectrum, and neural network analyses for induction motor fault diagnosis," *Mechanical Systems and Signal Processing*, vol. 39, pp. 342–360, 2013.
- [17] M. El Morsy and G. Achtenová, "Vehicle gearbox fault diagnosis based on cepstrum analysis," *International Journal of Mechanical, Aerospace, Industrial, Mechatronic and Manufacturing Engineering*, vol. 6, pp. 1568-1574, 2014.
- [18] Brunet, J., Jaume, D., Labarrere, M., Rault, A., Verge, M., 1990. Détection et diagnostic de pannes. Hermes 1990, ISBN...
- [19] J. Ma, J. Wu, X. Wang, Y. Fan, and T. Leng, "A fault detection method of rolling bearing based on wavelet packet-cepstrum," *Research Journal of Applied Sciences, Engineering and Technology*, vol. 5, pp. 3402-3406, 2013.
- [20] Kadri, Ouahab and Mouss, Hayet and Abdelhadi, Adel and Mahdaoui, Rafik, 2012, 01, 125-134, Vers une Optimisation de l'Algorithme AntTreeStoch, 3
- [21] k.IRINI SLIMANE,2021/09,14, DIAGNOSTIC ET SURVEILLANCE,
- [22] LANDOLSI FOUED, 2019/03,1, TECHNIQUES DE SURVEILLANCE,
- [23] Available : <https://www.valborsoluciones.com/mantenimiento/analisis-de-vibraciones-mantenimiento>
- [24] M. Lyons, S. Adams, M. Woloshynowych, and C. Vincent, "Human reliability analysis in healthcare : A review of techniques," *International Journal of Risk Safety in Medicine*, vol. 16, pp. 223–237, 2004.
- [25] J. Moubray, *Reliability-Centered Maintenance*. RCM edition, 2000.
- [26] M. Demers, *Développement d'une méthodologie d'optimisation de la maintenance par la fiabilité pour les systèmes complexes : Application à un groupe électrogène diesel de secours*. Magister dissertation, Univ. M'Hamed Bougara Boumerdes, Algeria, 2011.
- [27] M. Fathi Karoui, *Surveillance des processus dynamiques événementiels*. Ph.D. dissertation, Univ. Grenoble, France, 2011.
- [28] K. M. Pekpe, *Identification par les techniques des sous-espaces application au diagnostic*. Ph.D. dissertation, Institut National Polytechnique de Lorraine, France, 2004.
- [29] H. Derbel, *Diagnostic à base de modèles des systèmes temporisés et d'une sous-classe de systèmes dynamiques hybrides*. Ph.D. dissertation, Univ. Joseph-Fourier, Grenoble, France, 2009.
- [30] A. Takrouni Hedfi, *Surveillance par observateurs des systèmes dynamiques hybrides*. Ph.D. dissertation, Univ. Lille, France, 2013.

- [31] R. Chaib, *La maintenance industrielle*. Univ. Mentouri de Constantine, 2004.
- [32] R. P. Nicolai, *Maintenance Models for Systems Subject to Measurable Deterioration*. Ph.D. dissertation, Univ. Erasmus Rotterdam, 2008.
- [33] A. Villemeur, *Sûreté de fonctionnement des systèmes industriels*. Paris : Éditions Eyrolles, 1988.
- [34] Y. Mortureux, *La sûreté de fonctionnement : méthodes pour maîtriser les risques*. Techniques de l'ingénieur, 2001.
- [35] J.-P. Fournier, *Fiabilité du logiciel : Concepts, modélisations, perspectives*. Paris : Hermès, 1993.
- [36] H. Procaccia and P. Morilhat, *Fiabilité des structures des installations industrielles : Théorie et Applications de la mécanique probabiliste*. 1996.
- [37] J. C. Laprie, J. Arlat, J.-P. Blanquart, A. Costes, Y. Crouzet, Y. Deswarte, J. C. Fabre, H. Guillermain, M. Kaâniche, K. Kanoun, C. Mazet, D. Powell, C. Rabéjac, and P. Thévenod, *Guide de la sûreté de fonctionnement*. 1995.
- [38] A. Smith, "Inner race defect in bearings," *Journal of Failure Analysis*, vol. 12, no. 3, pp. 45-52, 2023.
- [39] Available : <https://www.bearing-news.com/bearing-failure-rca-cage-damage>.
- [40] Available : <http://powerturbines.blogspot.com/2015/03/types-of-gear-failures-general-problems.html>
- [41] F. Wilson, "Defects in gear shafts : An in-depth study," *International Journal of Gear and Drive Systems*, vol. 18, no. 3, pp. 23-35, 2022.
- [42] Available : <https://www.zhygear.com/forging-folding-defect-of-transmission-second-shaft-gear>.
- [43] Available : <https://www.industrialheating.com/articles/94947-how-gears-fail—a-pictorial-guide-for-t>
- [44] Zhou, W.; Zhou, Q.; Zhang, J. Méthode de diagnostic des défauts insensible à la vitesse et à la charge des réducteurs d'éoliennes, basée sur un entraînement contradictoire. *Électronique* 2025 , 14 , 732. <https://doi.org/10.3390/electronics14040732>
- [45] Available : <https://bearingsfailureanalysis.blogspot.com/2014/09/gear-failure-modes-and-types-analysis.html>
- [46] Y. Lei, F. Jia, J. Lin, S. Xing, and S. Ding. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. In *IEEE Transactions on Industrial Electronics*, volume 63, pages 3137–3147, 2018.
- [47] Time–frequency analysis for bearing fault diagnosis using multiple Q-factor Gabor wavelets. <https://doi.org/10.1016/j.isatra.2018.11.033>
- [48] Barcelos, A.S.; Cardoso, A.J.M. Current-Based Bearing Fault Diagnosis Using Deep Learning Algorithms. *Energies* 2021, 14, 2509. <https://doi.org/10.3390/en14092509>
- [49] Vrba, J.; Cejnek, M.; Steinbach, J.; Krbcova, Z. A Machine Learning Approach for Gearbox System Fault Diagnosis. *Entropy* 2021, 23, 1130. <https://doi.org/10.3390/e23091130>

- [50] Wang, LM., Shao, YM. Crack Fault Classification for Planetary Gearbox Based on Feature Selection Technique and K-means Clustering Method. *Chin. J. Mech. Eng.* 31, 4 (2018). <https://doi.org/10.1186/s10033-018-0202-0>
- [51] L. Wang, Z. Zhang, H. Long, J. Xu and R. Liu, "Wind Turbine Gearbox Failure Identification With Deep Neural Networks," in *IEEE Transactions on Industrial Informatics*, vol. 13, no. 3, pp. 1360-1368, June 2017, doi : 10.1109/TII.2016.2607179.
- [52] Cortes, Corinna and Vapnik, Vladimir, title = Support-Vector Networks, journal = *Machine Learning*, year = 1995, volume = 20, issue = 3, pages = 273–297.
- [53] Bishop, Christopher M., title = *Neural Networks for Pattern Recognition*, journal = Oxford University Press, year = 1995,
- [54] Hosmer, David W. and Lemeshow, Stanley and Sturdivant, Rodney X., title = *Applied Logistic Regression*, publisher = John Wiley Sons, year = 2013, edition = 3rd, isbn = 978-0-470-58247-3,
- [55] Cover, Thomas and Hart, Peter, title = Nearest Neighbor Pattern Classification, journal = *IEEE Transactions on Information Theory*, year = 1967, volume = 13, issue = 1, pages = 21–27, doi = 10.1109/TIT.1967.1053964,
- [56] Breiman, Leo, title = Random Forests, journal = *Machine Learning*, year = 2001, volume = 45, issue = 1, pages = 5–32, doi = 10.1023/A :1010933404324,
- [57] John, George H. and Langley, Pat, title = Estimating Continuous Distributions in Bayesian Classifiers, journal = *Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*, year = 1995, pages = 338–345, url = <http://arxiv.org/abs/1302.4964>,
- [58] P. Cao and J. Tang. University of Connecticut Gear Failure Dataset. Retrieved from <http://mfpt.org/wp-content/uploads/2015/04/UConn-Gear-Fault-Dataset.xlsx>, 2015.
- [59] Girshick, R., et al. Rich feature hierarchies for accurate object detection and semantic segmentation. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014.
- [60] Turaga, S.C., et al., Convolutional networks can learn to generate affinity graphs for image segmentation. *Neural Computation*, 2010. 22(2) : p. 511-38.
- [61] Guo, X., L. Chen, and C. Shen, Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis. *Measurement*, 2016. 93 : p. 490-502.
- [62] Chen, Z., C. Li, and R.-V. Sanchez, Gearbox fault identification and classification with convolutional neural networks. *Shock and Vibration*, 2015. 2015 : p. 1-10.

Annexes

GEARBOX FAULT DIAGNOSIS OPTIMIZATION USING CONVENTIONAL NEURAL NETWORKS AND MACHINE LEARNING METHODS

Miloudi Zakaria¹, Hadjadj Aoul Elias¹, Djemai Mounira¹
¹Electromechanical Systems Laboratory, Department of Electromechanical,
Badji Mokhtar – Annaba University, Annaba, Algeria
E-mail: Za_miloudi@enst.dz

Abstract - Machine condition monitoring is considered an effective approach for performing maintenance in a variety of industries. The gearbox is susceptible to failure under difficult working conditions, so it requires the practice of fault diagnosis. Deep learning has been shown to be efficient in vector assessment and vibration signal analysis. The main advantage of the method is the ability to extract representative information and sensitive features from raw data. However, the application of deep learning in feature extraction for vibration diagnosis is currently restricted, and little research has compared the efficacy of feature learning with different data types. This research aims to develop a convolutional neural network (CNN) with different configurations to learn features directly from the time series data of vibration signals and to evaluate the effectiveness of learning features from raw data. Seven typical machine learning methods are provided as comparisons. The reliability of the proposed approach is validated using UoC gearbox data. The results confirm that the proposed approach can adaptively learn features from time data and achieve higher diagnostic accuracy than comparable traditional techniques.

Keywords: Gearbox, Fault diagnosis, Features extraction, Deep learning, Convolutional neural network, Machine learning.

1. Introduction

Gearboxes are an essential component of mechanical transmission systems and are often found in wind turbines, airplanes, spacecraft, and other mechanical engineering machinery. Gearbox failure will result in unplanned downtime, decreased productivity, and even human tragedy. In order to avoid failures and maintain the proper functioning of mechanical transmission systems, it is thus important to efficiently identify gearbox defects. Due to its long-term continuous use, poor working condition, and other issues, the transmission gearbox is susceptible to damage and loss. Gears are responsible for the majority of gearbox system failures, which has a significant impact on equipment reliability and durability. Consequently, diagnosing gear system defects would boost mechanical system stability and prevent injuries caused by gear system faults. When the gearbox is malfunctioning, the energy transfer and frequency components of the vibration signal are unstable. As a consequence, the extraction of fault-sensitive characteristics such as frequency components and amplitude fluctuations may yield diagnostically useful information. In vibration signal processing, the feature signal of the fault is separated from the vibration signal. Then, the separated signal

is used to figure out what's wrong with the mechanistic device.

Currently, the signal processing technology used for mechanical fault diagnosis is divided into two categories: the standard mathematical processing system supplied by a fast Fourier transform (FFT) and the intelligent diagnostic technology, which is mostly represented by neural networks. Linear stationary mathematical transformation techniques, as well as non-stationary, non-Gaussian distribution, and non-linear random signal processing methods, are the most popular traditional mathematical processing methods. The time domain, frequency domain, and Fourier transform are linear stationary mathematical transformations. Fourier transform analysis, time series model analysis technique, holographic spectrum analysis single, spectrum noise-reducing technique, and matching monitoring analysis are examples of improved spectrum analysis. High-order spectral analysis, main component analysis, short-time Fourier transformation (STFT), distributing Wigner-Ville wavelet transform (WT), cyclic stationary analysis method, random resonance method, empirical mode decomposition (EMD), Hilbert-Huang transform (HHT), and sec-processing methods are non-stationary, non-Gaussian distribution, and non-linear

Conférences

No.	Conférence	Intitulé	Date
1	11th IMA International Conference on Modelling in Industrial Maintenance and Reliability (MIMAR), Online Conference via Zoom	Fault Diagnosis of Gear using Deep Convolutional Neural Network	29 Juin-1 Juillet 2021
2	2nd International Conference on Signals, Machines, and Automation (SIGMA)-2022, Skikda	Gearbox fault Diagnosis Optimization Using Conventional Neural Networks and Machine Learning Methods. (Poster)	23 - 24 octobre 2022
3	Engineering Applications AED	Comparisons of different deep convolutional neural network and machine learning based methods on gearbox fault diagnosis using small dataset (Présentation)	3 December 2022

Base de données

	A	B	C	D	E	F	G	H
1		Peak	RMS	Variance	CF	STD	Skewness	Kurtosiss
2	Healthy	0,15485	0,042003	0,001764	3,686666	0,042001	-0,02733	0,070898
3	Healthy	0,17982	0,043573	0,001899	4,126864	0,043573	-0,04619	0,330652
4	Healthy	0,13868	0,040487	0,001639	3,425323	0,040483	0,014544	-0,15993
5	Healthy	0,16476	0,041951	0,00176	3,927413	0,041949	-0,06781	0,136682
6	Healthy	0,19803	0,042287	0,001788	4,683025	0,042281	-0,08247	0,650838
7	Healthy	0,15865	0,042733	0,001826	3,712548	0,042733	0,009016	0,138004
8	Healthy	0,20903	0,04401	0,001937	4,749565	0,044009	-0,04214	0,518556
9	Healthy	0,15331	0,041985	0,001763	3,651535	0,041984	0,02612	0,154353
10	Healthy	0,14971	0,042073	0,00177	3,558322	0,042071	-0,06076	0,076843
11	Healthy	0,19666	0,043107	0,001858	4,562173	0,043106	-0,09126	0,772891
12	Healthy	0,16427	0,044555	0,001985	3,686864	0,044553	0,007079	-0,03523
13	Healthy	0,18945	0,04547	0,002067	4,166524	0,045464	-0,03952	0,409773
14	Healthy	0,13385	0,042401	0,001798	3,156776	0,042401	-0,02206	0,01574
15	Healthy	0,14969	0,043063	0,001854	3,476037	0,043061	-0,08331	-0,08096
16	Healthy	0,17951	0,043217	0,001867	4,153727	0,043211	-0,07445	0,702716
17	Healthy	0,16882	0,044587	0,001988	3,786302	0,044586	-0,0371	0,078201
18	Healthy	0,18526	0,045237	0,002046	4,095316	0,045231	-0,06501	0,391768
19	Healthy	0,13637	0,042774	0,00183	3,188141	0,042774	-0,0706	0,081906
20	Healthy	0,157	0,04324	0,00187	3,630922	0,043239	-0,07991	0,03751
21	Healthy	0,17811	0,044152	0,001949	4,034023	0,044149	-0,07044	0,73722
22	Healthy	0,17753	0,044755	0,002003	3,96667	0,044755	-0,07168	-0,0033
23	Healthy	0,19518	0,045405	0,002062	4,298602	0,045405	-0,07542	0,553605
24	Healthy	0,14514	0,042456	0,001802	3,41856	0,042455	-0,04923	0,139103
25	Healthy	0,15259	0,04354	0,001896	3,504591	0,043539	-0,08303	-0,04976
26	Healthy	0,18485	0,044203	0,001953	4,181863	0,044196	-0,0696	0,860215
27	Healthy	0,1746	0,044226	0,001956	3,947927	0,044222	-0,03152	-0,00134
28	Healthy	0,19823	0,045428	0,002064	4,363616	0,045428	-0,06263	0,571608
29	Healthy	0,14931	0,043053	0,001853	3,468065	0,043052	-0,00044	0,090348

Description des caractéristiques avec leurs équations

Caractéristique	Description et Équation
Peak (Pic)	Description : La valeur maximale absolue dans un signal. Équation : $Peak = \max(x_1 , x_2 , \dots, x_n)$
RMS (Root Mean Square)	Description : La racine carrée de la moyenne des carrés des valeurs dans un signal. Équation : $RMS = \sqrt{\frac{1}{n}(x_1^2 + x_2^2 + \dots + x_n^2)}$
Variance	Description : Une mesure de dispersion qui indique à quel point les valeurs dans un signal diffèrent les unes des autres. Équation : $Variance = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$, où μ est la moyenne des valeurs du signal.
CF (Centroid Frequency)	Description : La fréquence centrale pondérée par l'amplitude dans un spectre de fréquences. Équation : $CF = \frac{\sum_{k=1}^n f_k X(f_k) }{\sum_{k=1}^n X(f_k) }$, où f_k est la fréquence et $ X(f_k) $ est l'amplitude à la fréquence f_k .
STD (Standard Deviation)	Description : Une mesure de la dispersion des valeurs dans un signal par rapport à leur moyenne. Équation : $STD = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$, où μ est la moyenne des valeurs du signal.
Skewness	Description : Une mesure de l'asymétrie de la distribution des valeurs dans un signal. Équation : $Skewness = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^3}{(\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2)^{3/2}}$, où μ est la moyenne des valeurs du signal.
Kurtosis	Description : Une mesure de la "pointe" ou de l'"aplatissement" de la distribution des valeurs dans un signal. Équation : $Kurtosis = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4}{(\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2)^2}$, où μ est la moyenne des valeurs du signal.