



الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique Et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Saad Dahlab de Blida I
Institut d'Aéronautique et des Etudes Spatiales, IAES

Filière : Aéronautique
Spécialité : Construction Aéronautique
Option : Structure

Mémoire de fin d'études
En vue de l'obtention du diplôme de
Master en Aéronautique

Thème

**Surveillance et Diagnostic des Machines Tournantes par Analyse
Vibratoire Assistée par Intelligence Artificielle**

Dirigé par :
Dr. SARI Elkahina

Réalisé par :
**BENABDELMOULA
Nesrine**

Codirigé par :
Dr. AISSAOUI Abdelkadir
Dr. SEHAB Nadjette

Promotion : 2025 / 2026

ملخص

إن الهدف من مشروع نهاية الدراسة هذا هو تطوير نموذج هجين للتعلم العميق يجمع بين خوارزميتين من خوارزميات الذكاء الاصطناعي، وذلك لتشخيص الأعطال في الآلات الدوّارة باستخدام التحليل الاهتزازي، مع تطبيق ذلك برمجياً بواسطة نظام ماثلاب وقد تم الاعتماد على قاعدة بيانات جامعة "كيس وسترن ريسرف" للحصول على مجموعة الإشارات المستخدمة في عملية تدريب النموذج. وفي هذا السياق، ومن أجل التحقق من صحة نتائجنا الرقمية، تم إعداد منصة اختبار وسلسلة لجمع البيانات داخل مختبر الاهتزازات بمركز البحث والتطوير للقوات الجوية وذلك لتحديد المؤشرات الاهتزازية لعدة عيوب، مثل: تلف المحامل، وأعطال التروس، وعدم المحاذاة، وعدم التوازن. وأظهرت النتائج المحصل عليها أن نموذجنا الهجين الذي يجمع بين الخوارزميتين يتميز بكفاءة عالية جداً في تقديم تشخيص دقيق لأعطال الآلات الدوّارة، وهو ما تم تأكيده والتحقق من صحته من خلال نتائج منصة الاختبار التجريبية

Résumé

L'objectif de ce projet de fin d'études est d'établir un modèle hybride d'apprentissage profond CNN-LSTM pour le diagnostic des défauts dans les machines tournantes en utilisant l'analyse vibratoire avec une implémentation MATLAB. L'ensemble des signaux utilisé pour l'apprentissage a été fourni par la base de données de l'Université de Case Western Reserve (CWRU). Dans ce contexte afin de valider nos résultats numériques, un band d'essai et une chaîne d'acquisition des données ont été réalisés au sein du laboratoire de vibration au centre de recherche de développement militaire (CRD) pour déterminer les paramètres vibratoires de plusieurs défauts comme le défaut de roulement, d'engrenage, désalignement et le déséquilibre. Les résultats obtenus montrent que notre modèle hybride CNN-LSTM est très performant pour faire un bon diagnostic des défauts des machines tournantes qui a été validé par les résultats du band d'essai.

Abstract

The goal of this final project study is to develop a hybrid CNN-LSTM deep learning model for fault diagnosis in rotating machinery using vibration analysis, implemented in MATLAB. The signal dataset used for training was provided by the Case Western Reserve University (CWRU) bearing data center. In this context, to validate our numerical results, a test rig and a data acquisition chain were set up within the vibration laboratory at the Military Research and Development Center (CRD) to determine the vibration parameters of several faults, such as bearing faults, gear faults, misalignment, and unbalance. The results obtained show that our hybrid CNN-LSTM model is highly effective in accurately diagnosing rotating machinery faults, which was successfully validated by the experimental results from the test rig.

Remerciements

Au terme de ce voyage scientifique, mes premiers mots s'élèvent vers Allah Le Tout-Puissant, la lumière originelle qui a guidé mes pas, m'insufflant la clarté d'esprit et la résilience nécessaires pour mener à bien ce projet. Cette œuvre académique est le fruit d'une précieuse dynamique collective et de collaborations intellectuelles.

*J'exprime ma profonde gratitude à mon encadreuse, Madame le Docteur **SARI Elkahina**, enseignante et chercheuse à l'Institut d'Aéronautique et des Études Spatiales de Blida, pour sa rigueur scientifique, sa constante disponibilité et son élégance intellectuelle.*

*À mon co-encadreur, Monsieur **AISSAOUI Abdelkader**, je dois une immense reconnaissance pour sa vision stratégique, ses conseils avisés et son précieux parrainage.*

*Un hommage tout particulier s'adresse à Monsieur **BEKHOUCHE Nessleredine**, qui fut un véritable mentor sur le terrain par son dévouement exceptionnel sa patience remarquable et son soutien quotidien.*

À travers lui, je salue l'ensemble des chercheurs et le personnel du Centre de Recherche et Développement des Forces Aériennes de Dar El Beïda. Ce stage fut une immersion fondatrice où j'ai assimilé les valeurs de discipline, de rigueur et le goût du travail d'excellence.

J'adresse également mes sincères remerciements à Messieurs les membres du jury qui nous font l'honneur d'évaluer ce projet. Je leur suis profondément reconnaissant d'avoir accepté d'examiner notre travail et d'enrichir cette soutenance par leur bienveillance, leur rigueur et leur professionnalisme.

*À la source de toutes mes forces, il y a mes chers parents. Si ce projet arrive à bon port, je le dois à votre soutien indéfectible, vos sacrifices et vos prières. À mes sœurs et à toute la grande famille **Ben Abdelmoula**, merci d'avoir été mon pilier et ma source de motivation.*

Enfin, que mes collègues, amis et complices de l'ombre qui ont partagé un conseil technique ou un mot d'encouragement trouvent ici l'expression de ma profonde estime. Chacun à votre manière, vous avez tracé un morceau de cette trajectoire ; que ce travail soit le reflet de ma gratitude infinie envers ceux qui ont jalonné cette étape essentielle de mon parcours académique.




Table des matières

REMERCIEMENTS

LISTE DES FIGURES

LISTE DES TABLEAUX

LISTE DES SYMBOLES ET DES ABREVIATIONS

INTRODUCTION GENERALE17

Chapitre I: Généralités sur les machines tournantes et la maintenance

I.1 /Introduction.....	20
I.2/Description générale sur les machines tournantes.....	20
I.2.1/Définition des machines tournantes.....	20
I.2.2/ Principaux éléments constitutifs des machines tournantes.....	21
I.2.3/ Classification des machines tournantes.....	22
I.3/ Principe de fonctionnement des machines tournantes.....	23
I.3.1/Principe générale de conversion d'Energie	24
I.3.2/Rendement énergétique d'une machine tournante	24
I.4/ Phénomènes physiques associés au fonctionnement des machines tournantes	26
I.5 /Grandeurs caractéristiques des machines tournantes	30
I.6 /Vibration des machines tournantes.....	30
I.6.1/ La notions de vibration	30
I.6.2/L'importance des vibrations	31
I.6.3/Paramètres de mesure des vibrations.....	31
I.7/ La vibration, outil de surveillance et de maintenance prédictive des machines.....	32
I.7.1/Définition de la maintenance.....	32
I.7.2/ Les stratégies de la maintenance :	33
I.7.3/Type de maintenance	33
I.7.4/Avantage de la maintenance prévisionnelle ou conditionnelle	37
I.7.5/Technique de surveillance par maintenance conditionnelle	37
a/ Notions d'indicateurs.....	37
b/ Les indicateurs principaux ou précoces	38
c/ Les indicateurs secondaires ou tardifs	39
I.7.6/Types d'analyse de l'état de fonctionnement des machines tournantes	39
I.7.7/ Surveillance de l'état de fonctionnement des machines tournantes	42

a/ La détection.....	43
b/ Le diagnostic.....	44
c/Pronostic.....	44
d/Prise de décision	44
I.8/Types de défauts et cause.....	45
a / Le balourd	45
b/Le désalignement	46
c/Défauts d'engrenages	46
d/L'usure	47
e/ Les piqûres	48
f/Ecaillage	48
g/Fissuration.....	49
h/ La corrosion	49
i/La fatigue de contact.....	50
j/Les fissures en fatigue.....	50
k/ Défauts de roulements	51
I.9/Conclusion.....	52
Chapitre II : Technique De Maintenance Pour L'analyse Vibratoire	
II.1/Introduction.....	55
II.2/Outils de maintenance utilisés pour l'analyse vibratoire.....	55
II.3/Activités de l'analyse vibratoire.....	56
II.3.1/La surveillance et analyse temporelle pour l'analyse vibratoire.....	56
a/ Valeur efficace (RMS).....	57
b/ La valeur crête (Crest Value).....	58
c/La Kurtosis (Curtosis).....	61
II.3.2 /Le diagnostic.....	65
a/ Analyse fréquentiel	65
a.1/Spectrogramme.....	66
a.2/Analyse spectrale,FFT.....	66
a.3 /Le spectre PBC.....	67
b/Aalyse temp-fréquence	76
b.1/Transformée de Fourier à court-terme (TFCT ou STFT)	76
II.4/Conclusion.....	77

Chapitre III : Réseaux de Neurones et Algorithmes D'apprentissage

III.1/ Introduction.....	74
III.2/ Notions de base sur l'apprentissage de la machine (Machine Learning).....	74
III.2.1/ Définition	74
III.2.2/ Domaines d'application	75
III.3/ Réseaux de neurones artificiel (ANN).....	76
III.3.1/ Historique.....	76
III.3.2/ Neurone biologique.....	77
III.3.3/ Neurone artificiel	77
III.4 / Fonctions d'activation.....	81
III.4.1/ Rôle des fonctions d'activation.....	81
III.4.2 Types de fonctions d'activation	81
III.5/ Structure d'un réseau de neurones	85
III.6/ Types de réseaux de neurones	86
III.7/Architectures des réseaux de neurones	88
III.8/ Types d'apprentissage d'un réseau de neurones	89
III.9/ Algorithmes d'apprentissage des réseaux de neurones artificiel	91
III.10/ Réseau de neurones convolutionnel (CNN).....	94
III.11/ Algorithm LSTM (Long Short-Term Memory)	96
III.12 / Conclusion.....	97

Chapitre IV: Résultats et Interprétations

VI.1/Introduction	99
VI.2/Partie expérimentale.....	99
VI.2.1/Présentation du banc d'essai.....	99
VI.2.2/ Caracteristiques des défauts.....	101
VI.2.3/Présentation des résultats de l'acquisition	104
VI.2.4/Interprétation	110
VI.3/Partie numérique.....	111
VI.3.1/ Base de données utilisée pour l'apprentissage profond.....	112
VI.3.2/L'algorithme d'apprentissage	114
VI.3.3/Résultats et interpretations.....	115
VI.3.4/Validation	120
VI.4/Conclusion.....	120

CONCLUSION GENERALE	122
ANNEXE 1	127
ANNEXE 2	129
REFERENCES.....	132

Liste des figures

FIGURE I.1: DIFFERENTES APPLICATIONS DES MACHINES TOURNANTES [1].....	21
FIGURE I. 2: SCHEMA D'UNE MACHINE MOTRICE [59].	22
FIGURE I.3: SYMPTOMES DU DESALIGNEMENT D'ARBRE [3]	28
FIGURE I 4: REPARTITION DU CHAMP DE TEMPERATURE DANS UNE MACHINE TOURNANTE [60].	29
FIGURE I. 5: PHENOMENES LIES A LA MECANIQUE DES FLUIDES [58]	29
FIGURE I.6: DIFFERENTS TYPES DE MAINTENANCE [3]	34
FIGURE I.7 : COMPOSANTS DE L'ARCHITECTURE DE SYSTEME DE DETECTION DE DEFAULT. [10].	43
FIGURE I. 8: TYPES DE BALOURD [15].....	46
FIGURE I.9: DEFAULT DE DESALIGNEMENT [3].....	46
FIGURE I.10: LES TYPES D'ENGRENAGES UTILISES DANS L'INDUSTRIE [61]:	47
FIGURE I.11: PHENOMENE DE L'USURE SUR UN SURFACE METALLIQUE [62]	48
FIGURE I.12: EXEMPLE DE DEGRADATION PAR ECAILLAGE SUR DES BAGUES[12].....	49
FIGURE I.13: EXEMPLE DE FISSURATION D'ENGRENAGE [62].....	49
FIGURE I.14: COMPARAISON ENTRE UN ROULEMENT PRESENTANT DES TRACES DE CORROSION ET UN ROULEMENT AVEC PROTECTION CONTRE LA CORROSION [15].....	50
FIGURE I.15: ARRACHEMENT DE PETITS MORCEAUX METALLIQUES SUITE A DES CONTRAINTES REPETEES [62].....	50
FIGURE I.16: ELEMENTS DE ROULEMENT [3].....	51
FIGURE II.1: SCHEMA PRESENTATIF DES ACTIVITES DE L'ANALYSE VIBRATOIRE [14].....	56
FIGURE II.2: TRANSFORMEE DE FOURIER D'UN SIGNAL TEMPOREL EN SIGNAL FREQUENTIEL [3]	66
FIGURE II.3: EXEMPLE TYPIQUE D'UN SPECTRE [3].....	67
FIGURE II.4: ACQUISITION ET ANALYSE DU SIGNAL VIBRATOIRE A L'AIDE D'UN CAPTEUR ET D'UNE APPLICATION MOBILE [3].....	68
FIGURE II.5: PRINCIPE DE LA TRANSFORMEE DE FOURIER A COURT TERME (TFCT) [12].	72
FIGURE III.1: (A) ALGORITHME DE FONCTIONNEMENT DL/ML, (B) PERFORMANCE DES ALGORITHMES DL PAR RAPPORT AUX ANCIENS ALGORITHMES EN FONCTION DE LA QUANTITE DE DONNEES [3].....	75
FIGURE III.2: LES MODELES DE NEURONES BIOLOGIQUES [63].	78
FIGURE III.3: REPRESENTATION D'UN NEURONE ARTIFICIEL [49]	79

FIGURE III.4: MISE EN CORRESPONDANCE NEURONE BIOLOGIQUE / NEURONE ARTIFICIEL [49].	80
FIGURE III.5: FONCTION SEUIL [48].....	82
FIGURE III.6: FONCTION SIGMOÏDE [48].	82
FIGURE III.7: FONCTION SATURATION [48].....	83
FIGURE III.8: FONCTION GAUSSIENNE CENTREE [48].....	83
FIGURE III.9: FONCTION RELU [48].....	84
FIGURE III.10: FONCTION SOFTMAX [48].....	85
FIGURE III.11: STRUCTURE D'UN RESEAU DE NEURONES [36].	85
FIGURE III.12: LE RESEAU MONOCOUCHE [3].	87
FIGURE III.13: RESEAUX DE NEURONES MULTICOUCHEES [36].....	87
FIGURE III.14: RESEAU NON BOUCLE A CONNEXIONS TOTALES ; A CONNEXION PARTIELLE [36]	88
FIGURE III.15: STRUCTURE D'UN RESEAU DE NEURONES BOUCLEES [36].	89
FIGURE III.16: PROCESSUS DE L'APPRENTISSAGE AUTOMATIQUE. [3]	89
FIGURE III.17: TYPES D'APPRENTISSAGE AUTOMATIQUE [3]	90
FIGURE III.18: APPRENTISSAGE SUPERVISE [36].....	90
FIGURE III.19: APPRENTISSAGE NON SUPERVISE [36].	91
FIGURE III.20: (1) PROPAGATION (2) RETRO PROPAGATION [34]	93
FIGURE III.21: SCHEMA SYNOPTIQUE DE LA METHODE UTILISEE [3].....	94
FIGURE III.22: CALCUL CONVOLUTIONNELS [3].	95
FIGURE III.23: PORTES LSTM POUR CHAQUE PAS DU TEMPS [58].	97
FIGURE IV.1: BOITE DE VITESSE DE BANC D'ESSAI.....	100
FIGURE IV.2: BANC D'ESSAI	100
FIGURE IV.3: A) ACCELEROMETRE, B) TACHYMETRE, C) CARTE D'ACQUISITION	101
FIGURE IV.4: ROULEMENT UTILISE POUR LES ESSAIS DE TYPE SKF EXPLORER 6305/2Z/C3	102
FIGURE IV.5: LE ROULEMENT DEFECTUEUX	103
FIGURE IV.6: LES ENGRENAGES DU BANC D'ESSAI.....	103
FIGURE IV.7: LE DEFAUT DE DESALIGNEMENT DU BANC D'ESSAI	104
FIGURE IV.8: SIGNAL TEMPOREL POUR LE CAS SANS DEFAUT	105
FIGURE IV.9: SPECTRE DE FREQUECES POUR LE CAS SANS DEFAUT.....	106
FIGURE IV.10: SIGNAL TEMPOREL POUR LE DEFAUT DE ROULEMENT.....	106
FIGURE IV.11: SPECTRE DES FREQUENCES POUR LE DEFAUT DE ROULEMENT	107
FIGURE IV.12: SIGNAL TEMPOREL POUR LE DEFAUT D'ENGRENAGE	108
FIGURE IV.13: SPECTRE DES FREQUENCES POUR LE DEFAUT D'ENGRENAGE.....	108
FIGURE IV.14: SIGNAL TEMPOREL POUR UN LE DEFAUT DE DESALIGNEMENT	109

FIGURE VI.15: SPECTRE DES FREQUENCES POUR LE DEFAUT DE DESALIGNEMENT	110
FIGURE IV.16: LES DIFFERENTES CLASSES DE BASES DE DONNEES	113
FIGURE IV.17: LES DIFFERENTES SOUS-CLASSES DES BASES DE DONNEES	113
FIGURE IV.18: ARCHITECTURE DU RESEAU 1D CNN/LSTM [55]	114
FIGURE IV.19: ORGANIGRAMME DU PROCESSUS DE DIAGNOSTIC DES DEFAUTS [55]	115
FIGURE IV.20: L'ARCHITECTURE HYBRIDE CNN–LSTM POUR CLASSIFICATION DES DEFAUTS..	116
FIGURE IV.21: LA MATRICE DE CONFUSION	118
FIGURE IV.22: LES COURBES D'APPRENTISSAGE.....	119

Liste des tableaux

Tableau II.1: Correspondance entre les types de défauts et les méthodes de détection	55
Tableau II.2: Interprétation du facteur de crête.	59
Tableau II.3 : Evolution du facteur de crête dans le temps	60
Tableau II.4: Signification statistique du Kurtosis	62
Tableau II.5: Récapitulatif de reconnaissance des principales anomalies.....	72
Tableau IV.1: Caracteristiques des roulements d'essais.....	102
Tableau IV.2: Caracteristiques des engrennages d'essai	104
Tableau IV.3: Caracteristiques de l'aquisition.....	105
Tableau IV.4 : Caracteristiques du signal temporel pour le défaut de roulement	107
Tableau IV.5: Caracteristiques du signal temporel pour le défaut d'engrenage	109
Tableau IV.6 : Caracteristiques du signal temporel pour le défaut de désalignement	110
Tableau IV.7: Les differentes classes du base de données	112
Tableau IV.8: Nombre de sigaux pour les differentes classes.....	113

Liste des abréviations

BPFO:	Ball Pass Frequency Outer Race (Fréquence de passage d'une bille sur un défaut de bague externe).
BPFI:	Ball Pass Frequency Inner Race (Fréquence de passage d'une bille sur un défaut de bague interne).
BSF:	Ball Spin Frequency (Fréquence de passage de bille sur la bague interne ou externe).
BF:	Basse fréquence.
CRD:	Centre de recherche et de développement.
CWRU:	Université de Case Western Reserve.
CWT:	Transformée en Ondelettes Continues.
CNN:	Réseau de Neurones Convolutifs.
DL:	Apprentissage profond.
EMD:	Décomposition Modale Empirique.
FFT:	Transformée de Fourier rapide.
FL:	Couche entièrement connectée.
FT:	Transformée de Fourier.
FTF:	Fundamental 1 Train Frequency (Fréquence de passage d'un défaut de cage).
HF:	Haute fréquence.
HHT:	Transformée d'Hilbert-Huang.
HI:	Hoyer index.
IA:	Intelligence artificielle.
IGI:	Improved Gini Index.
IMF:	Fonction en Mode Intrinsèque.
KNN:	Les K plus Proches Voisins.
LSTM:	Long Short-Term Memory.
LASPI:	Laboratoire d'Analyse des Signaux et des Processus Industriels.
ML:	Apprentissage automatique.
MNN:	Réseau Neuronal de Taille Moyenne.
MPC:	Maintenance Préventive Conditionnelle.

MF:	Moyenne fréquence.
NG:	Niveau global.
PBC:	Pourcentage de bande constant.
RMS:	Carré de la moyenne quadratique.
RPM:	Tours par minute.
RUL:	Durée de vie utile restante.
RC:	Résolution constante.
STFT:	Short-Time Fourier Transform (la transformée de Fourier à court termes).
SBS:	Sélection séquentielle en arrière.
STFT:	Transformée de Fourier à court terme.
SVM:	Machines à vecteurs de support.
TFA:	Analyse temps-fréquence.
TNN:	Réseau Neuronal à Trois Couches.
TFD:	La transformée de Fourier discrète.
TF:	Transformée de Fourier.
VIS:	Vital, Important, Secondaire.

Liste des symboles

Ac :	L'amplitude crête.
Acc :	L'amplitude crête à crête.
Aeff :	L'amplitude efficace.
Aeff:	Accélération efficace.
B :	La largeur de la bande d'analyse [0 - f max].
C :	Charge dynamique de base.
Dcc :	Déplacement crête-crête(μm).
FC :	Facteur de crête.
fr :	La fréquence de rotation.
Fc :	Fréquence de la courroie.
Fe :	La fréquence d'engrènement.
Faubes :	La fréquence de passage des aubes.
Fg :	La fréquence de glissement du moteur.
fa :	Fréquence du courant d'alimentation.
Fenc :	La fréquence d'encoche.
g :	Accélération due à la pesanteur ($9,81 \text{ m/s}^2$).
L10 :	Durée de vie nominale atteinte par 90% des roulements essayés dans les mêmes conditions (norme I.S.O. 281).
N :	Vitesse de rotation(tr/min).
nenc :	Nombre d'encoches du moteur surveillé.
Nf :	Le nombre de lignes fréquentielles d'analyse.
Nchamp :	Vitesse du champ tournant du moteur.
P :	Charge dynamique équivalente.
T :	Durée d'analyse du signal.
Vcc :	Valeur efficace de la vitesse.
x(t):	Amplitude instantanée.
Z :	Nombre de dents de l'engrenage.
β :	Angle de contact du roulement.

- ω : Vitesse angulaire ou pulsation du mouvement.
- φ : Phase du mouvement par rapport à un repère dans le temps.
- τ : Fréquence qui a la dimension d'un temps.
- f : La résolution d'analyse.

Introduction Générale

INTRODUCTION GENERALE

Dans de nombreux secteurs industriels, les machines tournantes jouent un rôle fondamental, participant activement au bon fonctionnement des systèmes complexes qui soutiennent la production et les opérations. Ces machines, qu'il s'agisse de turbines, de moteurs électriques, de compresseurs ou d'autres équipements similaires, sont des éléments essentiels de l'infrastructure industrielle moderne. Leur bon état de fonctionnement est crucial pour maintenir la productivité, réduire les temps d'arrêt et garantir la rentabilité des opérations.

Cependant, la fiabilité de ces machines est constamment menacée par le risque de défauts. Ces défauts peuvent se manifester de manière subtile, se développant progressivement jusqu'à devenir des problèmes majeurs entraînant des pannes coûteuses et des interruptions non planifiées. La détection précoce de ces anomalies est donc d'une importance vitale pour la maintenance efficace des machines tournantes.

C'est là que le diagnostic des défauts entre en jeu. Cette approche, basée sur une analyse méticuleuse des données provenant de diverses sources telles que les vibrations et les signaux électriques, permet d'identifier les signes avant-coureurs de défaillance. En surveillant en permanence ces données, il est possible d'anticiper les problèmes potentiels, de planifier les interventions de maintenance de manière proactive et d'éviter les interruptions imprévues de la production.

Avec l'avènement des technologies de pointe telles que l'intelligence artificielle (IA) et l'apprentissage automatique, le diagnostic des défauts dans les machines tournantes a atteint de nouveaux sommets.

Ces technologies permettent une analyse plus approfondie des données et une détection plus précise des anomalies, même dans des conditions où les signaux sont faibles ou complexes. En combinant ces avancées technologiques avec l'expertise humaine, il est possible de développer des systèmes de diagnostic encore plus fiables et efficaces.

Ce travail vise donc à explorer et à présenter le modèle d'IA pour le diagnostic des défauts dans les machines tournantes, dans le but d'améliorer la maintenance préventive et de garantir une exploitation optimale de ces équipements.

En adoptant une approche intégrée, nous examinerons les différentes facettes de la détection des défauts, en mettant l'accent sur la pertinence, la précision et la fiabilité.

L'objectif ultime est de fournir aux professionnels de la maintenance des outils efficaces pour anticiper et remédier aux dégradations potentielles, assurant ainsi une production continue et fiable. En identifiant les meilleures pratiques en matière de surveillance et de diagnostic des machines tournantes, nous visons à contribuer à l'amélioration des performances opérationnelles et à la réduction des coûts de maintenance dans un large éventail d'industrie.

Alors, pour traiter le sujet nous divisons ce mémoire en cinq chapitres :

- Le premier chapitre est consacré à la recherche bibliographique sur les machines tournantes, la politique de la maintenance industrielle et son application dans le domaine de l'industrie ;
- Dans le deuxième chapitre, les techniques et les outils de surveillance et diagnostiques utilisés pour l'analyse vibratoire en maintenance conditionnelle sont présentés ;
- Le troisième chapitre est conçu sur les réseaux neurones, ses types avec leurs applications et même aussi les types d'apprentissages et les algorithmes de calcul ;
- Le quatrième chapitre traite l'ensemble des résultats numériques et expérimentaux et ses interprétations. Le dispositif expérimental conçoit un band d'essai et une chaîne d'acquisition de données pour déterminer les paramètres des signaux vibratoires pour un plusieurs catégories de défauts tel que : les défauts de roulement, d'engrenage et le désalignement. La partie numérique comprend une classification des défauts par l'intelligence artificielle en utilisant l'algorithme de l'apprentissage profond hybride (CNN-LSTM) ainsi qu'une validation des résultats d'apprentissage par les résultats du band d'essais. Les résultats de l'acquisition expérimentale et l'apprentissage profond sont obtenus grâce à une implémentation Matlab.

Et enfin nous terminons ce projet par une conclusion générale et des perspectives.

Généralités sur les machines tournantes et la maintenance

I.1/ Introduction

Dans le monde industriel, les machines tournantes occupent une place essentielle dans de nombreux processus de production. Elles interviennent dans des domaines variés tels que la production d'énergie, le pompage des fluides, la ventilation, le transport de gaz ou encore les systèmes de propulsion. Leur présence est indispensable au bon fonctionnement des installations industrielles, car elles assurent la transformation et la transmission de l'énergie nécessaire au fonctionnement des systèmes [1].

Dans le domaine aéronautique, les machines tournantes jouent également un rôle fondamental. Elles sont présentes dans les moteurs d'avions, les systèmes de génération électrique, les pompes hydrauliques, les compresseurs, ainsi que dans les systèmes de ventilation et de conditionnement d'air. Les turbomachines aéronautiques, telles que les compresseurs et les turbines des turboréacteurs, fonctionnent à des vitesses de rotation très élevées et nécessitent une conception et un contrôle particulièrement rigoureux afin d'assurer la sécurité et la fiabilité des aéronefs.

Les machines tournantes telles que les moteurs électriques, les générateurs et les pompes hydrauliques sont donc largement utilisées dans les secteurs industriel et aéronautique en raison de leur efficacité et de leur capacité à fonctionner en continu. Toutefois, ces machines sont souvent soumises à des conditions de fonctionnement sévères, notamment des charges mécaniques, des variations thermiques importantes et des contraintes dynamiques, ce qui peut influencer leur performance au cours du temps [2] [3].

I.2/Description générale sur les machines tournantes

I.2.1/Définition des machines tournantes

Une machine tournante est un ensemble mécanique constitué d'une structure fixe reliée par une liaison pivot à un élément mobile en rotation. Le mouvement de rotation constitue le principe fondamental de fonctionnement de ce type de machine, permettant la conversion ou la transmission de l'énergie. D'une manière générale, une machine tournante comprend :

- Une partie fixe, appelée stator ou bâti, assurant le support et la rigidité de l'ensemble ;
- Une liaison pivot, généralement réalisée à l'aide de paliers ou de roulements permettant la rotation ;

- Une partie mobile, appelée rotor, constituée principalement d'un arbre et d'un organe tournant.

Dans le secteur aéronautique, ces éléments doivent répondre à des exigences très strictes en termes de masse, de résistance mécanique, d'équilibrage et de fiabilité, en raison des conditions extrêmes de fonctionnement et des impératifs de sécurité [4].



Figure I.1: Différentes applications des machines tournantes [1].

I.2.2/ Principaux éléments constitutifs des machines tournantes

Une machine tournante est constituée d'un ensemble d'éléments mécaniques assurant la transformation et la transmission de l'énergie par un mouvement de rotation. Les principaux composants sont les suivants :

- Le rotor : partie mobile de la machine, animée d'un mouvement de rotation autour de son axe. Il constitue l'élément principal de conversion ou de transmission de l'énergie.
- Le stator : partie fixe entourant le rotor, assurant le guidage, le support mécanique et parfois la création d'un champ magnétique ou d'un écoulement dirigé.
- L'arbre : élément mécanique permettant la transmission du couple et de la puissance entre les différents composants de la machine.
- Les paliers ou roulements : organes de liaison assurant le guidage en rotation de l'arbre tout en réduisant les frottements et en supportant les charges radiales et axiales.
- Le carter : structure externe assurant la protection des éléments internes et la rigidité mécanique de l'ensemble.

Ces éléments constituent la base de fonctionnement de la majorité des machines tournantes

utilisées dans les domaines industriel et aéronautique [5].

I.2.3/ Classification des machines tournantes

Les machines tournantes peuvent être classées selon leur fonction principale et le type d'énergie échangée.

A / Classification des machines tournantes selon leur fonction

A.1/Machines motrices

Les machines motrices transforment l'énergie d'un fluide (hydraulique, thermique ou gazeux) en énergie mécanique de rotation. Le fluide cède une partie de son énergie au rotor, générant ainsi un couple mécanique. Parmi les principales machines motrices, on distingue :

- Les turbines hydrauliques,
- Les turbines à vapeur,
- Les turbines à gaz.

Ces machines sont largement utilisées dans les centrales de production d'énergie ainsi que dans les moteurs aéronautiques, où les turbines permettent d'entraîner les compresseurs et les accessoires du moteur [6].




Figure I.2 : Schéma d'une machine motrice transformant l'énergie électrique en énergie mécanique [59].

A.2/ Machines réceptrices

Les machines réceptrices utilisent une énergie mécanique fournie par un moteur afin d'agir sur un fluide en augmentant sa pression, sa vitesse ou son débit. L'énergie mécanique est ainsi convertie en énergie hydraulique ou pneumatique.

Les exemples les plus courants sont : Les pompes, Les compresseurs, Les ventilateurs.

Dans le domaine aéronautique, ces machines sont utilisées notamment dans les systèmes

hydrauliques, les circuits carburants et les systèmes de conditionnement d'air.

A.3/Machines électriques tournantes

Les machines électriques tournantes assurent la conversion entre énergie électrique et énergie mécanique. Elles peuvent fonctionner soit en moteur, soit en générateur.

On distingue principalement : Les moteurs électriques, Les générateurs ou alternateurs.

Selon la direction dans les aéronefs, les alternateurs permettent la production d'énergie électrique nécessaire aux systèmes de bord, tandis que les moteurs électriques entraînent certains équipements auxiliaires [7].

B/ Classification selon le type d'écoulement

Selon l'écoulement du fluide à travers la machine, on distingue :

- Les machines axiales, dans lesquelles le fluide s'écoule parallèlement à l'axe de rotation (Exemple : compresseurs axiaux des turboréacteurs).
- Les machines radiales, où l'écoulement est perpendiculaire à l'axe de rotation (exemple : Pompes centrifuges).
- Les machines mixtes, combinant les deux types d'écoulement.

Cette classification est particulièrement importante dans la conception des turbomachines aéronautiques [6].

I.3/ Principe de fonctionnement des machines tournantes

I.3.1/Principe générale de conversion d'Energie

Une machine tournante assure toujours une transformation énergétique selon le schéma :

Énergie d'entrée → Conversion → Énergie mécanique de rotation

Selon le type de machine, l'énergie d'entrée peut être :

- Electrique
- Thermique
- Hydraulique
- Pneumatique

Les machines tournantes constituent un ensemble d'équipements industriels dont le fonctionnement repose sur la transformation d'énergie par l'intermédiaire d'un mouvement de

rotation continu. Elles assurent la conversion d'énergie électrique, mécanique, hydraulique ou thermique en une autre forme d'énergie exploitable. Leur rôle est fondamental dans les systèmes de production, de transport et de transformation d'énergie [8] [9].

I.3.2/Rendement énergétique d'une machine tournante

Le rendement énergétique d'une machine tournante est définie comme le rapport entre le travail fourni et le travail utile. Un rendement élevé traduit une conversion efficace de l'énergie avec des pertes minimales. L'amélioration du rendement constitue un objectif majeur dans la conception et la maintenance des machines tournante [10]

I.3.3/ Exemples de machines tournantes

A/ Principe de fonctionnement d'un moteur électrique

Les machines électriques tournantes sont basées sur les lois fondamentales de l'électromagnétisme, notamment la loi de Faraday, la loi de Lenz et la loi de Lorentz.

Dans un moteur électrique, l'énergie électrique est convertie en énergie mécanique.

Le principe peut être illustré par le cas du Moteur asynchrone, largement utilisé dans l'industrie. Lorsque le stator est alimenté par un courant triphasé, il crée un champ magnétique tournant à la vitesse synchrone donnée par :

$$N_s = \frac{60 f}{p} \quad (I.1)$$

Où :

N_s : vitesse de synchronisme ;

f : est la fréquence d'alimentation (Hz)

p : est le nombre de paires de pôles.

Ce champ magnétique variable induit des courants dans le rotor (principe d'induction). L'interaction entre le champ magnétique statorique et les courants induits dans le Rotor produit une force électromagnétique qui génère un couple moteur. Le rotor tourne à une vitesse légèrement inférieure à la vitesse synchrone, cette différence relative est appelée glissement [11]

Le couple électromagnétique est proportionnel au flux magnétique et au courant rotorique. La dynamique de rotation est décrite par l'équation fondamentale de la mécanique :

$$C = J \frac{dW}{dt} \quad (I.2)$$

Où :

C : C'est le couple moteur (N.m)

J : est le moment d'inertie (kg m²)

W : est la vitesse angulaire (rad/s)

Dans le cas d'un Alternateur, la conversion est inverse l'énergie mécanique est transformée en énergie électrique.

Une turbine entraîne le rotor, créant une variation de magnétique à travers les enroulements du stator Selon la loi de Faraday, cette variation de flux induit une force électromotrice tel que :

$$e = \frac{d\Phi}{dt} \quad (I.3)$$

Où

e : Force électromotrice

Φ : Flux magnétique

La tension produite dépend de la vitesse de rotation, du nombre de spires et de l'intensité du champ magnétique. L'alternateur est ainsi l'élément central de la production d'énergie dans les centrales électriques

B/ Principe de fonctionnement d'une machines hydrauliques

Les machines hydrauliques fonctionnent sur la base des lois de la mécanique des fluides, notamment l'équation de Bernoulli et la théorie d'Euler des turbomachines.

B.1/Fonctionnement d'une pompe

Dans une Pompe centrifuge, l'énergie mécanique fournie par un moteur entraîne une roue à aubes appelée impulseur. La rotation provoque une accélération radiale du fluide sous l'effet de la force centrifuge.

Le fluide est aspiré au centre (zone de basse pression) puis refoulé vers la périphérie avec une augmentation de vitesse et de pressions. L'énergie mécanique est donc transformée en énergie hydraulique (Energie cinétique + Energie de pression).

L'équation fondamentale d'Euler pour les turbomachines s'écrit :

$$E = U_2 V_{u2} - U_1 V_{u1} \quad (I.4)$$

Ou:

E : Travail spécifique échangé.

U : est la vitesse périphérique à l'entrée et à la sortie ;

V_u : est la composante tangentielle de la vitesse absolue du fluide.

B.2/ Fonctionnement d'une turbine

Dans une Turbine hydraulique, le fluide en mouvement transmet son énergie aux aubes du rotor. La variation de quantité de mouvement du fluide engendre un couple mécanique qui met l'arbre en rotation.

La turbine convertit ainsi l'énergie hydraulique ou thermique en énergie mécanique, généralement utilisée pour entraîner un alternateur.

I.4/ Phénomènes physiques associés au fonctionnement des machines tournantes

Le fonctionnement des machines tournantes met en jeu un ensemble complexe de phénomènes physiques interdépendants relevant de l'électromagnétisme, de la mécanique, de la dynamique des structures et de la mécanique des fluides. La compréhension approfondie de ces phénomènes est essentielle pour analyser les performances, anticiper les défaillances et optimiser la maintenance.

A /Phénomènes électromagnétiques

Dans les machines électriques tournantes telles que le Moteur asynchrone ou l'Alternateur, la conversion d'énergie repose sur l'interaction entre champ magnétique et courant électrique. Lorsque les enroulements statoriques sont alimentés, ils génèrent un champ magnétique tournant. Ce champ traverse le rotor et induit des courants (dans le cas d'un moteur asynchrone). L'interaction entre le champ magnétique $\vec{B}$ et le courant I produit une force électromagnétique F le long du conducteur $\vec{L}$ donnée par la loi de Lorentz :

$$F = I \vec{L} \times \vec{B} \quad (I.5)$$

Cette force crée un couple électromagnétique responsable de la rotation. Les principaux phénomènes électromagnétiques associés sont :

- Induction électromagnétique
- Réaction magnétique du rotor
- Saturation du circuit magnétique
- Pertes par hystérésis
- Pertes par courants de Foucault

Ces phénomènes influencent directement le rendement, l'échauffement et la stabilité du couple.

B/ Phénomènes mécaniques et dynamiques

Le rotor d'une machine tournante est soumis à des contraintes mécaniques importantes dues à la rotation telles que :

1/ Effet d'inertie

Toute variation de vitesse angulaire implique un couple dynamique donné par la l'équation (I.2), plus l'inertie est élevée, plus la machine résiste aux variations rapides de vitesse.

2/ Forces centrifuges

La rotation engendre une force centrifuge F_c qui est donnée par la formule ci-dessous :

$$F_c = m r w^2 \quad (I.6)$$

Où :

m : est la masse ;

r : le rayon ;

w : la vitesse angulaire.

Ces forces provoquent des contraintes radiales pouvant entraîner des déformations, particulièrement à grande vitesse.

3/ Déséquilibre dynamique

Un défaut de répartition de masse crée un balourd générant des vibrations proportionnelles au carré de la vitesse. Ce phénomène est l'une des causes majeures de défaillance des roulements et des paliers [12].

C/ Phénomènes vibratoires

Les machines tournantes sont des systèmes dynamiques susceptibles d'entrer en vibration sous l'effet de forces internes ou externes. On distingue :

- Vibrations dues au balourd ;
- Vibrations dues au désalignement ;
- Vibrations liées aux défauts de roulements ;
- Vibrations d'origine électromagnétique.

Un phénomène critique est la résonance, qui se produit lorsque la fréquence d'excitation coïncide avec la fréquence propre du système. À cette condition, l'amplitude vibratoire augmente fortement, pouvant conduire à une rupture mécanique [13].




Figure I.3: Symptômes du désalignement d'arbre dans les machines tournantes [3]

D/ Phénomènes thermiques

Les pertes énergétiques se transforment en chaleur, provoquant une élévation de température.

Les sources principales d'échauffement sont :

- Effet Joule dans les enroulements ;
- Frottement dans les roulements ;
- Pertes magnétiques ;
- Pertes hydrauliques.

L'équilibre thermique dépend de la capacité de dissipation de la machine (ventilation, refroidissement). Une température excessive accélère le vieillissement des isolants électriques et des lubrifiants, réduisant ainsi la durée de vie de l'équipement.




Figure I.4 : Répartition du champ de température dans une machine tournante [60]

E /Phénomènes liés à la mécanique des fluides

Dans les machines hydrauliques comme la Pompe centrifuge ou la Turbine hydraulique, plusieurs phénomènes hydrodynamiques interviennent :

- Variation de pression et de vitesse du fluide ;
- Turbulence ;
- Pertes de charge ;
- Cavitation.

La cavitation apparaît lorsque la pression locale du fluide devient inférieure à sa pression de vapeur. Elle provoque la formation de bulles qui implosent en générant des chocs microscopiques, responsables d'érosion des aubes et de vibrations importantes.




Figure I.5 : Phénomènes liés à la mécanique des fluides [60]

F/Phénomènes de frottement et de lubrification

Les contacts mécaniques au niveau des paliers et des roulements génèrent des frottements.

Le régime de lubrification peut être :

- Hydrodynamique ;
- Élastohydrodynamique ;
- Limité.

Une lubrification insuffisante entraine une augmentation de la température, une usure prématurée et un risque de grippage [14].

I.5 /Grandeurs caractéristiques des machines tournantes

Le fonctionnement des machines tournantes est caractérisé par plusieurs grandeurs physiques permettant d'évaluer leurs performances :

- La vitesse de rotation (tr/min) ;
- Le couple mécanique ;
- La puissance transmise ;
- Le rendement énergétique ;
- Le débit du fluide ;
- La pression générée ou absorbée.

L'analyse de ces paramètres permet de caractériser le comportement de la machine et d'optimiser son fonctionnement dans les conditions d'exploitation [16].

I.6 /Vibration des machines tournantes**1.6.1/ La notions de vibration**

Une vibration est le mouvement oscillatoire d'un système mécanique autour d'une référence dans une période du temps. Le nombre de cycles complets du mouvement dans une période de temps d'une seconde est appelé fréquence et leur unité hertz (Hz).

Dans la pratique, Les signaux vibratoires sont composés d'une grande quantité de fréquences apparaissant en même temps au point que l'on ne peut pas juger directement au vu de la caractéristique amplitude-temps du nombre d'éléments synchroniques et à quelle fréquence elles se génèrent. Ces éléments peuvent être mis en évidence par la représentation graphique de la caractéristique des vibrations amplitude-fréquence, une technique probablement considérée Comme base du diagnostic de mesures des vibrations [13].

Les forces générées par les différents éléments internes du système en mouvement appelés phénomènes vibratoires, ce sont des phénomènes périodiques ou apériodiques plus ou moins complexes. Les forces générées sont présentées et résumées ci-dessous :

- Forces impulsionnelles (chocs) ;
- Forces transitoires (variations de charge) ;
- Forces périodiques (balourd) ;
- Forces aléatoires (frottements) [15].

I.6.2/L'importance des vibrations

L'importance des vibrations se présente par :

- Un indicateur de l'état de santé de la machine
- Un moyen de détection précoce des défauts
- Un outil essentiel en maintenance prédictive

Une augmentation anormale des vibrations peut provoquer :

- Usure accélérée des roulements
- Fissures des arbres
- Desserrage des fixations
- Dégradation des fondations
- Arrêt non planifié [4].

I.6.3/Paramètres de mesure des vibrations

Les vibrations sont caractérisées par :

a / Le déplacement

- Mesure le mouvement total.
- Utilisé pour basses fréquences.

b /La vitesse vibratoire

- Paramètre le plus utilisé en industrie.
- Bon indicateur de la sévérité globale.

c/ L'accélération

- Utilisée pour détecter les défauts de roulements.
- Sensible aux hautes fréquences [17]

I.7/ La vibration, outil de surveillance et de maintenance prédictive des machines

Toute machine comporte des pièces en mouvement qui exercent des efforts sur sa structure et engendrent des déformations. Ces déformations et ces efforts, varient au rythme du mouvement et se traduisent par des déplacements de la surface de la structure par rapport à elle-même d'où l'apparition de vibrations [3]

La vibration n'est pas directement l'image mais le résultat de l'effort sur la structure. Elle est fonction de l'effort et de la structure et peut être caractérisée indifféremment par l'un des paramètres suivants : le déplacement ; la vitesse et l'accélération.

Le capteur utilisé est l'accéléromètre qui délivre un signal directement proportionnel à l'accélération mais par traitement il est facile de remonter à la vitesse et au déplacement. Certains appareils de mesure permettent de suivre l'un ou l'autre de ces paramètres.

Si nous examinons un spectre type prélevé sur un déchiqueteur de papiers d'une usine de production de produits d'hygiène, nous constatons qu'en vitesse il est relativement homogène, c'est-à-dire, que les diverses raies ont des amplitudes du même ordre dans tous les domaines de fréquence [7].

Par contre, par suite du filtrage associé à l'intégration (passe - bas) ou à la dérivation (passe - haut), nous constatons que les basses fréquences sont favorisées en déplacement et les hautes fréquences en accélération. Suivant la nature du phénomène à observer (plage de fréquences) on utilisera le paramètre la mettant le mieux en évidence. Nous pouvons considérer trois domaines de fréquences :

- $f < 100$ ou 200 Hz pour le déplacement ;
- $f < 1000$ ou 2000 Hz pour la vitesse ;
- $f > 1000$ ou 2000 Hz pour l'accélération.

I.7.1/Définition de la maintenance

La maintenance est l'ensemble des actions entreprises pour maintenir ou rétablir un équipement, un système ou un bien en bon état de fonctionnement.

Elle vise à assurer la disponibilité opérationnelle, la fiabilité et la durée de vie optimale des équipements, en prévenant les défaillances ou en réparant rapidement celles qui surviennent.

La maintenance est essentielle dans divers secteurs tels que l'industrie, les services publics, le transport, et elle peut être réalisée à différents niveaux, en fonction des besoins et des objectifs spécifiques de l'organisation [1].

La maintenance a pour but de :

- garantir la disponibilité du bien.
- augmenter sa durée de vie,
- diminuer la probabilité des pannes et donc d'actions de maintenance corrective.
- contrôler les consommations d'énergie ou de pièces détachées en contribuant à la maîtrise des stocks [1].

I.7.2/ Les stratégies de la maintenance :

Jusqu'à ces dernières années, l'entretien des machines et le remplacement des pièces soumises à usure, pouvaient être envisagés uniquement de deux manières :

- L'attente de la casse (Maintenance Corrective)
- Le remplacement à intervalles réguliers (Maintenance Systématique).

Le contrôle préventif conditionnel par l'analyse vibratoire cible la connaissance de l'état réel de la machine à tout moment, prévient suffisamment tôt de l'apparition d'un défaut et permet de suivre son évolution pour gérer la maintenance.

On distingue trois stratégies de maintenance préventive :

- la maintenance préventive systématique,
- la maintenance préventive conditionnelle,
- la maintenance prévisionnelle [18].

I.7. 3/Type de maintenance

La classification des types de la maintenance est une question essentielle pour les entreprises, car elle détermine les stratégies à adopter pour assurer le bon fonctionnement et la durabilité de leurs actifs.

Traditionnellement, la maintenance est divisée en plusieurs catégories principales : préventive, corrective, prédictive et proactive, etc.

Chacune de ces classifications présentes des avantages et des inconvénients, et leur utilisation dépend souvent du type d'équipement [19], des objectifs de l'entreprise et de son budget alloué à la maintenance. Deux grandes familles seront discutées par la suite: La maintenance corrective et la maintenance préventive. La figure I.6 représente un schéma détaillé :




Figure I.6 : Différents types de maintenance [3]

A /Maintenance corrective

La maintenance corrective correspond à une opération engagée suite à une panne, un sinistre ou un aléa. Elle a pour objectif de remettre en fonctionnement les machines par un dépannage, une réparation ou le remplacement de pièces défectueuses [3].

On distingue deux types de maintenance corrective : la maintenance palliative et la maintenance curative [12].

A.1/Maintenance palliative

La maintenance palliative correspondante au dépannage. Elle consiste à remettre provisoirement une machine ou un outil en état, dans l'attente de sa réparation. La maintenance palliative permet d'éviter l'arrêt totale de production, on parle alors de reprise de production en mode « dégradé » [3].

Le dépannage est défini par l'ensemble des actions physiques exécutées pour permettre à un bien d'accomplir sa fonction requise pendant une durée limitée jusqu'à ce que la réparation soit exécutée [19]

A.2/ Maintenance curative

La maintenance curative répare les causes et conséquences de la panne. Contrairement à la maintenance palliative, il s'agit d'une action en profondeur qui agit sur le long terme, souvent en remplaçant la pièce défectueuse par une neuve. L'équipement reprend alors une production normale. La réparation est l'ensemble des actions physiques exécutées pour rétablir la fonction requise d'un bien en panne

B/Maintenance préventive

La maintenance préventive est décrite comme une « intervention réalisée à des moments prédéfinis ou selon des critères établis, visant à diminuer la probabilité de panne ou la dégradation des équipements » (SS-EN 13306, 2001, p.14). Cette forme de maintenance englobe deux approches distinctes : la maintenance préventive systématique et la maintenance préventive conditionnelle (SS-EN13306, 2001) [17].

B.1/Maintenance préventive systématique

La maintenance systématique est planifiée à l'avance, se fait sans nécessiter de surveillance continue. Elle peut être programmée selon le nombre d'heures d'opération, le nombre d'utilisations d'un système, le kilométrage parcouru, ou encore selon un calendrier préétabli.

Ce type de maintenance est particulièrement adapté pour les composants présentant des signes d'usure évidents, permettant ainsi d'effectuer les opérations nécessaires pour prévenir une défaillance systémique [17]. la maintenance systématique est également connue sous les noms de « maintenance basée sur le temps » et « maintenance préventive planifiée ».

B.2/Maintenance préventive conditionnelle

Contrairement à la maintenance préventive systématique, la maintenance préventive conditionnelle (MPC) n'est pas basée sur des interventions programmées à l'avance. Elle s'effectue en fonction des besoins signalés par l'état actuel du système [6].

Cette approche utilise des indicateurs spécifiques qui permettent de détecter l'état de santé du système et de prévoir les pannes potentielles avant qu'elles ne surviennent. Le suivi régulier de ces indicateurs offre des informations précieuses sur la probabilité d'une panne imminente et sur les premiers signes de défaillance pouvant affecter la performance du système ou, dans le pire des cas, entraîner son arrêt complet. La MPC est avantageuse car elle permet de détecter précocement les défauts et offre une grande précision dans la prédiction des défaillances. Elle facilite également le diagnostic des problèmes, puisqu'il est relativement simple de relier un défaut particulier aux paramètres surveillés. La MPC peut réduire significativement les coûts d'intervention et améliorer la fiabilité et la sécurité des opérations. Elle optimise l'équilibre entre les coûts de maintenance et les performances en maximisant la disponibilité et la fiabilité, tout en supprimant les opérations de maintenance superflues.

Dans ce concept de maintenance, la surveillance doit permettre la détection précoce de défauts et le suivi de leur évolution dans le temps. La détection des défauts à un stade précoce offre la possibilité de planifier et de préparer les interventions nécessaires.

Ces interventions se font lors des arrêts techniques de fabrication ou en provoquant des arrêts programmés en fonction notamment des impératifs de production.

La connaissance de la nature d'un défaut et sa gravité permet à l'ingénieur de maintenance de prendre une décision d'où la détection d'un défaut à un stade précoce le suivi de son évolution présentent un grand intérêt. Il est en effet impératif, dans un contexte industriel difficile où la disponibilité de l'outil de production, l'absence de stock et la réduction des coûts sont des objectifs stratégiques, de connaître de manière précise l'état du parc de machines.

La réponse à ces nouvelles exigences est du ressort du diagnostic. L'évolution du concept de maintenance préventive conditionnelle mène vers celui de maintenance prévisionnelle [6].

Cependant, l'évolution des techniques d'investigation et des outils de surveillance associée à l'amélioration considérable des performances de la micro-informatique tendent à rapprocher ces deux fonctions clés de la maintenance prévisionnelle que sont la surveillance et le diagnostic. Ces évolutions techniques ainsi que le développement de l'intelligence artificielle devraient permettre d'associer dans un même système :

- Une unité (portable ou à poste fixe) d'acquisition multivoies, de prétraitement et de stockage des signaux délivrés par différents types de capteurs (vibration, température, pression, débit, puissance, ou courant électrique...).
- Une unité de traitement composée d'un logiciel de gestion des données et d'aide à la décision pilotant automatiquement les traitements de signal et le calcul des indicateurs nécessaires à la formulation automatique d'un pré diagnostic élaboré.

B.3/ Maintenance prévisionnelle

Ce type de maintenance permet d'assurer le suivi continu des machines en service dans le but de :

- Prévenir les avaries graves et la casse.
- Intervenir uniquement ou c'est nécessaire et justifié.
- Pratiquer la maintenance sur la base d'informations objectives [14].

I.7.4/Avantage de la maintenance prévisionnelle ou conditionnelle

Les avantages apportés par la maintenance prévisionnelle ou conditionnelle sont d'ordre technique et économique :

A/Avantages techniques

- Meilleure connaissance de l'état réel du parc machine.
- Détection précoce des défauts et une diminution du nombre de pannes.
- Eviter les arrêts intempestifs et espacer les interventions systématiques.
- Diminuer les durées d'interventions.
- Meilleure planification des interventions de remise en état.
- Réduction des taux d'indisponibilité.
- Amélioration de la crédibilité de la maintenance vis-à-vis de la production.
- Fiabilisation de la production.
- Amélioration des approvisionnements en pièces de rechanges.
- Amélioration de l'image de l'entreprise [7].

B/Avantages économiques

- Prolongation de la durée de vie du matériel.
- Réduction des coûts de maintenance et de remise en état.
- Réduction des rebuts de fabrication et des pertes de production.
- Réduire les stocks de pièces de rechange.
- Réduction des montants des primes et franchises d'assurances.
- Réduction des pertes de matières et d'énergie
- Amélioration de la fiabilité de l'outil de production et de la sécurité du personnel [18].

I.7.5/Technique de surveillance par maintenance conditionnelle**a/ Notions d'indicateurs**

Le choix d'un certain nombre d'indicateurs est primordial pour la surveillance d'une machine. Ce sont des paramètres ou des grandeurs élaborés lors du fonctionnement de la machine. Par définition, un indicateur doit caractériser l'état ou les performances d'une machine de manière à ce que son évolution dans le temps doit avoir une signification dès l'apparition ou l'aggravation d'un défaut ou d'un ensemble de défauts. Parmi les indicateurs,

on cite : la température d'un palier, le taux de concentration dans le lubrifiant de particules métalliques et leur spectre dimensionnel, le rendement mécanique ou thermodynamique d'une machine, le bruit, le spectre ou la forme du courant d'alimentation d'un moteur électrique, le taux de rebuts de fabrication ...[17]

Le fonctionnement de tout dispositif comportant au moins une pièce en mouvement s'accompagne de vibrations qui représentent les images directes des forces dynamiques provoquées par les organes en mouvement. Elles sont caractéristiques de l'état de la machine et constituent ce qu'on appelle sa signature vibratoire. Les prélèvements et les techniques de traitement des signaux vibratoires permettent de définir plusieurs indicateurs de surveillance dont certains peuvent être extrêmement sensibles à l'apparition d'un défaut ou d'une anomalie et permettent sa localisation, voire même l'identification de sa nature, ainsi qu'au suivi de son évolution dans le temps sans effectuer le démontage.

L'analyse vibratoire est aussi dans le cadre de l'acquisition d'un nouvel équipement ou de sa remise en état, ce qu'on appelle le contrôle de sévérité vibratoire :

- Pour un équipement neuf, l'interprétation spectrale des mesures vibratoires permet la détection d'anomalies ou défauts de montage, pratiquement indécélables par d'autres techniques.
- Pour un équipement venant de faire l'objet d'une révision, elle permet de déceler un autre comportement anormal susceptible d'induire un nouvel arrêt intempestif.

On distingue deux catégories d'indicateur : les indicateurs principaux et secondaires [1].

b/ Les indicateurs principaux ou précoces

Ils permettent la détection des défauts à un stade précoce et d'en suivre l'évolution. A cet effet, les informations tirées des signaux émis par un équipement en fonctionnement permettent de réduire d'une façon remarquable

Le nombre d'arrêts inopinés sur panne et de planifier les interventions d'entretien le plus tard possible et uniquement quand cela devient nécessaire en perturbant au minimum la fabrication, notamment en les intégrant, dans la mesure du possible, dans les arrêts techniques programmés de production. Ceci se traduit non seulement par la réduction des temps d'arrêt des installations, mais il permet aussi d'optimiser la gestion du stock de pièces de rechange.

c/ Les indicateurs secondaires ou tardifs

Pour ce type d'indicateurs, une évolution significative traduit déjà des dégradations avancées et nécessite un arrêt à brève échéance, voire immédiate de la machine.

Il serait cependant peu réaliste et grave de penser que la fiabilité d'une surveillance repose uniquement sur le traitement des informations détectées par des capteurs ou véhiculées par un lubrifiant.

En résumé, la maintenance conditionnelle ou prévisionnelle fait appel à plusieurs techniques de surveillance, on cite : l'analyse des vibrations, l'analyse des huiles, la thermographie infrarouge, l'analyse des particules.

L'analyse vibratoire représente la majeure partie des techniques utilisées par la maintenance conditionnelle. Le traitement des signaux vibratoires permet de déceler ou d'identifier la totalité des pathologies susceptibles d'affecter un équipement industriel. Les autres indicateurs de surveillances jouent souvent un rôle complémentaire important dans la décision d'arrêter une installation [4]

I.7.6/Types d'analyse de l'état de fonctionnement des machines tournantes

Parmi les méthodes de surveillance et de diagnostic des machines tournantes, on distingue :

A/ Analyse vibratoire

L'analyse vibratoire occupe une position privilégiée. Dans Chaque machine, en particulier les machines tournantes, génère des vibrations qui possèdent un profil distinctif lorsqu'elles fonctionnent correctement. Dès que des phénomènes tels que l'usure, la fatigue, le vieillissement, le désalignement ou le déséquilibre se manifestent, Le profil de ces vibrations change, ce qui permet d'évaluer la nécessité d'une intervention. Cette technique permet de détecter la plupart des défauts mécaniques [13].

Cette technique permet d'obtenir une vision des forces dynamiques générées par les pièces en mouvement ou par des sources externes. Cette analyse des signaux vibratoires permet d'extraire des informations liées aux vibrations induites par les composants de la machine.

Les signaux vibratoires émis par les machines tournantes sont généralement harmoniques, ce qui justifie l'utilisation de la transformée de Fourier. Cependant, cette méthode ne convient pas toujours à tous les types de signaux, notamment les signaux non stationnaires.

Ces signaux sont souvent complexes et difficiles à interpréter, étant donné que l'analyse repose principalement sur des méthodes stationnaires classiques. Cependant, des recherches récentes ont souligné l'intérêt d'exploiter la non stationnarité des phénomènes vibratoires [15].

Dans la littérature, trois types d'analyses sont distingués : l'analyse temporelle, l'analyse fréquentielle et l'analyse temps-fréquence :

1/ Analyse temporels

L'analyse temporelle implique de suivre, dans le temps, le comportement vibratoire d'une machine en fonction de ses paramètres de fonctionnement.

Ce type de suivi est facile à interpréter lorsque le signal est simple, mais il devient difficile à exploiter lorsque le signal provient de sollicitations multiples.

Cette méthode repose sur le calcul statistique du signal collecté et est appliquée aux machines simples, en réalisant des mesures d'accélération [7].

L'objectif est de réduire l'influence des vibrations causées par la rotation des arbres. Elle utilise des indicateurs scalaires pour suivre l'évolution d'une grandeur dérivée de l'amplitude crête du signal. Bien que cette grandeur puisse ne pas avoir de signification intrinsèque, c'est son évolution dans le temps qui est significative du défaut.

Les indicateurs scalaires évaluent l'état de fonctionnement global des équipements, mais ne localisent pas le défaut.

Ce sont des méthodes utiles à la surveillance. Ils utilisent trois valeurs principales

- ACC crête : Accélération crête.
- ACC eff : Accélération efficace.
- ACC cc : Accélération crête-crête [18].

2/Analyse fréquentiels

L'analyse « en fréquence » est devenue l'outil fondamental pour le traitement des signaux vibratoires. Elle s'appuie sur la transformée de Fourier qui permet le passage du domaine temporel au domaine fréquentiel (figure I.13). Cette représentation permet de connaître le contenu spectral d'énergie ou de puissance présent dans le signal à la fréquence (f), et donc de détecter la présence d'un défaut générant un choc périodique à une fréquence de défaut.

La comparaison de cette fréquence avec celle des défauts théoriques potentiels (fréquences caractéristiques) sur le roulement permet sa localisation.

Dans la pratique, on utilise la transformée de Fourier discrète rapide (FFT) sur des signaux numérisés :

$$X(k) = \sum_{n=0}^{n=N-1} x(n) e^{\frac{2\pi kni}{N}} \quad (I.7)$$

Où :

$X(k)$: est la composante fréquentielle à la fréquence k ;

$x(n)$: est la valeur numérique du signal à l'instant n ;

N : est la taille de l'échantillon du signal ;

i : est l'unité imaginaire ($i^2 = -1$);

e : est la base du logarithme naturel.

Plusieurs indicateurs globaux ont été définis à partir de l'analyse temporelle afin de mettre en évidence la présence d'un défaut. Cependant, une telle démarche ne permet pas de détecter de manière fiable la nature du défaut ni d'identifier sa source.

La figure suivante ci-dessous représente la transformée de Fourier d'un signal temporel [15]

3/Indicateurs Temps-Fréquence

Les indicateurs temps-fréquence sont des outils essentiels dans l'analyse vibratoire avancée, permettant de caractériser les variations temporelles des composantes fréquentielles des signaux vibratoires. Contrairement aux analyses temporelles ou fréquentielles simples, qui ne fournissent qu'une vue statique du signal, les indicateurs temps-fréquence offrent une perspective dynamique, capturant les changements de fréquence au fil du temps.

Ces indicateurs sont particulièrement utiles dans le diagnostic des défauts dans les machines vibratoires [13]

Elle s'appuie sur la transformée de Fourier qui permet le passage du domaine temporel au domaine fréquentiel (figure I.13). Cette représentation permet de connaître le contenu spectral d'énergie ou de puissance présent dans le signal à la fréquence (f), et donc de détecter la présence d'un défaut générant un choc périodique à une fréquence de défaut.

La comparaison de cette fréquence avec celle des défauts théoriques potentiels (fréquences caractéristiques) sur le roulement permet sa localisation.

Plusieurs indicateurs globaux ont été définis à partir de l'analyse temporelle afin de mettre en évidence la présence d'un défaut. Cependant, une telle démarche ne permet pas de détecter de manière fiable la nature du défaut ni d'identifier sa source.

La figure suivante ci-dessous représente la transformée de Fourier d'un signal temporel [7].

B/ Analyse acoustique

La plage de fréquences des ultrasons s'étend de 20 000 à 10 000 000 Hertz, bien au-dessus de ce qui est perceptible par l'oreille humaine. Tout déplacement relatif entre les pièces génère des ultrasons, et leur surveillance dans le temps permet de détecter efficacement divers problèmes. Cette méthode présente de nombreuses applications, notamment la détection de fuites, le contrôle d'étanchéité, la détection de dégradations et l'évaluation de la lubrification [4].

C/ Analyse d'huile

La réalisation de cette analyse est simple, et quasiment tous les mécanismes lubrifiés peuvent être soumis à ce type de diagnostic. En étudiant l'huile en contact permanent avec les pièces mobiles, on obtient une multitude d'informations sur l'état de la machine, ce qui permet d'évaluer son niveau de dégradation et, par conséquent, sa capacité à fonctionner correctement.

Les résultats de l'analyse permettent de déceler des anomalies telles que :

- La présence de particules internes contaminant l'équipement ;
- La pollution par des agents extérieurs ;
- L'usure par abrasion.

D / Thermographie infrarouge

La thermographie est une méthode qui utilise une caméra infrarouge pour mesurer l'émission de rayonnement infrarouge (chaleur) et détecter ainsi les anomalies thermiques, ce qui permet d'évaluer les conditions de fonctionnement de l'équipement. Certaines zones peuvent présenter des températures anormalement élevées ou basses.

Les applications de cette technique sont variées, notamment :

- Repérer les zones de chaleur excessive dans les dispositifs électriques ou mécaniques.
- Repérer les pertes de chaleur dans les fours et les conduites en utilisant la thermographie [18].

I.7.7/ Surveillance de l'état de fonctionnement des machines tournantes

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

maintenance, sur un dysfonctionnement probable. La signature est établie à partir d'une première campagne de mesures sur la machine neuve ou révisée. D'après [3], on distingue deux types de surveillance : surveillance « **Online** », les mesures des indicateurs soit de manière continue, et soit d'une manière périodique qui est la surveillance « **Off line** ».

Dans un programme de surveillance d'une machine quelconque, on peut distinguer quatre missions principales : la détection de défauts, le diagnostic de défauts, le pronostic de défauts et la prise de décision [1].

Ces missions constituent les résultats de tout programme de maintenance et ne doivent pas être confondues avec les outils utilisés pour réaliser ces tâches, tels que l'acquisition de données et le traitement des données.

A/ La détection

La détection des anomalies constitue la phase initiale de toute politique de maintenance. Il s'agit d'une méthode qui évalue si un système opère dans des conditions normales ou non en se basant sur l'analyse des données issues de la surveillance de l'état. Habituellement, ce processus repose sur la mesure des écarts entre les comportements observés et attendu du système, utilisant pour cela un indicateur spécifique de l'état de santé et un seuil de détection prédéterminée.

À cette étape de la maintenance, la conclusion se limite à la présence ou l'absence d'une anomalie, sans fournir de précisions sur la localisation ou la sévérité de celle-ci [6].




Figure I. 1 : Composants de l'architecture de système de détection de défaut [10]

B/ Le diagnostic

Il permet de désigner l'élément de la machine défectueux Lorsqu'une défaillance est identifiée au sein du système suite à une évolution anormale des vibrations constatée lors de la surveillance (mesures).

Le diagnostic n'est réalisé que lorsque la surveillance a permis de détecter une anomalie ou une évolution dangereuse du signal vibratoire, Le diagnostic dans la majorité des cas est établi en interprétant les signaux vibratoires émis par les machines en fonctionnement et déterminer la nature et la cause de la défaillance, et évaluer le niveau de dégradation, ce qui permet de quantifier la sévérité du défaut [3].

C/ Pronostic

Le pronostic est le processus qui vise à prévoir le moment où un composant ne sera plus capable d'assumer sa fonction, ou à déterminer autrement la durée de vie utile restante (RUL) de ce composant.

Ce processus utilise généralement une variété d'algorithmes prédictifs qui cherchent à anticiper l'évolution future d'un indicateur de santé du système basé sur des données historiques. Le moment de la panne est alors établi à partir d'un seuil de défaillance prédéfini [17].

D/ Prise de décision

En conclusion, l'étape finale d'un processus de maintenance est celle de la prise de décision. Cette étape consiste à choisir et organiser les actions de maintenance les plus appropriées et efficaces en se basant sur les conclusions tirées des phases de détection, de diagnostic et de pronostic. Les décisions prises peuvent affecter divers aspects du cycle de vie d'un système, que ce soit au niveau de la conception avec des choix relatifs au design des composants, à leur emplacement ou à la modification de l'instrumentation du système.

Au niveau opérationnel, les décisions impliquent généralement des interventions de maintenance, des ajustements du fonctionnement de la machine, des reconfigurations matérielles ou logicielles, ou l'implémentation de commandes résistantes aux pannes [6].

I.8/Types de défauts et cause

Les machines tournantes, éléments vitaux dans de nombreux secteurs industriels, sont sujettes à divers types de défauts qui peuvent compromettre leur fonctionnement et leur efficacité. Identifier et comprendre ces défauts est essentiel pour mettre en place des stratégies de maintenance efficaces et pour minimiser les arrêts de production. Cette section se consacre à l'examen des principaux types de défauts affectant les machines tournantes, tels que les problèmes de roulements, les défaillances d'engrenages, et d'autres anomalies mécaniques courantes.

Chacun de ces défauts sera exploré en détail, mettant en lumière les causes, les symptômes, et les techniques de détection les plus adaptées. Ce panorama des défauts permettra non seulement de mieux comprendre les enjeux associés à chaque type de panne, mais aussi de poser les bases pour des approches de diagnostic plus ciblées et efficaces.

A / Le balourd

Le balourd survient lorsqu'un arbre de machine en rotation présente un déséquilibre causé par une répartition inégale des masses dans sa structure, déplaçant ainsi le centre de gravité hors de l'axe géométrique du rotor.

Les types de balourd comprennent le balourd statique, le balourd de couple, le balourd dynamique et le balourd thermique.

La force due au balourd est influencée par la masse du rotor et le rayon de rotation.

Elle varie proportionnellement au carré de la vitesse de rotation. Le balourd se caractérise par une augmentation significative de l'amplitude de la fréquence fondamentale.

Le balourd se manifeste par une nette augmentation de l'amplitude de la fréquence fondamentale (fréquence de rotation) [6] :

$$Fr = N/60 \quad (I.8)$$

Ou :

N : vitesse de rotation (tr/min)

Fr : Fréquence de rotation.




Figure I.8: Types de Balourd [15]

B/Le désalignement

Un désalignement engendre des vibrations à la fréquence de rotation et à ses harmoniques d'ordre 2, 3, 4.

Ces harmoniques se manifestent également dans les accouplements à denture, où des harmoniques liées au nombre de dents et à la fréquence de rotation peuvent être observées. La composante axiale des vibrations revêt une importance particulière pour les harmoniques d'ordre élevé.

Lorsqu'un palier est desserré ou présente une possibilité de mouvement partiel dans le plan radial, une vibration radiale apparaît à une fréquence égale à deux fois la vitesse de rotation. Cette vibration survient sous l'effet du balourd initial et peut prendre une amplitude élevée en fonction du degré de desserrage du palier comme c'est présenté dans la figure I.9.




Figure I.9: Défaut de désalignement [3].

C/Défauts d'engrenages

Ces défauts sont liés aux dégradations de la denture. Les vibrations des engrenages sont dominées par un effort à chaque contact. Un arbre tournant à une fréquence f sur lequel est

monté un pignon ou une roue comptant z dents sera soumis à z chocs par tour. La fréquence caractéristique de l'engrenage sera :

$$F_e = z \cdot F_r \quad (I.9)$$

Avec :

F_e : La fréquence caractéristique de l'engrenage ;

z : Nombre de dents ;

F_r : Fréquence de rotation.

Au début du fonctionnement des engrenages, pendant la période de rodage, les légères imperfections des profils des dents s'estompent progressivement. Après un certain temps, si les engrenages restent dans un environnement de fonctionnement optimal et sous de bonnes conditions, l'usure des dentures reste faible. Cependant, si les conditions de fonctionnement se dégradent, il est possible d'observer des détériorations sur les surfaces actives des dents.



Figure I.2: Les Types d'engrenages utilisés dans l'industrie : (a) Engrenage parallèle, (b) Engrenage hélicoïdal, (c) Engrenage conique et (d) Roue et vis sans fin [61].

D/L'usure

L'usure est un phénomène local qui se caractérise par l'élimination de matière résultant du frottement entre deux surfaces. Le processus d'usure dépend de la charge et de la vitesse de glissement au niveau de chaque point de contact entre les surfaces, ainsi que de la présence éventuelle de particules abrasives dans le lubrifiant. L'usure normale progresse lentement et

est inversement proportionnelle à la dureté superficielle des dents.

En revanche, l'usure anormale se produit lorsque le lubrifiant est contaminé par des particules abrasives ou s'il est corrosif comme c'est illustré dans la figure I.11. Cette usure anormale entraîne un mauvais fonctionnement voire l'arrêt complet de l'engrenage.



Figure I.11: Phénomène de l'usure sur un surface métallique [62]

E/ Les piqûres

Les piqûres sont des défauts peu profonds qui affectent toutes les dents des engrenages. Elles se produisent principalement sur des engrenages en acier de construction qui sont relativement moins durs et donc plus fragiles, sensibles aux contraintes cumulatives. Les piqûres sont moins susceptibles de se produire si la viscosité du lubrifiant est élevée.

L'apparition de piqûres est également liée à un rapport insuffisant entre l'épaisseur du film lubrifiant et la rugosité composite, ce qui entraîne des contacts entre les aspérités des surfaces.

F/Ecaillage

L'écaillage des dents est causé par l'absence de film d'huile entre les surfaces en contact. Cette absence de film d'huile est généralement due à un échauffement provoqué par les vitesses de frottement et de glissement entre les profils des dents.

Le contact entre les surfaces entraîne un processus d'usure et de rupture alternée qui enlève rapidement du matériau de la surface des dents (figure I.12). Cela peut être le résultat d'un état de surface insuffisant des dents ou d'un mauvais choix de lubrifiant.



Figure I.12 : Exemple de dégradation par écaillage sur des bagues de roulement [12]

G/Fissuration

La fissuration progresse progressivement à chaque application de charge et se situe au niveau du pied de la dent de l'engrenage (figure I.10).

Elle se produit généralement sur des aciers fins et durcis, qui sont sensibles à la concentration de contraintes.

L'apparition de ces fissures est le résultat d'une contrainte excessive au niveau du pied de la dent qui dépasse la limite de fatigue du matériau. Ces fissures se forment lorsque la contrainte de traction au pied de la dent dépasse la limite élastique du matériau.



Figure I.13: Exemple de fissuration d'engrenage [62]

H/ La corrosion

Ce type de défaut se caractérise par la présence de taches colorées entre le brun et le rouge sur le flanc des dents, accompagnées de légères irrégularités de surface autour de ces taches. Lors de l'engrènement, les traces de rouille ou d'oxydes se propagent sur tout le flanc, ce qui peut entraîner une usure dans la dent. Cette usure conduira éventuellement à un jeu

accru entre les dents.



Figure I.14 : Comparaison entre un roulement présentant des traces de corrosion et un roulement avec protection contre la corrosion [15]

I/La fatigue de contact

Ce type de détérioration de surface résulte de contraintes répétées exercées sur la surface ou les couches sous-jacentes, dépassant les limites de résistance ou d'endurance des matériaux.

Ce défaut se caractérise par l'arrachement de petits morceaux métalliques et la formation de cavités au fil du temps. Les conséquences de cette détérioration incluent la perturbation de la lubrification, entraînant une modification de la friction, la rupture du film d'huile et l'amorçage de la fatigue de flexion [12].




Figure I.15: Arrachement de petits morceaux métalliques suite à des contraintes répétées [62]

J/Les fissures en fatigue

Les fissures en fatigue surviennent généralement là où les contraintes sont maximales, notamment dans les arrondis des pieds des dents, du côté où la dent est soumise à une traction. Ces fissures fragilisent les dents, surtout lorsqu'elles s'incurvent pour atteindre

l'autre côté de la dent, réduisant ainsi sa rigidité. Dans la plupart des cas, ce type de fissure débute à partir d'une piqûre de contact située autour de la région fortement sollicitée en flexion [21].

Lalonde et Guilbault [22] ont examiné dans leur modèle une fissure au pied d'une dent du pignon, qui s'agrandit progressivement. Leur étude a révélé que la présence de la fissure réduit la rigidité de la dent.

Par ailleurs, Lavoie [15] a mené plusieurs études sur l'impact de la largeur, de la profondeur, de la position et de l'angle de la fissure par rapport à l'axe de rotation de la roue d'engrenage. Selon ses analyses, il a conclu que les paramètres géométriques, tels que la largeur et la profondeur de la fissure, sont les plus influents sur la rigidité.

Cependant, une augmentation de l'angle et de la profondeur entraîne une augmentation de la rigidité par rapport à un angle proche de zéro. En revanche, la largeur et la profondeur diminuent la rigidité. En ce qui concerne la position, elle a le moins d'influence lorsqu'elle est examinée seule. Cependant, si elle est combinée avec une augmentation de la largeur ou de la profondeur de la fissure, la diminution de la rigidité d'engrènement serait encore plus significative.

En général, chacun de ces paramètres influence la rigidité, mais lorsque plusieurs d'entre eux se combinent, les conséquences peuvent être dévastatrices [14].

H/ Défauts de roulements

Les roulements sont omniprésents, que ce soit dans les pédales de vélos, les ventilateurs d'ordinateurs, les compresseurs ou les roues de véhicules. De nombreux systèmes en rotation utilisent des roulements (figure I.16).




Figure I.16: Elément de roulement [3]

Dans l'industrie, les roulements sont des composants stratégiques des machines en rotation : ils se trouvent entre les parties fixes et mobiles de la structure, assurant ainsi la transmission des forces et la rotation de l'arbre [17].

Mais, s'ils sont les plus courants, ces composants sont aussi les plus fragiles. Il faut dire que les différents éléments qui les constituent (les billes, la cage et les bagues) sont en permanence sollicités. Le passage répétitif des billes sur les pistes engendre de fortes contraintes mécaniques qui entraînent peu à peu une dégradation du métal par fatigue, et finissent par provoquer l'apparition de défauts ponctuels (des fissures, un écaillage des surfaces, etc.).

Autre cause d'avarie, les défauts de montage et de conception. Ils provoquent en effet des surcharges qui entraînent, à terme, l'usure prématurée du roulement [19].

Parmi les causes externes d'endommagement des roulements, on peut citer :

- contamination du roulement par des particules extérieures : poussière, grains de sable, ...
- corrosion engendrée par la pénétration d'eau, d'acides, ...
- lubrification inadéquate qui peut causer un échauffement et l'usure du roulement,
- mauvais alignement du rotor,
- courant qui traverse le roulement et qui cause des arcs électriques.

Afin d'éviter des arrêts de production imprévus et coûteux, il est essentiel de surveiller en continu l'état des roulements et de détecter tous les signes avant-coureurs de défauts : des bruits inhabituels, des vibrations anormales, une augmentation de la température, etc [15].

I.9 /Conclusion

Les machines tournantes constituent des équipements essentiels dans les systèmes industriels, car elles assurent la conversion et la transmission de l'énergie mécanique dans de nombreux domaines. Leur bon fonctionnement dépend de plusieurs phénomènes physiques tels que les vibrations, les effets thermiques, les phénomènes hydrodynamiques ainsi que les conditions de frottement et de lubrification, qui peuvent influencer directement leurs performances et leur durée de vie.

L'étude des différents types de machines tournantes, de leurs principes de fonctionnement et des défauts susceptibles d'apparaître permet de mieux comprendre les causes de dégradation

et d'anticiper les défaillances. Dans ce contexte, la maintenance industrielle joue un rôle fondamental pour garantir la fiabilité, la sécurité et la disponibilité des équipements [6].

L'utilisation des techniques modernes de maintenance, telles que la surveillance conditionnelle, l'analyse vibratoire et le diagnostic des défauts, permet de détecter les anomalies à un stade précoce et d'optimiser les interventions de maintenance. Ainsi, une gestion efficace de la maintenance contribue à améliorer les performances des machines tournantes, à réduire les coûts d'exploitation et à prolonger leur durée de vie [3].

Technique de maintenance pour l'analyse vibratoire

II.1/Introduction

La surveillance et le diagnostic des machines tournantes par analyse vibratoire reposent sur la capacité à extraire, à partir des signaux vibratoires mesurés, des informations pertinentes et exploitables sur l'état de santé mécanique de ces équipements. Ce chapitre se propose de présenter de manière structurée et progressive l'ensemble de ces outils, en détaillant leurs fondements théoriques, leurs modalités de calcul et leurs domaines d'application respectifs. La maîtrise de ces techniques constitue le socle indispensable sur lequel s'appuiera, dans les chapitres suivants, le développement du système intelligent de prédiction des défauts des machines tournantes [6].

II.2/Outils de maintenance utilisés pour l'analyse vibratoire

L'analyse vibratoire constitue aujourd'hui l'une des méthodes les plus utilisées et les plus performantes en maintenance prédictive, en raison de sa grande praticité et de sa polyvalence. Elle permet de surveiller l'état de fonctionnement des machines tournantes en exploitant les vibrations générées par leurs composants mécaniques, offrant ainsi la possibilité de détecter précocement un large éventail de défauts tels que les déséquilibres, les défauts d'alignement, les jeux mécaniques ou encore les anomalies des roulements et des engrenages [17].

Non intrusive et applicable en fonctionnement normal des équipements, cette technique fournit une vision globale et fiable du comportement dynamique des machines comme c'est présenté par le tableau II.1.

Tableau II.1:Correspondance entre les types de défauts et les méthodes de détection

Tableau 1 : Principales méthodes de détection [Mar. 03].				
Types de défauts	Analyse vibratoire	Analyse d'huiles	Thermographie IR	Analyse acoustique
Déséquilibres, balourd	Oui	Non (sauf s'il y a usure)	Oui (s'il y a un échauffement)	Non
Jeux, défauts de serrage	Oui	Non (sauf s'il y a usure)	Oui (s'il y a un échauffement)	Oui (s'il y a une résonance)
Défauts spécifiques aux roulements	Oui	Oui	Oui	Oui
Défauts spécifiques aux engrenages	Oui	Oui	Oui	Oui
Défauts de courroies	Oui	Non	Oui	Oui
Défauts d'alignement	Oui	Non	Oui	Non
Défauts liés à la lubrification (Dégradation de la qualité de l'huile)	Non (sauf paliers fluides)	Oui	Non	Oui
Manque d'huile	Oui	Oui	Oui	Oui
Défauts de nature électrique ou électromagnétique	Oui	Non	Oui	Oui
Défauts liés aux écoulements (pour pompes et machines hydrauliques)	Oui	Non	Non	Oui

L'analyse des signaux vibratoires peut être réalisée selon deux approches complémentaires : le domaine temporel et le domaine fréquentiel.

L'analyse temporelle permet d'extraire des indicateurs statistiques caractérisant l'intensité et la forme du signal, tels que la valeur RMS, la valeur crête et le kurtosis. Parmi eux, la valeur RMS est particulièrement significative puisqu'elle représente l'énergie moyenne du signal et permet d'évaluer le niveau global de vibration.

Toutefois, ces indicateurs ne permettent pas toujours d'identifier précisément l'origine des défauts. C'est pourquoi l'analyse fréquentielle, basée sur la transformée de Fourier (FFT), est utilisée afin de mettre en évidence les fréquences caractéristiques associées aux différentes anomalies mécaniques. Cette approche permet un diagnostic plus précis des défauts, notamment le déséquilibre, le désalignement et les défauts de roulements [15].

Ainsi, la combinaison des analyses temporelle et fréquentielle constitue une méthode complète et efficace pour la surveillance et le diagnostic des machines tournantes dans le cadre de la maintenance conditionnelle.

II.3/Activités de l'analyse vibratoire

L'analyse vibratoire est un ensemble d'outils méthodologiques bien établis a été développé au fil des années, couvrant deux dimensions complémentaires et indissociables : la surveillance et le diagnostic comme c'est présenté par la figure II.1 ci-dessous [18] :




Figure II.1: Schéma présentatif des activités de l'analyse vibratoire [14]

II.3.1/La surveillance et analyse temporelle pour l'analyse vibratoire

La surveillance du système d'engrenages d'une machine tournante par l'analyse vibratoire est un thème qui a pris un grand intérêt durant les trois dernières décennies [13]. Les

vibrations issues d'une machine sont très affectées par les conditions de son fonctionnement (vitesse, charge...) [7].

La surveillance par analyse vibratoire, consiste à suivre en continu ou périodiquement l'évolution de l'état d'une machine à travers des indicateurs scalaires synthétiques, extraits directement du signal vibratoire temporel. Ces indicateurs, calculés dans le domaine temporel, permettent de détecter rapidement toute dégradation ou anomalie par simple comparaison avec des seuils d'alarme prédéfinis. Parmi les plus utilisés en milieu industriel, on distingue la valeur RMS, qui rend compte de l'énergie globale des vibrations, l'indicateur crête, sensible aux chocs transitoires, le kurtosis, particulièrement efficace pour la détection précoce des défauts de roulements, ainsi que le spectre PBC qui offre une vision plus fine de la distribution de l'énergie vibratoire.

Plusieurs techniques d'analyses des signaux vibratoires dans le domaine temporel existent et sont basées sur l'analyse statistique du signal recueilli à travers des indicateurs dits globaux. Ces indicateurs évaluent l'état de fonctionnement global des équipements mais ne localisent pas le défaut, ce sont des méthodes utiles à la surveillance. Plusieurs travaux de recherches ont proposé un ensemble d'indicateurs pour le diagnostic automatisé des défauts de roulements. Il s'agit des indicateurs statistiques tels que la Valeur Efficace, l'Ecart Type, le Skewness et le Kurtosis.

D'autres indicateurs basés sur la combinaison de ces premiers ont été également proposés tels que le facteur de crête, facteur d'impulsion, facteur de clairance, facteur de forme.

a/ Valeur efficace (RMS)

La valeur RMS (Root Mean Square), appelée en français valeur efficace, est un indicateur statistique très utilisé en analyse vibratoire pour mesurer l'intensité globale des vibrations d'une machine. Elle représente la valeur moyenne de l'énergie contenue dans le signal vibratoire sur une période donnée et utilisée pour détecter des dissipations d'énergie anormalement élevées accompagnant la naissance d'un défaut.

Mathématiquement, la valeur RMS d'un signal vibratoire $x(t)$ est définie par la relation suivante :

$$RMS = \sqrt{\frac{\sum_{i=1}^n (x(i))^2}{n}} \quad (\text{II.1})$$

Où :

$x(i)$: la valeur instantanée du signal à i ;

n ; le nombre de points du signal.

La valeur RMS est particulièrement importante car elle reflète l'énergie moyenne des vibrations produites par la machine. Plus la valeur RMS est élevée, plus le niveau de vibration est important, ce qui peut indiquer la présence d'un défaut mécanique comme le déséquilibre, le désalignement ou l'usure des roulements.

En maintenance industrielle, la valeur RMS est largement utilisée pour surveiller l'état des machines tournantes et comparer les niveaux de vibration aux limites définies par les normes internationales, notamment ISO 10816 et ISO 20816 [24].

Le RMS correspond à l'énergie globale des vibrations produites par la machine. Une augmentation progressive du RMS peut indiquer :

- Déséquilibre (balourd) ;
- Désalignement ;
- Desserrage mécanique ;
- Usure des roulements.

Elle est sensible aux phénomènes basse fréquence (balourd, lignage, fixation). Une augmentation du RMS indique une dégradation générale du niveau vibratoire.

Limite

Elle est peu sensible aux chocs de faible énergie (début d'écaillement de roulement). Cependant, le RMS ne permet pas d'identifier précisément la nature du défaut, il sert surtout d'indicateur d'alarme globale [4].

b/La valeur crête (Crest Value)

Le facteur de crête (Crest Factor) est un indicateur statistique largement utilisé dans l'analyse vibratoire pour la surveillance de l'état des machines tournantes. Il permet de détecter la présence de chocs ou d'impacts dans le signal vibratoire, souvent associés à des défauts naissants dans les roulements, les engrenages ou certains composants mécaniques. Le facteur de crête est particulièrement utile dans les programmes de maintenance conditionnelle et prédictive, car il permet d'identifier des anomalies à un stade précoce, avant que l'augmentation globale des vibrations ne soit visible dans la valeur RMS. Contrairement à la valeur efficace ; Le facteur crête est le mieux adapté pour représenter un signal induit par des

forces impulsionnelles telles que les écaillages de roulements. Ces indicateurs sont issus des valeurs crêtes du signal temporel mesuré.

Mathématiquement, la valeur crête est définie comme :

$$\text{Crest value} = \frac{\text{Peak}}{\text{RMS}} \quad (\text{II.2})$$

Avec :

Peak : amplitude maximale du signal vibratoire ;

RMS : valeur quadratique moyenne du signal.

Ce rapport permet d'évaluer le caractère impulsif du signal vibratoire

b.1/Signification physique

Dans un signal vibratoire normal, les vibrations sont généralement régulières et relativement uniformes. Dans ce cas, la valeur crête et la valeur RMS restent proportionnelles et le facteur de crête est relativement faible.

En revanche, lorsqu'un défaut mécanique apparaît (par exemple dans un roulement), le signal vibratoire contient des impulsions brèves mais très intenses. Ces impulsions augmentent fortement la valeur Peak, tandis que la RMS augmente plus lentement.

Par conséquent, le facteur de crête augmente, ce qui indique la présence d'impacts dans le signal [19].

b.2/Interprétation des valeurs

L'interprétation du facteur de crête suit généralement les seuils indiqués dans le tableau II.2 ci-dessous :

Tableau II.2: Interprétation du facteur de crête [1]

Valeur du facteur de crête	Interprétation
1.5 – 2	Vibration stable et régulière
2 – 3	Fonctionnement normal
3 – 4	Apparition possible d'impacts
> 4	Défaut probable (roulement ou engrenage)

Il convient de noter que ces valeurs peuvent varier selon : Le type de machine ; La vitesse de rotation ; La méthode de mesure ; L'environnement de fonctionnement [18].

b.3/ Application dans la détection des défauts

Le facteur de crête est particulièrement efficace pour détecter les défauts à caractère impulsif. Dans le cas des roulements, les défauts de piste intérieure, de piste extérieure ou des éléments roulants génèrent des impacts périodiques qui se traduisent par des pics d'accélération élevés et une augmentation significative de la valeur Peak.

Concernant les engrenages, les dents endommagées produisent des chocs lors de leur contact, qui apparaissent sous forme d'impulsions dans le signal vibratoire. Par ailleurs, cet indicateur peut également révéler des jeux mécaniques excessifs ou des desserrages de composants [7].

b.4/Évolution pendant la dégradation d'une machine

Dans le processus de dégradation d'un roulement, l'évolution du facteur de crête suit généralement trois phases distinctes. En phase initiale, les premiers impacts font augmenter le facteur de crête tandis que la RMS reste encore faible, ce qui en fait un indicateur de détection précoce particulièrement précieux. En phase intermédiaire, la RMS commence à augmenter progressivement tandis que le facteur de crête demeure élevé. Enfin, en phase avancée, la RMS atteint des valeurs très élevées et les vibrations deviennent continues, ce qui peut paradoxalement faire diminuer le facteur de crête. Cela confirme que cet indicateur est surtout pertinent et fiable dans les premières phases de dégradation [17].

Dans le processus de dégradation d'un roulement, l'évolution des indicateurs vibratoires suit généralement le tableau II.3 suivant :

Tableau II.3: Evolution du facteur de crête dans le temps [1]

Phase initiale du défaut	Phase intermédiaire	Phase avancée
Apparition d'impacts	Augmentation progressive de la RMS	RMS très élevée avec des vibrations continues
Augmentation du facteur de crête	Facteur de crête encore élevé	Diminution du facteur de crête
RMS encore faible		Diminution du facteur de crête

b.5/Avantages du facteur de crête

Le facteur de crête présente plusieurs avantages dans l'analyse vibratoire :

- Indicateur simple à calculer ;

- Sensible aux impulsions mécaniques ;
- Utile pour la détection précoce des défauts ;
- Complémentaire à la valeur RMS.

Il est souvent utilisé dans les systèmes de surveillance automatique des machines.

b.6/Limites du facteur de crête

Malgré ses avantages, cet indicateur présente certaines limitations :

- Il est sensible au bruit ;
- Il ne permet pas d'identifier précisément la source du défaut ;
- Il peut être influencé par des perturbations externes.

Pour ces raisons, il est généralement utilisé en combinaison avec d'autres méthodes d'analyse vibratoire, Telles que l'analyse spectrale, l'analyse d'enveloppe, le kurtosis et l'analyse temps-fréquence, afin d'établir un diagnostic plus complet et fiable [3].

b.7/Utilisation pratique dans l'analyse vibratoire

Dans la pratique industrielle, le facteur de crête est généralement calculé à partir du signal d'accélération mesuré par un accéléromètre installé sur la machine. La procédure débute par l'acquisition du signal vibratoire, à partir duquel la valeur RMS et la valeur Peak sont extraites. Le facteur de crête est ensuite calculé par le rapport de ces deux grandeurs, puis son évolution est suivie dans le temps afin de détecter toute tendance anormale.

Cette démarche simple et efficace permet d'identifier rapidement les machines présentant des anomalies et nécessitant une analyse vibratoire plus approfondie [1].

c/La Kurtosis (Curtosis)

La kurtosis (Curtosis) est un indicateur statistique avancé utilisé dans l'analyse vibratoire pour détecter les défauts impulsifs dans les machines tournantes, notamment les défauts de roulements. Contrairement aux indicateurs classiques comme la valeur RMS, qui mesurent l'énergie globale du signal vibratoire, la kurtosis permet d'évaluer la présence de pics ou d'impacts dans le signal.

Dans le domaine de la maintenance conditionnelle, la kurtosis est particulièrement utile pour la détection précoce des défauts, car elle est très sensible aux impulsions générées par les premières dégradations des composants mécaniques.

Elle est définie mathématiquement par :

$$K = \frac{1}{N} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^4 \quad (\text{II.3})$$

Où :

x_i : valeur instantanée du signal vibratoire ;

μ : moyenne du signal ;

σ : écart-type du signal ;

N : nombre d'échantillons.

Cette expression correspond au moment statistique d'ordre quatre normalisé par la variance.

c.1/Signification statistique

La kurtosis décrit le degré d'aplatissement ou de concentration des données autour de la moyenne. Dans l'analyse vibratoire, elle permet de déterminer si le signal contient des impulsions ou des chocs mécaniques.

- Cas d'un signal normal (gaussien): Pour un signal vibratoire ayant une distribution normale : Kurtosis ≈ 3 : Cela signifie que les vibrations sont relativement régulières et sans impacts significatifs.
- Cas d'un signal impulsive: Lorsque le signal contient des impacts (chocs), la distribution devient plus pointue et la kurtosis augmente [18]

Tableau II.4 : Signification statistique du Kurtosis [1]

Valeur de la kurtosis	Interprétation
≈ 3	Signal normal
3 – 5	Apparition d'impacts
6– 10	Défaut probable
> 10	Défaut severe

Une valeur élevée de kurtosis indique donc la présence d'impulsions importantes dans le signal vibratoire. Lorsqu'un composant mécanique commence à se détériorer, il génère des impacts localisés. Ces impacts produisent des pics de vibration très courts mais de forte amplitude. Ces pics ont un effet significatif sur la kurtosis car :

- La RMS dépend de l'énergie moyenne ;
- La kurtosis dépend fortement des valeurs extrêmes ;
- Ainsi, même si les vibrations globales restent faibles, la kurtosis peut augmenter fortement.

C'est pourquoi cet indicateur est très efficace pour la détection précoce des défauts.

c.2/Application de la kurtosis dans la surveillance des machines

La kurtosis est un indicateur statistique essentiel en maintenance prédictive, utilisé pour détecter les phénomènes impulsifs dans les signaux vibratoires. Elle est particulièrement efficace pour identifier les défauts naissants dans les machines tournantes, car elle met en évidence les pics d'accélération souvent invisibles avec d'autres indicateurs comme la RMS [7].

La kurtosis est un indicateur pertinent pour la détection de plusieurs types de défauts mécaniques associés à des phénomènes impulsifs. Parmi ces défauts, on peut citer les défauts de roulement et d'engrenage, les fissures dans les composants, les chocs entre pièces mécaniques, le desserrage des assemblages ainsi que les défauts intermittents. Ces anomalies engendrent des signaux vibratoires non stationnaires caractérisés par la présence d'impulsions brèves et de forte amplitude. Par conséquent, ces perturbations influencent directement la valeur de la kurtosis, qui augmente de manière significative en présence de ce type de défaut, ce qui facilite leur détection [17].

c.3/Évolution de la kurtosis pendant la dégradation d'une machine

L'évolution de la kurtosis au cours du temps constitue un indicateur fiable pour suivre les différentes phases de dégradation d'un composant mécanique. Cette évolution permet de mieux comprendre le comportement du signal vibratoire en fonction du niveau de sévérité du défaut.

Dans une première phase, appelée phase de défaut naissant, des impacts isolés commencent à apparaître dans le signal vibratoire. À ce stade, la valeur RMS reste généralement faible, tandis que la kurtosis augmente rapidement, traduisant la présence de phénomènes impulsifs précoces.

Au cours de la deuxième phase, correspondant à la propagation du défaut, les impacts deviennent plus fréquents et plus énergétiques. La valeur RMS commence alors à augmenter progressivement, tandis que la kurtosis se maintient à un niveau élevé en raison du caractère toujours impulsif du signal [17].

Enfin, dans la phase de défaut sévère, les vibrations deviennent plus continues et perdent leur caractère impulsif. Cette situation se traduit par des vibrations quasi continues, une valeur RMS très élevée et une diminution possible de la kurtosis. Cette évolution met en évidence le fait que la kurtosis est particulièrement efficace pour la détection précoce des défauts, mais peut perdre en sensibilité lorsque le défaut devient très avancé [15].

c.4/Avantages de la kurtosis

La kurtosis présente plusieurs avantages importants dans l'analyse vibratoire :

- Très sensible aux défauts impulsifs ;
- Permet la détection précoce des anomalies ;
- Particulièrement efficace pour les roulements ;
- Complémentaire à la RMS et au facteur de crête ;
- Largement utilisée dans les systèmes industriels modernes.

c.5/Limites de la kurtosis

Malgré son efficacité, la kurtosis présente certaines limitations :

- Elle est sensible au bruit de mesure ;
- Elle ne permet pas d'identifier précisément la source du défaut ;
- Elle peut être influencée par des perturbations externes ;

Pour cette raison, elle est généralement utilisée avec d'autres méthodes d'analyse comme :

- L'analyse spectrale ;
- L'analyse d'enveloppe ;
- L'analyse temps-fréquence [3].

c.6/Utilisation pratique dans l'industrie

Dans un contexte industriel, la kurtosis est calculée à partir du signal d'accélération mesuré par un accéléromètre installé sur la machine. Le processus de surveillance repose généralement sur une chaîne de traitement bien définie, débutant par l'acquisition du signal vibratoire, suivie de son filtrage afin d'éliminer les bruits indésirables et d'améliorer la qualité des données [1].

Ensuite, différents indicateurs statistiques tels que la valeur RMS, la valeur de crête et la kurtosis sont calculés pour caractériser l'état de fonctionnement de la machine. L'évolution de ces indicateurs est ensuite suivie dans le temps afin de détecter toute anomalie ou tendance anormale. Enfin, des seuils d'alarme sont définis, permettant de déclencher automatiquement des alertes en cas de dépassement. Cette approche permet d'anticiper les défaillances, d'optimiser les opérations de maintenance et de réduire significativement les coûts ainsi que les arrêts imprévus [19].

II.3.2 /Le diagnostic

Les outils de diagnostic en analyse vibratoire jouent un rôle essentiel dans l'identification et la caractérisation des défauts affectant les machines tournantes. Contrairement aux outils de surveillance, qui permettent de détecter une anomalie globale à partir d'indicateurs simples, les outils de diagnostic offrent une analyse approfondie du signal vibratoire afin de déterminer la nature, la localisation et la gravité du défaut.

Ces méthodes reposent principalement sur l'étude des signaux dans différents domaines d'analyse, notamment le domaine fréquentiel et le domaine temps-fréquence. Elles permettent de mettre en évidence des signatures spécifiques associées à chaque type de défaut, telles que les fréquences caractéristiques des roulements, les harmoniques liées aux engrenages ou encore les phénomènes transitoires [6].

Parmi les principales techniques utilisées, on distingue l'analyse spectrale, qui consiste à examiner la répartition des fréquences du signal vibratoire afin d'identifier les anomalies caractéristiques des machines tournantes. L'analyse d'enveloppe est particulièrement adaptée à la détection des défauts de roulements, car elle met en évidence les modulations de haute fréquence générées par les impacts. Enfin, l'analyse temps-fréquence permet d'étudier les signaux non stationnaires en offrant une représentation simultanée dans le temps et en fréquence, ce qui est particulièrement utile pour détecter des défauts évolutifs ou intermittents. Ainsi, la combinaison de ces outils de diagnostic permet d'obtenir une vision complète et fiable de l'état de fonctionnement des machines, facilitant la prise de décision en maintenance prédictive [3].

a/ Analyse fréquentiels

L'analyse « en fréquence » est devenue l'outil fondamental pour le traitement des signaux vibratoires. Elle s'appuie sur la transformée de Fourier qui permet le passage du domaine temporel au domaine fréquentiel comme c'est montré par la figure II.4. Cette représentation permet de connaître le contenu spectral d'énergie ou de puissance présent dans le signal à la fréquence (f), et donc de détecter la présence d'un défaut générant un choc périodique à une fréquence de défaut. La comparaison de cette fréquence avec celle des défauts théoriques potentiels (fréquences caractéristiques) sur le roulement permet sa localisation [15].

Dans la pratique, on utilise la transformée de Fourier discrète rapide (FFT) sur des signaux numérisés :

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-\frac{2\pi i}{N} kn} \quad (\text{II.4})$$

Où :

$X(k)$: est la composante fréquentielle à la fréquence k ,

$x(n)$: est la valeur numérique du signal à l'instant n ,

N : est la taille de l'échantillon du signal,

i : est l'unité imaginaire ($i^2 = -1$),

e : est la base du logarithme naturel.

Plusieurs indicateurs globaux ont été définis à partir de l'analyse temporelle afin de mettre en évidence la présence d'un défaut. Cependant, une telle démarche ne permet pas de détecter de manière fiable la nature du défaut ni d'identifier sa source. La figure II.2 suivante ci-dessous représente la transformée de Fourier d'un signal temporel [18].




Figure II.2 : Transformée de Fourier d'un signal temporel en signal fréquentiel [3]

a.1/Spectrogramme

Le spectrogramme est une représentation graphique qui affiche l'intensité des composantes fréquentielles d'un signal en fonction du temps. Il permet de visualiser l'évolution des fréquences présentes dans le signal vibratoire au fil du temps. Le spectrogramme $S(t, f)$ est calculé à partir de la transformée de Fourier à court terme (STFT), qui consiste à calculer la transformée de Fourier du signal sur de petites fenêtres temporelles glissantes [7].

$$S(t, f) = \left| \int_{-\infty}^{\infty} x(\tau) \cdot w(t - \tau) e^{-j2\pi f \tau} d\tau \right|^2 \quad (\text{II.5})$$

a.2/Analyse spectrale, FFT

Le spectre, outil de cette analyse, se présente sous forme d'un graphique montrant l'amplitude de la vibration à chaque fréquence (figure II.3).

Les composantes du signal vibratoire sont représentées sous forme de pics dont on peut suivre individuellement une variation d'amplitude sans qu'il ait, comme dans la mesure globale, d'effet de masque qui risque de ne pas mettre en évidence un défaut en développement [1].

A partir des caractéristiques d'une machine surveillée, et des fréquences auxquelles apparaissent les anomalies, il est donc possible de détecter l'origine d'un défaut et d'en suivre l'évolution.

Les unités de fréquences les plus utilisées sont : le RPM ou nombre de rotations par minute ; le CPM ou nombre de cycles par minute ; le hertz (Hz) ou nombre de cycles par secondes ; $1 \text{ Hz} = 60 \text{ CPM} = 60 \text{ RPM}$ [4].




Figure II.3 : Exemple typique d'un spectre [3]

a.3/ Le spectre PBC (Peak Band Component)

Le spectre PBC (Peak Band Component) est une représentation fréquentielle utilisée en analyse vibratoire pour détecter les défauts précoces dans les machines tournantes. Permettant de mettre en évidence les composantes dominantes du signal, notamment sous forme de pics dans certaines bandes de fréquences. Il permet également d'identifier l'énergie localisée autour de ces pics, ce qui facilite l'analyse des phénomènes vibratoires associés aux défauts mécaniques. Contrairement au spectre FFT classique, qui représente l'ensemble du contenu fréquentiel du signal, le spectre PBC se concentre spécifiquement sur les bandes de fréquences où une augmentation anormale de l'énergie est observée (figure II.4). Cette approche permet d'améliorer la sensibilité de détection et d'identifier plus précisément les anomalies, en particulier dans les phases précoces de dégradation des machines [7].




Figure II.4 : Acquisition et analyse du signal vibratoire à l'aide d'un capteur et d'une application mobile [3]

a.3.1/Principe de fonctionnement

Le calcul du spectre PBC repose sur une série d'étapes successives visant à extraire les informations les plus pertinentes du signal vibratoire. Le processus débute par l'acquisition du signal à l'aide d'un capteur, suivie de sa transformation dans le domaine fréquentiel à l'aide de la transformée de Fourier rapide (FFT). Le spectre obtenu est ensuite divisé en plusieurs bandes de fréquences afin de faciliter l'analyse.

Pour chaque bande, une mesure représentative, telle que l'énergie ou l'amplitude maximale, est calculée afin de caractériser l'intensité des vibrations dans cette zone. Les bandes présentant des valeurs élevées sont alors identifiées comme significatives, car elles peuvent indiquer la présence d'un défaut ou d'une anomalie.

Ainsi, le spectre PBC permet d'obtenir une représentation simplifiée du signal, en mettant en évidence uniquement les zones critiques où l'énergie vibratoire est anormalement concentrée, ce qui facilite l'interprétation et le diagnostic [3].

a.3.2/Objectifs du spectre PBC

Le spectre PBC permet de :

- Détecter des défauts précoces invisibles dans le spectre global
- Localiser les zones fréquentielles critiques
- Suivre l'évolution des défauts dans le temps
- Réduire le bruit et améliorer la lisibilité du diagnostic [17].

a.3.3/Types de défauts détectés

Le spectre PBC constitue un outil performant pour l'identification de différents types de défauts mécaniques, en particulier ceux qui se manifestent par une concentration anormale d'énergie dans certaines bandes de fréquences. Il est notamment très efficace pour la détection des défauts de roulements, tels que les anomalies localisées sur la bague interne (BPFI), la bague externe (BPFO) ou encore les défauts affectant les éléments roulants. Ces défauts génèrent des signatures fréquentielles spécifiques facilement identifiables dans le spectre PBC.

En ce qui concerne les engrenages, le spectre PBC permet de mettre en évidence plusieurs anomalies, notamment l'usure des dents, le désalignement ou encore un jeu excessif entre les éléments en contact. Ces défauts se traduisent par une modification de la répartition de l'énergie dans certaines bandes de fréquences caractéristiques [14].

Par ailleurs, le spectre PBC est également capable de détecter d'autres anomalies mécaniques telles que le déséquilibre, le désalignement ou encore le desserrage des assemblages. Ces phénomènes influencent directement le comportement vibratoire de la machine et entraînent une augmentation de l'énergie dans des zones spécifiques du spectre, facilitant ainsi leur identification [18].

a.3.4/Avantages du spectre PBC

Le spectre PBC présente plusieurs avantages tels que :

- Sensibilité élevée aux défauts faibles
- Réduction du bruit par analyse en bandes
- Facilité d'interprétation
- Adapté à la maintenance prédictive [1].

a.3.5/Limites du spectre PBC

Malgré ses avantages, le spectre PBC présente aussi des limitations comme c'est présenté par le tableau II.5 ci-dessous :

- Nécessite un choix judicieux des bandes de fréquence
- Moins précis si les bandes sont mal définies
- Peut nécessiter une expertise pour interprétation avancée [3].

a .4/ Zone fréquentielle et principales anomalies des machines tournantes

L'analyse fréquentielle constitue un outil fondamental en diagnostic vibratoire, permettant d'identifier les défauts mécaniques à partir de leurs signatures caractéristiques dans le spectre. En effet, chaque type de défaut génère des vibrations à des fréquences spécifiques liées à la cinématique de la machine (vitesse de rotation, nombre de dents, géométrie des roulements, etc.). L'étude de ces fréquences permet ainsi de localiser et de caractériser les anomalies avec précision [17].

La zone fréquentielle correspond à la représentation du signal vibratoire dans le domaine des fréquences, obtenue généralement par la transformée de Fourier (FFT). Cette représentation permet de visualiser l'amplitude des vibrations en fonction de la fréquence et de distinguer différentes zones caractéristiques :

- **Basses fréquences (0 – 1 kHz)** : associées principalement aux phénomènes globaux comme le déséquilibre, le désalignement et le jeu mécanique
- **Moyennes fréquences (1 – 5 kHz)** : liées aux défauts d'engrenages et à certaines interactions mécaniques
- **Hautes fréquences (> 5 kHz)** : caractéristiques des défauts de roulements et des phénomènes impulsifs

Chaque zone fréquentielle correspond donc à un type spécifique de défaut, ce qui facilite l'interprétation du spectre vibratoire.

L'analyse cinématique de la machine tournante permet de déterminer à priori les zones fréquentielles où se manifestent les vibrations générées des vibrations de la machine [19].

Tableau II.5: Récapitulatif de reconnaissance des principales anomalies en fonction des fréquences [3, 6,7].

Cause	Vibration		Remarques
	Frequence	Direction	
Tourbillon d'huile	De 0.42 à 0.48*FR	Radiale	Uniquement surpaliers lisses hydrodynamiques à grand vitess
Balourd	1*FR	Radiale	Intensité proportionnelle à la vitess de rotation. déphasage de 90° sur 2 mesures orthogonales
Defaut de fixation	1,2,3,4*FR	Radiale	Aucun déphasage sur 2 mesures orthogonales
Defaut d'alignement	2*FR	Axiale et Radiale	Vibration axiale en general plus importante si le defaut d'alignement comporte un écart angulaire
Excitation électrique	1,2,3,4*50 HZ	Axiale et Radiale	Disparait des coupure de l'alimentation
Vitesse critique de rotation	Frequence critique du rotor	Radiale	Apparait en régime transitoire et s'atténue ensuite
Courroie en mauvais etat	1,2,3,4*FP	Radiale	
Engrenages endommagés	Frequence d'engrènement : FE=N dents *FR arbre	Axiale et Radiale	Bandes latérales autour de la frequence d'engrenement
Faux-rond pignon	F+-FR pignon	Axiale et Radiale	Bandes latérales autour de la frequence d'engrenement dues au faux-rond
Excitation hydrodynamique	Frequence de passage des aubes	Axiale et Radiale	
Deterioration de roulement	Hautes fréquences	Axiale et Radiale	Ondes de choc dues aux écaillages

b/Analyse Temps-Fréquence

L'analyse spectrale par analyse de Fourier ne peut naturellement pas prendre en compte l'évolution temporelle des caractéristiques fréquentielles des signaux non stationnaires tels que les vibrations. Pour décrire cette évolution temporelle, il faut réaliser une analyse spectrale évolutive, d'où la méthode Temps-Fréquence. La méthode d'analyse Temps-Fréquence a été développées pour l'étude des signaux non stationnaires. Plus généralement, elles s'appliquent à des signaux dont le contenu fréquentiel où les propriétés statistiques évoluent au cours du temps [7].

b.1/Transformée de Fourier à court-terme (TFCT ou STFT)

La transformée de Fourier à court terme (TFCT) a été développée par Gabor en 1946 connue également par la transformée de Fourier à fenêtre glissante (en anglais, ShortTime Fourier Transform (STFT)). Cette technique consiste à calculer la TF sur une partie du signal sélectionné supposé stationnaire à l'aide de fenêtre bien localisée en temps. La TFCT continue d'un signal $X(t)$ est définie par :

$$X_g(\tau, f) = \int_{-\infty}^{+\infty} x(t) g(t - \tau) \exp(-j2\pi f t) dt \quad (\text{II.6})$$

La TFCT discrète est donnée par [14] :

$$X_g(k, m) = \sum_{i=1}^n x(i) g(i - k) \exp\left(-j \frac{2\pi m k}{N}\right) \quad (\text{II.7})$$

Avec:

$K, i, m \in \mathbb{Z}$

N : le nombre de points du signal.




Figure II.5: Principe de la transformée de Fourier à court terme (TFCT) [12]

II.4/Conclusion

Dans ce chapitre nous avons présenté le principe de quelques méthodes, leur efficacité et leurs limites dans le diagnostic et la détection des défauts.

L'analyse temporelle (RMS, Facteur de Crête, Kurtosis, etc) permettant la détection de défaut mais ils sont limités pour l'identification et la localisation de défaut. Les outils de traitement de signal tels que la transformée de Fourier, le spectre ainsi que l'analyse d'enveloppe, donnent des résultats encourageants quand il s'agit de découvrir l'existence de défauts dans les roulements. Les techniques d'analyse Temps-Fréquence telles que la distribution peut résoudre les problèmes des méthodes fréquentielles.

Réseaux de neurones et algorithmes d'apprentissage

III.1/ Introduction

Le terme intelligence artificielle a été introduit dans les années 1950 par John McCarthy, chercheur et professeur éminent, pour désigner les systèmes capables de reproduire certaines capacités cognitives humaines et pour rendre les machines intelligentes par le biais de la science et de l'ingénierie [25]. L'IA repose sur des bases mathématiques telles que la logique booléenne et les probabilités, permettant aux programmes de prendre des décisions éclairées [24]. Ces avancées ont été fondamentales pour le développement de technologies intelligentes, améliorant ainsi la capacité des machines à traiter et à analyser de vastes quantités d'informations de manière efficace.

L'intelligence artificielle est aujourd'hui largement utilisée dans plusieurs domaines pour répondre aux besoins d'automatisation et d'efficacité. Elle permet d'apporter des solutions rapides et intelligentes adaptées aux exigences actuelles.

L'IA est aussi largement employée dans le domaine de la supervision et du diagnostic, elle a permis d'augmenter l'efficacité et la fiabilité du diagnostic. Dans le domaine de la supervision des machines tournantes. Elle regroupe plusieurs techniques, telles que les systèmes experts, les réseaux de neurones et la logique floue, pouvant être utilisées de manière indépendante ou combinée afin d'améliorer les performances des systèmes [27]. Ces approches reposent sur une phase d'apprentissage basée sur des données, dont la qualité influence directement les résultats obtenus.

Dans ce chapitre, nous allons parler des réseaux de neurones leur importance, ses modèles d'apprentissage automatique pour classer, prédire et reconnaître des formes [28].

III.2/ Notions de base sur l'apprentissage de la machine (Machine Learning)

III.2.1/ Définition

L'apprentissage automatique est une application de l'intelligence artificielle qui donne à la machine la capacité d'apprendre et de s'améliorer automatiquement à partir de l'expérience sans la programmer d'une façon explicite.

Une définition plus technique est proposée par Tom Mitchell (1997), l'apprentissage automatique désigne des systèmes optimisés par rapport aux modèles présents dans les données d'entraînement afin de réaliser des prédictions sur de nouvelles données.

Il existe plusieurs algorithmes d'apprentissage comme la régression linéaire, la régression logistique, l'arbre de décision, KNN, Naive Bayes, l'arbre aléatoire et ANN, CNN, RNN (deep learning)...




Figure III.1: (a) Algorithme de fonctionnement DL/ML, (b) performance des algorithmes DL par rapport aux anciens algorithmes en fonction de la quantité de données [3].

III.2.2/ Domaines d'application

L'évolution rapide de l'intelligence artificielle (IA) dans le monde des affaires a accentué son rôle central dans de nombreux domaines d'application. Aujourd'hui, cette technologie est intégrée dans plusieurs systèmes intelligents visant à améliorer la performance, la sécurité et l'expérience utilisateur par exemple :

- dans le domaine de la sécurité, les dispositifs modernes exploitent des données biométriques issues d'empreintes digitales ou de la reconnaissance faciale pour autoriser l'accès à des espaces sécurisés ou à des appareils personnels.
- Dans le secteur financier, l'IA permet d'analyser en temps réel les comportements des utilisateurs afin d'identifier des activités inhabituelles, comme des transactions suspectes, et de déclencher automatiquement des alertes pour limiter les risques de fraude. En parallèle, les smartphones intègrent des assistants vocaux basés sur le traitement du langage naturel, capables de comprendre les commandes vocales et d'interagir efficacement avec les utilisateurs.
- L'intelligence artificielle trouve également des applications importantes dans le domaine médical, notamment pour l'interprétation d'images radiologiques, la détection précoce de pathologies et l'aide à la prise de décision clinique. Dans le secteur industriel, elle est largement utilisée pour la maintenance prédictive, en exploitant les données issues des capteurs afin d'anticiper les défaillances des équipements et réduire les coûts d'arrêt [29].

- De plus, dans le commerce en ligne, les algorithmes d'IA analysent les préférences des consommateurs afin de proposer des recommandations personnalisées, ce qui améliore la satisfaction client et les performances commerciales.
- Enfin, dans le domaine des transports, cette technologie contribue au développement de systèmes intelligents, tels que les véhicules autonomes et la gestion optimisée du trafic routier [30].

III.3/ Réseaux de neurones artificiel (ANN)

III.3.1/ Historique

Les réseaux de neurones artificiels constituent une approche majeure de l'intelligence artificielle, inspirée du fonctionnement du cerveau humain, née il y a environ une cinquantaine d'années, leur conception repose sur l'observation des neurones biologiques. Ces neurones se distinguent du reste des cellules du corps par plusieurs avantages, ils sont capables de traiter et de transmettre l'information à travers des connexions synaptiques [32]. Cette inspiration biologique combinée entre la neurobiologie comme idée de base, la physique comme champs d'application et les mathématiques et l'informatique autant que moyens de réalisation, a permis l'émergence de modèles computationnels capables de simuler des mécanismes d'apprentissage.

Les réseaux de neurones ont suscité un intérêt croissant au sein de la communauté scientifique. Il a attiré l'attention de beaucoup de chercheurs de différentes disciplines. Leur évolution a été marquée par le passage de modèles simples à des architectures plus complexes sous le nom de « Deep Learning » :

- L'idée de modéliser les réseaux de neurones artificiels a été introduite pour la première fois dans les années 1940 par le mathématicien Warren McCulloch et le neurophysiologiste Walter Pitts. Ils ont publié un article sur la théorie des réseaux de neurones qui décrit un modèle simplifié de neurones et leur interconnexion pour résoudre des problèmes de logique.
- Dans les années 1950, le psychologue Frank Rosenblatt a développé le Perceptron, un réseau de neurones artificiels à une seule couche capable de résoudre des problèmes de classification simples.
- Dans les années 1960 et 1970, l'intérêt pour les réseaux de neurones artificiels a diminué en raison des limitations de l'époque en matière de puissance de calcul et de stockage de données [33].

- Dans les années 1980, l'apprentissage en profondeur a commencé à émerger avec des algorithmes tels que le réseau de neurones récurrents (RNN) et le réseau de neurones à propagation arrière (backpropagation), qui ont permis des modèles de réseaux de neurones plus complexes et plus profonds. Cependant, ces algorithmes ont encore été limités par les ressources informatiques de l'époque [3].
- Dans les années 1990, les réseaux de neurones ont été largement remplacés par des modèles d'apprentissage automatique basés sur des arbres de décision et des SVM. Cependant, la situation a changé dans les années 2000 avec l'évènement des processeurs graphiques (GPU) qui ont permis d'accélérer considérablement les calculs nécessaires pour les réseaux de neurones.
- Au cours de la dernière décennie, les réseaux de neurones sont devenus le modèle d'apprentissage automatique le plus populaire, en grande partie grâce à l'avènement de l'apprentissage en profondeur [37]. Les réseaux de neurones profonds ont permis des avancées dans des domaines tels que la reconnaissance d'image, la reconnaissance vocale, la traduction automatique et la génération de texte.

III.3.2/ Neurone biologique

Le neurone biologique est une cellule vivante spécialisée dans le traitement des signaux et la transmission de l'information électrochimique dans le système nerveux. Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux-mêmes jouer un rôle important dans le comportement logique de l'ensemble. Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu vont fournir un courant en sortie [34].

La structure d'un neurone Il se compose essentiellement de :

- **Corps cellulaire (La somma):** ou cellule d'activité nerveuse, il est centré par un noyau. Toutes les informations recueillies par les synapses sont acheminées vers le corps cellulaire ;
- **L'axone :** attaché au somma qui est la partie qui s'occupe de la transmission de l'information issue du corps cellulaire ; conduisant des signaux électriques de la sortie d'un neurone vers l'entrée d'un autre neurone ;
- **Dendrites:** ce sont de fines extensions tubulaires qui se ramifient autour du neurone et forment une sorte de vaste arborescence. Elles captent les signaux envoyés au neurone ;

- **Synapse:** une synapse est une jonction entre deux neurones ; et généralement entre l'axone d'un neurone et une dendrite d'un autre neurone.




Figure III.2: Les modèles de neurones biologiques [63]

Dans leur organisation générale et leur système biochimique, les nombreuses similitudes avec les autres cellules. Voici les caractéristiques biologiques :

- Des signaux en provenance de neurones voisins ;
- Recevoir ces signaux ;
- Engendrer un influx nerveux (message nerveux) ;
- Le conduire ;
- Le transmettre à un autre neurone capable de le recevoir.

III.3.3/ Neurone artificiel

a / Modélisation mathématique

Le neurone artificiel est une représentation mathématique inspirée du fonctionnement du cerveau humain. Bien que simplifiée par rapport au neurone biologique, conçue pour reproduire certaines de ses capacités telles que l'apprentissage, la mémorisation et le traitement parallèle de l'information. Il est considéré comme une fonction mathématique paramétrée, qui transforme un ensemble de données d'entrée en une sortie unique. Cette modélisation permet d'exprimer le comportement du neurone sous forme d'équations, où les paramètres essentiels sont les poids synaptiques et le biais [41]. Ainsi, le neurone artificiel constitue un élément de base dans la construction des réseaux de neurones, où plusieurs unités sont interconnectées pour former des systèmes capables de résoudre des problèmes complexes [42].

b/ Somme pondérée + biais

Le neurone artificiel fonctionne en deux étapes :

La première phase représente les prétraitements des données reçus en calculant le potentiel ϑ_j des neurones j par la fonction suivante [43] :

$$\vartheta_j = b_j + \sum_{i=1}^n \omega_{j,i} x_i \quad (\text{III.1})$$

Où :

$\omega_{j,i}$: Le poids de la connexion liant le neurone j à l'entrée i

b_j : Terme constant appelé biais, il est considéré comme le poids d'une entrée 0 x égal à 1

Ainsi la relation (III.1) s'écrit plus simplement :

$$\vartheta_j = \sum_{i=0}^n \omega_{j,i} x_i \quad (\text{III.2})$$

Dans la deuxième phase, une fonction de transfert g appelée également fonction d'activation, calcule la valeur de l'état interne du neurone j à partir de la valeur du potentiel ϑ_j . Cette valeur désignera la sortie du neurone [49]:

$$S_j = g(\vartheta_j) = g\left(\sum_{i=0}^n \omega_{j,i} x_i\right) \quad (\text{III.3})$$

Le choix de la fonction d'activation se révèle dans certains cas être un élément constitutif important des réseaux de neurones. Ainsi, le neurone peut être défini mathématiquement comme étant une fonction algébrique, a priori non linéaire (suivant g) et bornée, des entrées et paramétrée par les poids $\omega_{j,i}$:

$$S_j = g(x_i, \omega_{j,i}) = g_{\omega_{j,i}}(x_i) \quad (i = 1, 2, \dots, n) \quad (\text{III.4})$$




Figure III.3: Représentation d'un neurone artificiel [49]

Le fonctionnement du neurone débute par une phase de combinaison linéaire des entrées. Chaque signal d'entrée x_i est multiplié par un poids $\omega_{j,i}$ qui traduit l'importance de cette information dans le processus de calcul. L'ensemble de ces produits est ensuite additionné, puis un terme constant appelé biais b_j est ajouté afin d'ajuster le seuil d'activation du neurone. Cette opération permet d'obtenir le potentiel interne, représentant l'état du neurone avant activation. Le biais peut être interprété comme une entrée supplémentaire constante, facilitant la flexibilité du modèle et améliorant sa capacité d'apprentissage [44].

c/ Fonctionnement global

Après le calcul du potentiel interne, une fonction d'activation g , généralement non linéaire, est appliquée pour produire la sortie S_j du neurone. Cette fonction joue un rôle essentiel, car elle permet au modèle de représenter des relations complexes et non linéaires entre les données. Le neurone délivre ainsi une sortie unique, qui peut être transmise à d'autres neurones dans une couche suivante. Dans un réseau de neurones, ces unités sont organisées en couches et fonctionnent de manière parallèle, assurant une propagation de l'information de la couche d'entrée vers la couche de sortie [44]. La capacité globale du réseau repose sur l'ajustement des poids et du biais au cours du processus d'apprentissage, ce qui permet de stocker l'information et d'améliorer les performances du modèle.




Figure III.4: Mise en correspondance neurone biologique / neurone artificiel [49].

Le neurone artificiel est l'élément constitutif de l'ANN (Artificial Neural Network) conçu pour simuler la fonction du neurone biologique. Les signaux d'arrivée, appelés les entrées, multipliés par les poids de connexion (ajustés) sont d'abord additionnés (combinés) puis passe par une fonction d'activation pour produire la sortie pour ce neurone [43].

Le neurone réalise alors trois opérations sur ses entrées :

- **Pondération:** multiplication de chaque entrée par un paramètre appelé poids déconnexion,
- **Sommation:** une sommation des entrées pondérées est effectuée
- **Activation:** passage de cette somme dans une fonction, appelée fonction d'activation

III.4 / Fonctions d'activation

Les fonctions d'activation constituent un élément clé dans les réseaux de neurones artificiels. Elles interviennent après la combinaison linéaire des entrées pour convertir le signal interne du neurone en une sortie exploitable, rendant ainsi possible l'apprentissage et la modélisation des données.

Chaque neurone applique une fonction d'activation afin de déterminer son niveau d'activation en fonction des informations reçues. Il existe plusieurs types de fonctions, chacune étant adaptée à des contextes et des architectures spécifiques. Au-delà d'un simple rôle de transformation, ces fonctions influencent directement les performances du réseau ainsi que sa capacité à représenter des relations complexes entre les données [44].

III.4.1/ Rôle des fonctions d'activation

Un rôle fondamental de ces fonctions est d'introduire la non-linéarité dans le réseau. En l'absence de cette propriété, un modèle, même composé de plusieurs couches, se réduirait à une simple transformation linéaire, limitant fortement sa capacité à traiter des problèmes complexes. La non-linéarité permet ainsi au réseau de capturer des relations plus riches et plus réalistes entre les données [45].

De plus, les fonctions d'activation ont une influence directe sur le processus d'apprentissage. Elles interviennent dans la propagation des informations et dans l'ajustement des paramètres du réseau lors de l'entraînement. Un choix approprié contribue à améliorer la vitesse de convergence, la stabilité de l'apprentissage et les performances globales du modèle [43].

III.4.2 Types de fonctions d'activation

Il existe plusieurs fonctions d'activations, les plus utilisées sont :

a/ Fonction seuil asymétrique (Heaviside)

C'est une fonction discontinue en β prenant la valeur de 1 pour tous les réels supérieurs à β et la valeur de 0 pour tous les réels inférieur ou égal à β [48].

Si $\beta = 0$ la fonction s'appelle la fonction de Heaviside.

$$f(X) = \begin{cases} 0 & \text{si } X \leq \beta \\ 1 & \text{si } X > \beta \end{cases} \quad (\text{III.5})$$

Le graphique de la fonction seuil est donné par la figure II.4 :




Figure III. 5 Fonction seuil [48]

b/ Fonction sigmoïde

C'est une fonction en forme de S qui transforme la somme pondérée des entrées en une sortie comprise entre 0 et 1. Elle est souvent utilisée pour les problèmes de classification binaire [34].

$$f(x) = \frac{1}{1 + e^{-bx}} \quad (\text{III.6})$$

Avec :

b : Gain de la fonction d'activation.

Le graphique de la fonction sigmoïde est présenté par la figure II.5 :




Figure III.6: Fonction sigmoïde [48]

c/ Fonction saturation (Hardtanh)

C'est une fonction d'activation défini par:

$$f(x) = \begin{cases} 1 & \text{si } X > \beta \\ X & \text{si } \beta < X < \beta \\ 1 & \text{si } \beta < X \end{cases} \quad (\text{III.7})$$

Le graphique de la fonction saturation est présenté par la figure II.6 :




Figure III.7: Fonction saturation [48]

d/ Fonction gaussienne centrée

C'est une fonction en exponentielle de l'opposé du carré de l'abscisse. Elle a une forme caractéristique en courbe en cloche. Cette fonction est donnée par :

$$f(x) = \exp\left(\frac{-1}{2} \frac{x^2}{\sigma^2}\right) \quad (\text{III.8})$$

Avec :

σ : L'écart type de la gaussienne

Le graphique de la fonction gaussienne est présenté par la figure II.7 :




Figure III.8: Fonction gaussienne centrée [48]

e/ Fonction ReLU

La fonction ReLU est une des fonctions d'activation les plus utilisées. Elle est définie mathématiquement par :

$$f(X) = \begin{cases} 0 & \text{si } X < 0 \\ X & \text{si } X \geq 0 \end{cases} \quad (\text{III.9})$$

Le graphique de la fonction ReLU est présenté par la figure II.8 :




Figure III.9: Fonction ReLU centrée [48]

f/ Fonction Softmax

C'est une fonction exponentielle normalisée qui converti un nombre un vecteur de n nombre réel en une distribution de probabilité sur n choix. Cette fonction est défini par :

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^n e^{z_k}} \quad \text{avec } j \in \{1, \dots, n\} \quad (\text{III.10})$$

Avec :

z_i : les valeurs du vecteur d'entrée.

Le graphique de la fonction Softmax est présenté par la figure III.10 suivante:




Figure III.10: Fonction Softmax [48]

III.5/ Structure d'un réseau de neurones

Un réseau de neurones artificiels est une architecture de calcul inspirée du fonctionnement du cerveau humain, constituée de plusieurs couches de neurones interconnectés. Ces couches permettent d'assurer un traitement progressif et structuré de l'information, depuis les données d'entrée jusqu'aux résultats finaux [43].




Figure III.11 : Structure d'un réseau de neurones [36]

III.5.1/ Couche d'entrée (Input Layer)

La couche d'entrée représente le point d'accès du réseau. Elle est composée de neurones qui reçoivent directement les données du problème, sous forme de variables ou de caractéristiques. Le nombre de neurones dans cette couche dépend du nombre de variables d'entrée. Cette couche n'effectue généralement pas de traitement complexe, mais assure la transmission des informations vers les couches suivantes [44].

III.5.2/ Couches cachées (Hidden Layer)

Les couches cachées sont situées entre la couche d'entrée et la couche de sortie. Elles constituent le cœur du réseau et réalisent les traitements intermédiaires. Grâce à l'utilisation des poids, des biais et des fonctions d'activation non linéaires, elles permettent d'extraire des caractéristiques importantes et de modéliser des relations complexes entre les données. Le nombre de couches cachées et de neurones varie selon la complexité du problème à résoudre [45].

III.5.3/ Couche de sortie (Output Layer)

La couche de sortie correspond au dernier niveau du réseau. Elle regroupe les neurones responsables de produire les résultats finaux après les différentes transformations effectuées dans le réseau. Le nombre de neurones dans cette couche dépend du type de tâche (par exemple, un seul neurone pour une classification binaire ou plusieurs pour une classification multi-classes). Cette couche fournit ainsi la prédiction ou la décision finale du modèle.

Pris individuellement, chaque neurone effectue une transformation simple de ses entrées. Cependant, c'est leur interconnexion en réseau et la succession de transformations non linéaires qui confèrent aux réseaux de neurones leur capacité à résoudre des problèmes complexes [45]. Selon l'organisation des connexions, on distingue notamment les réseaux non bouclés (acycliques) et les réseaux bouclés, qui diffèrent par la présence ou non de rétroactions.

III.6/ Types de réseaux de neurones

L'architecture d'un réseau de neurones artificiels est définie par le nombre de couches qui le composent et par l'organisation des connexions entre ses neurones. Cette structure détermine la manière dont l'information circule et est traitée au sein du réseau. On distingue plusieurs formes d'architectures, notamment les réseaux monocouches, les réseaux multicouches, ainsi que les architectures à connexions locales ou entièrement connectées, chacune présentant des caractéristiques adaptées à des types de problèmes spécifiques [43].

III.6.1/ Réseaux monocouches (Perceptron)

Le réseau monocouche, connu sous le nom de perceptron, représente l'une des structures les plus simples des réseaux de neurones artificiels. Il se compose d'une unique couche de neurones directement reliée aux variables d'entrée. Il est composé de p neurones, Chaque

neurone reçoit l'ensemble des n entrées, que l'on organise de manière parallèle. Chacun peut en théorie avoir une fonction d'activation différente comme c'est mentionné sur la figure III.12. Ce type de réseau est principalement adapté à des tâches simples et ne permet de résoudre que des problèmes où les données sont séparables de manière linéaire [46].




Figure III.12 : Le réseau monocouche [3]

III.6.2/ Réseaux multicouches

Les réseaux multicouches constituent une généralisation du perceptron, permettant de traiter des problèmes plus complexes. Ils sont formés par l'enchaînement de plusieurs couches de neurones, où la sortie d'une couche est utilisée comme entrée pour la suivante. Cette organisation comprend habituellement une couche d'entrée, une ou plusieurs couches intermédiaires dites cachées, et une couche de sortie. Les connexions s'établissent généralement entre couches successives, sans liaison directe entre les neurones d'une même couche. L'introduction de fonctions d'activation non linéaires dans les couches cachées confère à ces réseaux une grande capacité de modélisation [45].




Figure III.13 : Réseaux de neurones multicouches [36]

III.7/Architectures des réseaux de neurones

III.7.1 / Réseaux non bouclés (Feed forward)

Un réseau de neurones non bouclé, appelé aussi non récurrents est représenté graphiquement par un ensemble de neurones connectés entre eux, on parle aussi de topologie. Se caractérise par une circulation de l'information dans un seul sens, des entrées vers les sorties (feed forward). Sans possibilité de retour en arrière, ce qui garantit une structure acyclique.

Les réseaux de neurones non bouclés sont des outils statiques, utilisés principalement pour effectuer des tâches l'approximation de fonctions non linéaires, de modélisation de processus statiques non linéaires [41].




Figure III.14 : Réseau non bouclé à connexions Totales ; à connexion partielle [36].

III.7.2/ Réseau de neurones bouclé (feed-back)

Ce sont des réseaux qui ont un ou plusieurs rebouclages internes, réalise une (ou plusieurs) fonctions algébriques de ses entrées, leurs sorties à un instant t dépendront des entrées aux mêmes instants, et aux instants antérieurs. Ces connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation. Les rebouclages rajoutent donc un effet de mémorisation du passé. Ces réseaux de neurones bouclés constituent un système dynamique "à temps discret", régi par une (ou plusieurs) équation(s) aux différences non linéaires, résultant de la composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions. Ils sont utilisés pour effectuer des tâches de modélisation et d'adaptation de systèmes dynamiques, de commande de processus, ou de filtrage [36].




Figure III.15 : Structure d'un réseau de neurones bouclées [36]

III.8/ Types d'apprentissage d'un réseau de neurones

Après la définition de l'architecture, le réseau de neurones passe par une phase d'apprentissage durant laquelle ses paramètres internes, notamment les poids des connexions, sont ajustés à l'aide d'algorithmes spécifiques. Ce processus vise à optimiser ces poids afin que le réseau adopte un comportement adapté au problème traité. Pour garantir de bonnes performances, les données utilisées lors de l'entraînement doivent être suffisamment représentatives du domaine étudié. À l'issue de cette phase, le réseau converge vers une solution satisfaisante. On distingue principalement deux modes d'apprentissage : l'apprentissage supervisé et l'apprentissage non supervisé[36]. !




Figure III.16 : Processus de l'apprentissage automatique [3].

Il existe plusieurs types d'apprentissage comme c'est mentionné par la figure III.17 ci-dessous :




Figure III.17 : Types d'apprentissage automatique [3]

III.8.1/ Apprentissage supervisé

L'apprentissage supervisé consiste à entraîner un réseau de neurones à partir d'exemples associant des entrées à des sorties attendues. Les poids synaptiques, initialisés généralement de manière aléatoire, sont ajustés progressivement à l'aide d'algorithmes d'optimisation afin de réduire l'écart entre la sortie produite et la sortie souhaitée. À chaque itération, l'erreur est calculée puis utilisée pour corriger les paramètres du réseau. Ce processus se répète jusqu'à obtenir des performances satisfaisantes. !




Figure III.18 : Apprentissage supervisé [36]

III.8.2/ Apprentissage non supervisé

L'apprentissage non supervisé repose sur la présentation d'exemples au réseau sans fournir de sorties attendues. Dans ce cadre, le réseau s'auto-organise en ajustant ses poids synaptiques selon des règles locales, sans intervention externe. Ce type d'apprentissage, souvent qualifié d'apprentissage par compétition, permet au modèle d'identifier des

similarités entre les données et de regrouper automatiquement les entrées en classes distinctes. En l'absence d'un signal d'erreur explicite, le processus d'apprentissage est généralement plus complexe et repose sur la capacité du réseau à extraire des structures cachées dans les données.




Figure III.19 : Apprentissage non supervisé [36]

III.8.3 Apprentissage par renforcement

L'apprentissage par renforcement est une approche basée sur l'expérience, dans laquelle le modèle apprend progressivement en interagissant avec son environnement. À chaque action effectuée, il reçoit une récompense lorsqu'elle est correcte ou une pénalisation dans le cas contraire, l'objectif étant de maximiser les gains cumulés au fil du temps. Contrairement à l'apprentissage supervisé, ce type d'apprentissage ne repose pas sur un signal d'erreur explicite, mais sur un indice de satisfaction global qui guide l'ajustement des poids synaptiques.

Pour améliorer ses performances, le réseau adopte un mécanisme d'essais et d'erreurs : il teste différentes actions, observe les sorties obtenues, puis adapte son comportement en conséquence. Cette absence d'indication directe rend l'apprentissage plus complexe et généralement plus lent, car le modèle doit estimer lui-même la meilleure direction d'ajustement. Malgré cela, cette méthode permet de surmonter certaines limites de d'optimisation séquentielle.

III.9/ Algorithmes d'apprentissage des réseaux de neurones artificiel

III.9.1 / Principe de l'apprentissage

Le mécanisme d'apprentissage dans les réseaux de neurones repose sur l'adaptation progressive des paramètres du modèle afin d'améliorer la qualité des prédictions. Ce processus vise à réduire l'écart entre les résultats fournis par le réseau et les valeurs attendues, en s'appuyant sur des techniques d'optimisation.

- Ajustement des poids

L'apprentissage s'effectue à travers la modification continue des poids synaptiques. À chaque itération, ces paramètres sont ajustés en fonction de l'erreur constatée, permettant ainsi au réseau de mieux s'adapter aux données et d'accroître ses performances de manière progressive.

➤ Fonction de coût

La fonction de coût permet d'évaluer la différence entre les sorties estimées et les valeurs de référence. Elle constitue un indicateur essentiel pour orienter le processus d'apprentissage, puisque les algorithmes cherchent à la minimiser afin d'améliorer la précision globale du modèle.

III.9.2 / Algorithme de Rétropropagation du gradient (Back propagation)

a/ Définition de la Rétropropagation

La rétropropagation est l'un des algorithmes d'apprentissage les plus utilisés dans les réseaux de neurones, en particulier pour les architectures multicouches. Elle permet d'ajuster efficacement les poids du réseau en propageant l'erreur de la sortie vers les couches précédentes, afin d'améliorer progressivement les performances du modèle.

a.1/Principe

Le principe de cet algorithme consiste à mesurer l'écart entre la sortie calculée et la valeur cible, puis à faire circuler cette erreur en sens inverse à travers le réseau. Cette propagation arrière permet d'évaluer l'impact de chaque poids sur l'erreur globale, afin d'ajuster ces paramètres dans le sens qui réduit cette dernière. Le réseau apprend ainsi de manière progressive en minimisant l'erreur au fil des itérations.

a.2/Étapes de calcul

Le fonctionnement de la rétropropagation suit plusieurs étapes successives. D'abord, une propagation avant est réalisée pour obtenir la sortie du réseau à partir des données d'entrée. Ensuite, l'erreur est déterminée en comparant cette sortie à la valeur attendue. Cette erreur est ensuite transmise vers les couches précédentes afin de calculer les gradients associés aux différents poids. Enfin, ces poids sont mis à jour selon la descente de gradient, dans le but de diminuer l'erreur. Ce processus est répété de manière itérative jusqu'à atteindre des performances satisfaisantes.




Figure III.20 : (1) propagation (2) retro propagation [48]

b/Algorithme de la descente de gradient de l'erreur

C'est un algorithme itératif conçu pour le but de minimiser l'erreur entre la sortie obtenue par le réseau multicouche et la sortie désirée :

$$F(x_i) \quad z_i \quad (III.11)$$

Avec :

$F(x_i)$: La sortie calculée

z_i : La sortie désirée

L'algorithme de la descente du gradient de l'erreur se résume par les étapes suivantes :

1/ Choix de la fonction d'activation et le réseau de neurones

2/ Initialisation des poids et le pas.

3/ Présentation des entrées et des sorties désirées de la base d'apprentissage

4/ Calcul de l'erreur locale et totale tel que :

$$E_i = (z_i - F(x_i))^2 \quad (III.12)$$

$$E_m = \frac{1}{N} \sum_{i=1}^N E_i \quad (III.13)$$

5/ Tant que l'erreur est importante, on calcule les gradients de l'erreur :

$$\text{gradient } E_i = \left(\frac{\partial E_i}{\partial w_i} \right) \quad (III.14)$$

6/ Calcul des nouveaux poids :

$$w_i(k+1) = w_{ij}(k) + \delta \left(\frac{\partial E_i}{\partial w_i(k)} \right) \quad (III.15)$$

Avec :

$w_i(k+1)$: Le nouveau poids; $w_{ij}(k)$: L'ancien poids; δ : Le pas (le taux d'apprentissage).

7 /Retour à l'étape 2

III.10/ Réseau de neurones convolutionnel (CNN)

a/ Définition

Un réseau de neurones convolutionnel (CNN) est une architecture particulière de réseau neuronal profond de type *feed-forward*. Conçue pour traiter des données structurées sous forme de grilles, comme les signaux ou les images. Il est constitué d'une couche d'entrée, suivie de plusieurs couches de convolution et de pooling, puis de couches entièrement connectées, et enfin d'une couche de sortie dédiée à la classification ou à la régression. L'un des principaux atouts des CNN réside dans leur capacité à exploiter la notion de champs réceptifs locaux, ce qui permet de réduire considérablement le nombre de paramètres (poids et biais) par rapport aux réseaux entièrement connectés classiques. Cette propriété favorise une meilleure efficacité d'apprentissage et limite la dépendance à de grandes quantités de données. Par ailleurs, des techniques d'optimisation sont intégrées afin d'améliorer les performances globales du modèle, notamment en termes de précision de classification [3].




Figure III.21: Schéma synoptique de la méthode utilisée [3]

b/ Principe

Le principe de fonctionnement des réseaux de neurones convolutifs repose sur l'extraction hiérarchique et automatique des caractéristiques des données d'entrée. Cette extraction est réalisée à l'aide de filtres de convolution appliqués localement sur les données,

contrairement aux réseaux entièrement connectés qui nécessitent un grand nombre de connexions entre les neurones. Cette architecture permet de réduire la complexité computationnelle tout en conservant les informations essentielles. Au fur et à mesure que les données progressent dans les différentes couches du réseau, des représentations de plus en plus abstraites sont construites. Les cartes de caractéristiques obtenues après les opérations de convolution mettent en évidence les éléments les plus pertinents, améliorant ainsi les performances de reconnaissance et de classification.




Figure III.22: Calcul convolutionnels [3]

c/Étapes de calcul

Dans le domaine du traitement du signal, on distingue principalement trois types de convolution : la convolution complète, la convolution identique et la convolution valide. Ces opérations sont utilisées pour extraire et représenter les caractéristiques des données à l'aide de filtres partageant les mêmes poids. Contrairement aux architectures entièrement connectées, les CNN utilisent plusieurs filtres indépendants pour analyser différentes parties de l'entrée.

Après l'opération de convolution, les données d'entrée sont transformées en plusieurs cartes de caractéristiques sous forme matricielle. Parmi les différentes variantes, la convolution valide est la plus couramment utilisée dans les CNN.

d /Algorithme d'apprentissage

L'apprentissage des CNN repose sur l'algorithme de rétropropagation du gradient, combiné à des méthodes d'optimisation telles que la descente de gradient. L'objectif est de minimiser une fonction de coût en ajustant les paramètres du réseau, notamment les poids des filtres de convolution et ceux des couches entièrement connectées.

À chaque itération, l'erreur entre la sortie prédite et la valeur réelle est calculée, puis propagée en sens inverse à travers les différentes couches afin de mettre à jour les paramètres. Ce processus itératif permet au modèle d'améliorer progressivement ses performances. L'intégration de fonctions d'activation non linéaires, telles que ReLU, contribue également à stabiliser l'apprentissage et à accélérer la convergence.

III.11/ L'algorithme LSTM (Long Short-Term Memory)

L'architecture *Long Short-Term Memory* (LSTM) est une extension des réseaux de neurones récurrents (RNN) spécialement conçue pour modéliser des données séquentielles et des séries temporelles sur de longs horizons. Alors que les RNN classiques échouent à capturer les dépendances éloignées en raison du phénomène mathématique de disparition du gradient, le LSTM résout cette limite en introduisant un « état de cellule ». Cet état de cellule fait office de mémoire à long terme en propageant l'information à travers le temps avec un minimum d'altération. Pour gérer ce flux, le LSTM s'appuie sur trois portes mathématiques régulées par des fonctions sigmoïdes :

- la porte d'oubli, qui applique une fonction sigmoïde pour filtrer et éliminer les informations obsolètes de l'état de cellule précédent $c(t-1)$;
- la porte d'entrée, qui sélectionne les nouvelles informations pertinentes à stocker en combinant un filtre sigmoïde, qui sélectionne les variables à modifier, et une couche tangente hyperbolique ($\tanh$), qui génère un vecteur de valeurs candidates $c(t)$;
- la porte de sortie, qui filtre la mémoire pour produire l'état caché actuel en utilisant une activation sigmoïde pour identifier les informations pertinentes de ce nouvel état de cellule afin de produire l'état caché actuel $h(t)$, qui servira à la fois de prédiction et de contexte pour le pas de temps suivant.

Grâce à cette structure interne sophistiquée comme c'est présenté par la figure III.23, le LSTM est capable de capturer simultanément des dynamiques à court et à long terme, s'imposant ainsi comme une méthode de référence pour l'analyse de structures temporelles complexes et non linéaires.




Figure III.23: Portes LSTM pour chaque pas du temps [58]

III.12 / Conclusion

Ce chapitre a permis de poser les fondements théoriques indispensables à la surveillance des machines tournantes en exploitant la complémentarité des réseaux CNN et LSTM. L'intégration du CNN s'avère cruciale pour scanner les signaux vibratoires bruts et en extraire automatiquement les signatures de défauts (roulements, engrenages), éliminant ainsi le besoin d'un calcul manuel d'indicateurs statistiques. De son côté, le LSTM prend le relais pour analyser la chronologie de ces signatures, permettant de mémoriser l'historique du signal et de suivre la dégradation progressive des composants dans le temps. Cette synergie spatio-temporelle offre une approche d'apprentissage profond automatisée et robuste, indispensable pour un diagnostic précoce et fiable des pannes industrielles. Dès lors, le chapitre suivant sera consacré à la mise en œuvre pratique de cette architecture hybride, détaillant la préparation de la base de données réelle, l'entraînement du modèle et la validation expérimentale de ses performances.

Résultats et interprétations

IV.1/Introduction

Ce chapitre présente l'ensemble d'une partie expérimentale et numérique conçu et mis au point au cours de cette étude. Le dispositif expérimental conçoit un banc d'essai et une chaîne d'acquisition de données pour déterminer les paramètres des signaux vibratoires pour un plusieurs catégories de défauts tel que : les défauts de roulement, d'engrenage et le désalignement. La partie numérique comprend une estimation des défauts par l'intelligence artificielle en utilisant l'algorithme de l'apprentissage profond hybride (CNN-LSTM) en utilisant la base de données de l'Université de Case Western Reserve (CWRU); et une validation des résultats d'apprentissage par la comparaison avec les résultats du banc d'essais.

VI.2/Partie expérimentale

La partie expérimentale conçoit un banc d'essai et une chaîne d'acquisition de données pour déterminer les paramètres des signaux vibratoires pour plusieurs défauts comme les défauts de roulement, d'engrenage et le désalignement dont le but est la validation des résultats numériques.

VI.2.1/Présentation du banc d'essai

Le banc d'essai utilisé dans cette étude est conçu par les chercheurs du laboratoire de vibration au centre de recherche de développement militaire (CRD) qui répond aux exigences des chercheurs dans le domaine de maintenance industrielle, en particulier la détection des défauts des machines tournantes par analyse vibratoire.

Il s'agit donc d'une machine se présente sous la forme d'une boîte de vitesses constituée de trois arbres rigides supportés par six roulements, et reliés entre eux par quatre pignons cylindriques à denture fabriqués en acier. La boîte est alimentée et mis en rotation par un moteur asynchrone électrique de vitesse nominale entre (1500-3000 tr/min) comme c'est présenté par la figure VI.1 ci-dessous.



Figure VI.1 : Boîte de vitesse de band d'essai

Le band essai est présenté par la figure VI.2 suivante :




Figure VI.2 : Banc d'essai

L'acquisition des données est faite à l'aide :

- Deux accéléromètres piézoélectrique a circuit intégré (ICP) en position vertical dont la gamme des fréquences est comprise entre 10Hz-10kHz qui est caractérisé par sa haute sensibilité, sa faible taille et sa réponse en fréquence élevée comme celle des machines tournantes. Un tachymètre de type optique est aussi nécessaire pour vérifier que la vitesse de rotation réelle de l'arbre est correspond avec celle affichée comme c'est présenté sur la figure VI.3.
- Une carte d'acquisitions de type NATIONAL INSTRUMENTS NI USB 4432 qui nous permet la conversion du signal analogique acquis en un signal numérique en faisant un prétraitement du signal afin de réduire le bruit et de normaliser les données comme c'est présenté sur la figure VI.3.
- Un PC pour d'une part pour sauvegarder les données et d'autre part pour avoir une gestion pratique des essais en utilisant les techniques de traitement du signal en utilisant e logiciel Matlab.



(a)

(b)

(c)

Figure VI.3 : a) Accéléromètre, b) Tachymètre, c) carte d'acquisition

VI.2.2/ Caracteristiques des défauts

a/Défaut de roulement

Les roulements utilisés dont des roulements à billes simple rangée, alésage cylindrique de marque SKF explorer 6305/2z/c3 comme c'est présenté par la figure VI.4 ci-dessous.



Figure VI.4: Roulement utilisé pour les essais de type SKF explorer 6305/2z/c3

Ses principales caractéristiques sont données par le tableau VI.1 suivant :

Tavleau VI.1 :Caracteristiques des roulements d'essais

Paramètres	Valeurs
Type de roulement	Roulement rigide à billes (simple rangée) SKF explorer 6305/2z/c3
Diamètre de bague extérieure	62 mm
Diamètre de bague inférieure	25mm (diamètre d'alésage)
Diamètre intermédiaire	43.5 mm (moyenne entre D et d)
Diamètre de bille	11.509 mm (standard pour série 6305)
Nombre des billes	7 billes
Ongle de contact	0 (roulement radial pur)
Largeur	17 mm

L'essai est réalisé en deux étapes. Tout d'abord, des essais sont effectués avec un roulement en bon état, puis un essai réalisé pour le roulement défectueux présentant une pénétration sur la bague interne à cause des chocs vibratoires comme c'est présenté sur la figure VI.5 ci-dessous :



Figure VI.5: Le roulement défectueux

b/ Défaut d'engrenage

Les pignons utilisés dans le band d'essai sont cylindriques à denture fabriqués en acier comme c'est présenté par la figure VI.6 suivante :



a) engrenage sain



b) engrenage défectueux

Figure VI.6: Les engrenages du Band d'essai


Les pignons procèdent les caractéristiques présentées par le tableau VI.2 suivant :

Tavleau VI.2 :Caracteristiques des engrenages d'essai

Paramètres	Valeurs
Nombre de dents (pignon menant)	68
Nombre de dents (pignon mené)	34
Nombre de dents (pignon mené défectueux)	1
Rapport de transmission	$\frac{1}{2}$

c/Défaut de désalignement

Le défaut de désalignement a été introduit expérimentalement dans le banc d'essai en créant un décalage contrôlé entre l'axe du moteur et celui de l'arbre entraîné. Ce défaut a été obtenu par déplacement latéral du moteur pour générer un désalignement parallèle comme c'est présenté par la figure VI.7. Les différents niveaux de désalignement ont permis d'étudier leur influence sur les signatures vibratoires du système rotatif.

**Figure VI.7: Le défaut de désalignement du Banc d'essai****VI.2.3/Présentation des résultats de l'acquisition**

Les signaux des essais représentent la signature vibratoire des défauts dans le domaine temporel et fréquentielle ainsi que les paramètres statistiques du signal temporel comme : Curtosis, RMS, le peak, la crête et l'amplitude sont faits à l'aide le code Matlab.

Les signaux vibratoires sont obtenus avec les caractéristiques de l'acquisition pour le cas sain et les différents défauts sont donnés par le tableau VI.3 :

Tavleau VI.3: Caracteristiques de l'aquisition

Parametres	Valeurs
Fréquences de resonance (Hz)	3450
Fréquence d'échantillonnage (Hz)	$5.12 \cdot 10^4$
Variation de vitesse angulaire (tr/min)	360
La durée seconde	5
Sensibilité	100
Seuil du tachymètre	0.3

Les résultats de la signature viratoire pour les différents cas sont :

a/cas sans défaut

Les signaux temporels et fréquentiels pour le cas sans défaut sont présentés par les figures VI.8, VI.9 suivantes :




Figure VI.8: Signal temporel pour le cas sans défaut




Figure VI.9: Spectre de fréquences pour le cas sans défaut

a/Cas du défaut de roulement :

Les signaux temporels et fréquentiels du défaut de roulement sont présentés par les figures VI.10, VI.11 suivantes :




Figure VI.10: Signal temporel pour le défaut de roulement




Figure VI.11: Spectre des fréquences pour le défaut de roulement

Les caractéristiques statistiques du signal temporel pour le défaut de roulement sont présentées par le tableau VI.4 suivant :

Tavleau VI.4 :Caracteristiques du signal temporel pour le défaut de roulement

Parametres	Valeurs	
	Sans défaut	Avec défaut de roulement
Kurtosis	2.506	4.147
RMS	0.0004423	0.0003489
Facteur de Crête	3.54	7.95
L'amplitude	0.06814	0.01012
Pic	0.001566	0.002774

b/Cas du défaut d'engrenage

Les résultats des signaus temporels et frequentiels pour le défaut d'egrenage sont présentés pars les figures VI.12, VI.13 suivantes :




Figure VI.12: Signal temporel pour le défaut d'engrenage




Figure VI.13: Spectre des fréquences pour le défaut d'engrenage


Les caractéristiques statistiques du signal temporel du défaut d'engrenage sont présentées par le tableau VI.5 suivant :

Tavleau VI.5 :Caracteristiques du signal temporel pour le défaut d'engrennege

Parametres	Valeurs	
	Sans défaut	Avec défaut d'engrenage
Kurtosis	2.506	6.017
RMS	0.0004423	0.001
Crete	3.54	8.348
L'amplitude	0.06814	/
Pic	0.001566	0.006

c/Cas du défaut de désalignement

Les résultats des signaus temporels et frequentiels pour le défaut de désalignement sont présentés pars les figures VI.14, VI.15 suivantes :

**Figure VI.14:** Signal temporel pour un le défaut de désalignement




Figure VI.15: Spectre des fréquences pour le défaut de désalignement

Les caractéristiques statistiques du signal temporel du défaut de désalignement sont présentées par le tableau VI.6 suivant :

Tavleau VI.6 :Caracteristiques du signal temporel pour le défaut de désalignement

Parametres	Valeurs	
	Sans défaut	Avec défaut de désalignement
Kurtosis	2.506	5.846
RMS	0.0004423	0.01697
Crete	3.54	4.277
L'amplitude	0.06814	/
Pic	0.001566	0.07256

VI.2.4/Interprétation

Analysant les résultats des tableaux VI.5,VI.6 et VI.7, on remarque que :

- le paramètre de crête est supérieur à 4 pour les trois types des défauts ce qui signifie un défaut probable par contre il est inferieur à 4 pour le cas sain ce qui valide la théorie donnée par le tableau II.2 du chapitre II.

- Pour le paramètre du Kurtosis, on remarque qu'il est supérieur à 6 pour le défaut d'engrenage ce qui signifie la présence du défaut, mais pour le cas de roulement et le désalignement le Kurtosis est entre 3-5 ce qui signifie une génération des impacts localisés. Ces impacts produisent des pics de vibration très courts mais de forte amplitude tandis que le cas sain est caractérisé par un Kurtosis de 2.5 inférieur à 3 ce qui valide la théorie donnée par le tableau II.4 du chapitre II.

Analysant les résultats des figures VI.9, VI.11, VI.13, VI.15, on remarque que :

- Pour le cas normal, on observe un pic apparaît autour de 5Hz qui correspond à la fréquence fondamentale de rotation de la machine avec une amplitude de 3.1 10g qui indique un niveau vibratoire faible et acceptable. De faibles amplitudes sont également observées aux alentours de 9Hz et 10.5HZ qui correspond à des phénomènes secondaires liés au fonctionnement normal de la machine.
- Pour le cas de défaut de roulement, le spectre est dominé par un pic principal situé autour de 5.8 HZ correspond à la fréquence fondamentale de rotation de la machine. Cependant l'apparition de plusieurs composantes fréquentielles supplémentaires notamment autour de 9HZ ce qui indique une excitation vibratoire supplémentaire liée au défaut de roulement. Ces caractéristiques constituent une signature vibratoire des défauts de roulement.
- Pour le cas du défaut d'engrenage, le spectre met en évidence plusieurs pics significatif environ 6HZ, 12Hz et 18Hz correspondant respectivement à la fréquence fondamentale et à ses harmoniques. L'amplitude élevée observée au niveau du troisième harmonique indique un endommagement localisé des dents.
- Pour le cas du désalignement, le spectre de fréquence associé présente une concentration importante de l'énergie vibratoire dans la zone des basses fréquences qui se traduit par des efforts supplémentaires imposés aux paliers et aux accouplements lorsque les axes de rotation ne sont pas parfaitement colinéaires.

VI.3/Partie numérique

La partie numérique comprend une estimation des défauts par l'intelligence artificielle en utilisant l'algorithme de l'apprentissage profond hybride (CNN-LSTM) et une validation des résultats d'apprentissage par la comparaison avec les résultats du band d'essais.

VI.3.1/ Base de données utilisée pour l'apprentissage profond

L'ensemble des signaux utilisé pour l'apprentissage a été fourni par la base de données de l'Université de Case Western Reserve (CWRU), Cleveland USA, le band d'essai et les caractéristiques des différents classes de défaut se trouve en Annexe1, (cette base de données des essais est disponible sur: [CWRU Bearing Dataset|hustcxl/Rotating-machine-fault-data-set|DeepWiki](https://hustcxl.github.io/DeepWiki/CWRU-Bearing-Dataset/)) .De nombreuses études ont été effectuées sur les signaux de la base de CWRU [55], [56], [57], dans le but d'établir une détection précoce et un diagnostic des défauts.

Les bases de données utilisées pour l'apprentissage profond pour cinq différents défauts : désalignement, déséquilibre, deux types de défaut de roulements interne (BPFI) et externe (BPFO) et l'état sain. Les mesures pour chaque bases de données sont obtenus pour trois types de chargements du moteurs : 0Nm, 2Nm, et 4Nm, et pour chaque type de chargement, on distingue plusieurs types des signaux telle qu'il est présenté par le tableau VI.7 et les figures VI.16 et VI.17 :

- Pour les classes de bases de données BPFI et BPFO : pour chaque chargement moteur les mesure s'affecte pour 3 fréquences différentes : 3KHz, 10KHz et 30KHz.
- Pour la classe de base de données désalignement : pour chaque chargement moteur les mesure s'affecte pour 3 désalignement de : 1mm, 3mm et 5mm.
- Pour la classe base de données déséquilibre : pour chaque chargement moteur les mesure s'affecte pour 5 poids : 583mg, 1169mg, 1751mg, 2239mg et 3318mg.

Tavleau VI.7: Les differentes classes du base de données

Les différentes classes de bases de données	Nombre de sous-classes	Nombre de chargement moteur pour chaque classe (0-2-4 Nm)	Nombre de label pour chaque chargement moteur
Normal	3	3	1
Désalignement	9	3	3
Déséquilibre	15	3	5
Roulement (BPFI)	9	3	3
Roulement (BPFO)	9	3	3




Figure VI.16: Les différentes classes de bases de données



Figure VI.17: Les différentes sous-classes des bases de données

Le nombre des signaux bruts et segmentés pour chaque classe sont présentés par le tableau VI.8 :

Tableau VI.8: Nombre de signaux pour les différentes classes de la base de données

Les différentes classes de bases de données	Nombre de signaux temporels bruts	Nombre de signaux temporels segmentés
Normal	3	2330
Désalignement	9	3317
Déséquilibre	15	3172
Roulement (BPFI)	9	1841
Roulement (BPFO)	9	2001

VI.3.2/L'algorithme d'apprentissage

L'algorithme hybride 1D CNN/LSTM est largement utilisé pour l'analyse et le diagnostic des signaux vibratoires des machines tournantes, car il combine la capacité du CNN (Convolutional Neural Network) à extraire automatiquement les caractéristiques importantes du signal et celle du LSTM (Long Short-Term Memory) à modéliser les dépendances temporelles du signal.

Dans le cadre de l'analyse vibratoire, le signal acquis par les capteurs accélérométriques est d'abord prétraité afin de réduire le bruit et de normaliser les données. Ensuite, le réseau CNN applique plusieurs couches de convolution sur le signal vibratoire pour détecter automatiquement les motifs caractéristiques associés aux défauts mécaniques, tels que le déséquilibre, le désalignement ou les défauts de roulements. Les couches de convolution sont généralement suivies de couches de pooling qui réduisent la dimension des données tout en conservant les informations essentielles.

Après l'extraction des caractéristiques, les données sont transmises au réseau LSTM, qui est une forme avancée de réseau de neurones récurrents (RNN). Le LSTM est spécialement conçu pour traiter les séries temporelles et mémoriser les dépendances à long terme dans les signaux vibratoires. Grâce à ses cellules de mémoire et à ses mécanismes de portes (entrée, oubli et sortie), il peut apprendre l'évolution dynamique du comportement vibratoire au cours du temps. Comme c'est présenté par la figure VI.18 ci-dessous.




Figure VI.18 : Architecture du réseau 1D CNN/LSTM [57]

L'association du CNN et du LSTM permet ainsi d'obtenir un modèle performant capable :

- d'extraire automatiquement les caractéristiques pertinentes du signal ;
- de prendre en compte la dynamique temporelle des vibrations ;
- d'améliorer la précision de classification des défauts ;
- de détecter précocement les anomalies dans les machines tournantes.

Pendant la phase d'apprentissage, 1D CNN/LSTM le modèle ajuste automatiquement ses paramètres afin de minimiser l'erreur de classification. Une fois entraîné, il peut être utilisé pour la surveillance intelligente et le diagnostic automatique des systèmes mécaniques à partir des signaux vibratoires mesurés en temps réel.

On peut résumer les étapes de calcul par l'organigramme donné par la figure VI.19 ci-dessous :




Figure VI.19 : Organigramme du processus de diagnostic des défauts [57]

VI .3.3/Résultats et interpretations

a/architecture de l'algorithme d'apprentissage

La partie numérique est une implémentation sur le logiciel Matab qui consiste à faire une classification des défauts à partir des sigaux vibratoires 1D en utilisant l'algorithme hybride de l'apprentissage profond CNN-LSTM. Afin de maximiser l'efficacité des algorithmes

d'apprentissage, une phase rigoureuse de traitement de signal a d'abord été menée pour éliminer les bruits parasites et isoler l'information utile. Les signaux ainsi nettoyés ont été divisés sous forme de segments temporels, puis transformés avec succès sous forme d'images (représentations temps-fréquence), permettant de convertir un problème temporel unidimensionnel en une structure bidimensionnelle exploitable par vision artificielle. Les étapes de calcul se résume par l'architecture hybride CNN-LSTM donné parla figure VI.20 ci-dessous :




Figure VI.20 : l'architecture hybride CNN-LSTM pour classification des défauts

Cette figure représente une architecture hybride CNN-LSTM utilisée pour la classification des défauts des machines tournantes à partir des signaux vibratoires 1D qui combine :

- Une entrée : qui est un trançent du signal temporel 1D brute ;
- CNN (Convolutional Neural Network) : utilisé pour extraction automatique des caractéristiques locales du signal ;
- LSTM (Long Short-Term Memory) : utilisé pour apprentissage des dépendances temporelles ;
- Couche de classification : utilisée pour la décision finale sur le type de défaut ;
- Une sortie : qui se divise en cinq catégories de défauts.

Cette architecture hybride donne :

- meilleure précision ;
- robustesse au bruit ;
- meilleure détection des défauts vibratoires.

a.1/L'entrée

Le model reçoit 2048 points (fenêtre passante de 2048 points) du signal temporel brut 1D. Le modèle est de dimension 1×2048 .

a.2/CNN

Cette étape est constituée de trois blocs CNN :

- CNN 1: cette couche applique 16 filtre avec une taille de 32 pour extraire les premier signatures des défauts comme les pics, les impulsions... et la réduction de dimension à 16×512 en utilisant la fonction d'activation ReLU et un MaxPooling de taille 4.
- CNN 2: cette couche applique 32 filtre avec une taille de 16 pour extraire les plus complexes caractéristiques et la réduction de dimension de la taille temporelles à 32×128 en utilisant la fonction d'activation ReLU et un MaxPooling de taille 4.
- CNN 3: cette couche applique 64 filtre avec une taille de 8 pour extraire les caractéristique des défauts d'une manière spécifiques et la réduction de dimension à 64×64 en utilisant la fonction d'activation ReLU et un MaxPooling de taille 2.

a.3/LSTM

Le bloc LSTM mémorise l'évolution du signal dans le temps et dans cet exemple on utilise 128 unités mémoire et un dropout de 0.4 c'est-à-dire 4%des neurones sont désactivés aléatoirement pour éviter le surapprentissage (overfitting).

a.4/Couche de classification

Dans ce bloc on utilise un réseau de neurone constitué par six neurones totalement connectés avec la fonction d'activation Softmax en utilisant l'algorithme de la retro propagation avec une optimisation de l'erreur par la décente de gradient ;

a.5/La sortie

Le réseau classe le signal dans 5 catégories :

1. Normal ;
2. Déséquilibre ;
3. Désalignement ;
4. BPFI ;
5. BPFO .

b/La matrice de confusion

La matrice de confusion sert à évaluer les performances du modèle de classification des défauts en comparant les vraies classes avec les classes prédites. Pour une bonne classification les valeurs se trouvent sur la diagonale, et la mauvaise classification se trouve hors diagonale comme c'est prêté par la figure VI.21.




Figure VI.21 : La matrice de confusion

Analysant la matrice de convolution, on distingue que notre modèle est très performant car presque toutes les valeurs sont sur la diagonal et peu de valeurs hors la diagonale tel que :

- Pour la classe BPFI :1832 signaux corrects 9 signaux mal reconnu ;
- Pour la classe BPFO :1999 signaux corrects 2 signaux mal reconnu ;
- Pour la classe désalignement :3317 signaux corrects 0 signal mal reconnu ;
- Pour la classe déséquilibre :3166 signaux corrects 6 signaux mal reconnu ;
- Pour la classe normal :2329 signaux corrects 1 signaux mal reconnu.

Donc, cela signifie qu'il y'a une excellente précision et classification, les erreurs sont faibles et limitées principalement au désalignement et que la CNN-LSTM apprend correctement les signatures vibratoires car la CNN extrait les fréquences et les impulsions locale et la LSTM apprend l'évolution temporelle des signaux vibratoires.

c/Les courbes d'apprentissage

Les courbes d'apprentissage se divisent à deux courbes principales: la courbe de précision (accuracy) et la courbe d'erreurs (loss) comme c'est présenté par la figure VI.22 ci-dessous :




Figure VI.22 : Les courbes d'apprentissage

La base de donnée est subdivisée en trois parties d'une manière aléatoire dont :

- 70% de données sont dédiées pour l'apprentissage ;
- 15% dédiées pour le test ;
- 15% pour la validation.

c.1/La courbe de précision

On remarque que la courbe de précision en fonction des itérations au début est faible car le modèle ne connaît pas encore les données, puis la précision augmente rapidement et enfin se stabilise proche de 98.86% en 23730 itérations (30 cycles) avec un taux d'apprentissage de 0.001 et un temps totale d'entraînement de 312 minutes. Cela signifie que le modèle apprend efficacement et prouve une excellente classification avec une convergence stable.

c.1/La courbe d'erreur

On remarque qu'au début la courbe est élevée puis elle diminue rapidement et finalement elle se stabilise vers 0 en 23730 itérations (30 cycles) avec un taux d'apprentissage de 0.001 et

un temps total d'entraînement de 312 minutes et cela signifie que l'apprentissage est très efficace avec une bonne convergence.

On remarque aussi que pour les courbes d'apprentissage, les deux courbes de d'entraînement et de validation sont très proches qui signifie qu'il n'y'a pas un surapprentissage (overfittig) important et le modèle fonctionne aussi pour de nouvelles données.

Donc notre modèle CNN-LSTM converge rapidement et apprend efficacement les caractéristiques vibratoires avec une erreur proche à 0 et une précision de 99.86% et cela signifie que le modèle présent une excellente capacité de généralisation.

VI.3.4/Validation

Notre modèle CNN-LSTM valide d'une manière très efficace nos résultats du band d'essai en faisant une bonne classification des signaux sain et avec défaut de roulement et le désalignement.

VI.4/Conclusion

On peut conclure que le modèle d'apprentissage profond hybride CNN-LSTM est très performant pour faire un excellent diagnostic des défauts des machines tournantes car il converge rapidement et apprend efficacement les caractéristiques vibratoires avec une erreur proche à 0 et une précision de 99.86% et cela signifie que le modèle présent une excellente capacité de généralisation qui a été prouvé par la validation de nos résultats du band d'essai.

Conclusion Générale

Conclusion Générale

Ce projet de fin d'études s'articule autour de la surveillance prédictive et de l'identification automatisée de pathologies au sein des machines tournantes par le biais de l'intelligence artificielle (IA). L'enjeu majeur consistait à concevoir implémenter et valider une approche hybride innovante et performante pour la maintenance prédictive industrielle avec un dispositif de diagnostic précoce capable de détecter et de classifier des anomalies critiques, telles que les défaillances de roulements et d'engrenages, de désalignement et le déséquilibre à un stade précoce.

Tout d'abord, nous avons présenté le domaine de la maintenance préventive des machines tournantes, en exposant un certain nombre des défaillances majeures susceptibles altérer le fonctionnement de ces machines.

Une classification des approches de surveillance dédiées à la recherche de défauts a été dressée, avec un intérêt particulier pour les approches sans modèle, notamment le diagnostic basé sur les méthodes exploitant les données capteur provenant de différentes sources d'information. Une attention particulière a été donnée à l'analyse vibratoire, en décrivant et détaillant les principales méthodes d'exploitation et de traitement de l'information vibratoire.

Le cœur de notre méthodologie a reposé sur l'exploitation des bases de données de l'Université de Case Western Reserve (CWRU), contenant des signaux vibratoires riches et complexes. Afin de maximiser l'efficacité des algorithmes d'apprentissage, une phase rigoureuse de traitement de signal a d'abord été menée pour éliminer les bruits parasites et isoler l'information utile. Les signaux ainsi nettoyés ont été divisés sous forme de segments temporels, puis transformés avec succès sous forme d'images (représentations temps-fréquence), permettant de convertir un problème temporel unidimensionnel en une structure bidimensionnelle exploitable par vision artificielle.

La valeur ajoutée de notre contribution réside dans le développement d'une architecture profonde hybride combinant les réseaux de neurones convolutifs (CNN), qui ont assuré l'extraction automatique et pertinente des caractéristiques spatiales et géométriques des images vibratoires, aux réseaux LSTM (Long Short-Term Memory), qui ont capturé avec précision la dynamique évolutive et temporelle des dégradations tout en affinant les résultats pour maximiser l'exactitude du diagnostic.

Dans le cadre de ce travail, des essais expérimentaux menés sur le banc d'essai du laboratoire de vibrations au centre de recherche et développement militaire CRD, ont permis de constituer notre propre base de données pour évaluer la pertinence de nos approches en intelligence artificielle.

Les résultats obtenus en partie expérimentale montrent :

Le signal temporel montre que :

- Le paramètre de crête est supérieur à 4 pour les trois types des défauts ce qui signifie un défaut probable par contre il est inférieur à 4 pour le cas sain ce qui valide la théorie.
- Le paramètre du Kurtosis, on remarque qu'il est supérieur à 6 pour le défaut d'engrenage ce qui signifie la présence du défaut, mais pour le cas de roulement et le désalignement le Kurtosis est entre 3-5 ce qui signifie une génération des impacts localisés. Ces impacts produisent des pics de vibration très courts mais de forte amplitude tandis que le cas sain est caractérisé par un Kurtosis de 2.5 inférieur à 3 ce qui valide aussi la théorie.

Le spectre de fréquences montre que :

- Pour le cas normal, on observe un pic apparaît autour de 5Hz qui correspond à la fréquence fondamentale de rotation de la machine avec une amplitude de 3.1 10g qui indique un niveau vibratoire faible et acceptable.
- Pour le cas de défaut de roulement, le spectre est dominé par un pic principal situé autour de 5.8 HZ correspond à la fréquence fondamentale de rotation de la machine. Cependant l'apparition de plusieurs composantes fréquentielles supplémentaires notamment autour de 9HZ ce qui indique une excitation vibratoire supplémentaire liée au défaut de roulement. Ces caractéristiques constituent une signature vibratoire des défauts de roulement.

- Pour le cas du défaut d'engrenage, le spectre met en évidence plusieurs pics significatif environ 6Hz, 12Hz et 18Hz correspondant respectivement à la fréquence fondamentale et à ses harmoniques. L'amplitude élevée observée au niveau du troisième harmonique indique un endommagement localisé des dents.
- Pour le cas du désalignement, le spectre de fréquence associé présente une concentration importante de l'énergie vibratoire dans la zone des basses fréquences qui se traduit par des efforts supplémentaires imposés aux paliers et aux accouplements lorsque les axes de rotation ne sont pas parfaitement colinéaires.

Les résultats obtenus en partie numérique montrent :

- La matrice de convolution distingue que notre modèle est très performant car presque toutes les valeurs sont sur la diagonal et peu de valeurs hors la diagonale. Cela signifie qu'il y'a une excellente précision et classification, les erreurs sont faibles et limitées principalement au désalignement et que la CNN-LSTM apprend correctement les signatures vibratoires car la CNN extrait les fréquences et les impulsions locale et la LSTM apprend l'évolution temporelle des signaux vibratoires.
- La courbe de précision en fonction des itérations au début est faible car le modèle ne connaît pas encore les données, puis la précision augmente rapidement et enfin se stabilise proche de 98.86% en 23730 itérations (30 cycles) avec un taux d'apprentissage de 0.001 et un temps totale d'entraînement de 312 minutes. Cela signifie que le modèle apprend efficacement et prouve une excellente classification avec une convergence stable.
- La courbe d'erreur au début est élevée puis elle diminue rapidement et finalement elle se stabilise vers 0 en 23730 itérations (30 cycles) avec un taux d'apprentissage de 0.001 et un temps total d'entraînement de 312 minutes et cela signifie que l'apprentissage est très efficace avec une bonne convergence.
- Les deux courbes de d'entraînement et de validation sont très proches qui signifie qu'il n'y'a pas un surapprentissage (overfittig) important et le modèle fonctionne aussi pour de nouvelles données.

On peut conclure que le modèle d'apprentissage profond hybride CNN-LSTM est très performant pour faire un excellent diagnostique des défauts des machines tournantes car il converge rapidement et apprend efficacement les caractéristiques vibratoires avec une

erreur proche à 0 et une précision de 99.86% et cela signifie que le modèle présent une excellente capacité de généralisation qui a été prouvé par la validation de nos résultats du band d'essai.

Perspective et recommandation :

Comme perspective à cette étude, les travaux suivants peuvent être proposés :

- Traiter le cas des défauts combinés;
- Traiter le cas des signaux 2D ;
- Etudier d'autre algorithmes d'apprentissage profond comme les réseaux antagonistes génératifs (GAN) ;
- Utilisation du traitement du signal avancé comme la transformation en Odelettes.

ANNEXES

ANNEXE 1

Banc d'essai utilisé pour l'acquisition des signaux de (CWRU)

En exploitant des bases de données publiques largement reconnues, telles que la base de données **Case Western Reserve University (CWRU)**, dans le diagnostic des défauts et la surveillance de l'état des machines. Les bases de données sélectionnées fournissent des informations vibratoires variées provenant de différents types de roulements, de multiples scénarios de défauts et de diverses conditions de fonctionnement. Cette diversité permet le développement de modèles capables de généraliser leurs performances à un large éventail d'applications industrielles.

Cette base de données a joué un rôle majeur dans le développement des modèles d'apprentissage automatique profond, en particulier des réseaux de neurones convolutifs (CNN) et LSTM, appliqués aux tâches de diagnostic des défauts.

Les données CWRU sont acquises à des fréquences d'échantillonnage de **12 000 Hz** et **48 000 Hz**, avec une durée d'enregistrement de **10 secondes** par échantillon. Les vitesses de rotation varient généralement entre **1 720 tr/min** et **1 797 tr/min**.

Le banc d'essai utilisé pour la collecte des données est composé :

- d'un moteur électrique ;
- d'un arbre de transmission ;
- d'un accouplement ;
- d'un dynamomètre permettant de contrôler les différentes charges appliquées au système.

Les roulements testés dans le cadre du jeu de données CWRU sont :

- un roulement à billes à gorge profonde **SKF 6205-2RS** monté du côté entraînement (*Drive End*) ;
- un roulement à billes à gorge profonde **SKF 6203-2RS** monté du côté ventilateur (*Fan End*).




Figure 1: Banc d'essai utilisé pour l'acquisition des données vibratoires du jeu de données CWRU (*Case Western Reserve University, Apparatus & Procedures*, 2021).

ANNEXE 2

Interfaces Matlab de l'acquisition de données




Figure 1: Interface Matlab de l'acquisition pour le cas normal




Figure 2: Interface Matlab de l'acquisition pour le cas du défaut de roulement




Figure 3: Interface Matlab de l'acquisition pour le cas du défaut de désalignement

Références

Références

- [1] Boulenger, A. (2007), Maintenance conditionnelle par analyse des vibrations, Les Techniques de l'Ingénieur, base documentaire.
- [2] Lyonnet, P., Thomas, M., & Toscano, R. (2012), Fiabilité, Diagnostic et Maintenance des systèmes industriels. Éditions Ellipses.
- [3] Khelil, A & Fadel, I. (2024). Contribution au diagnostic intelligent des défauts dans les machines tournantes [Mémoire d'ingénieur, EMP - Alger].
- [4] Magraoui, R. (2011). Diagnostic de quelques cas de machines tournantes par l'analyse vibratoire [Mémoire de magister, Université de Blida].
- [5] Hadj Said, B. (2009). Détection des défauts d'engrenage des machines tournantes par les méthodes d'analyse vibratoire et expérimentale [Mémoire de magister, ENP d'Alger]. (Idéal pour sourcer la description des arbres de transmission et des roues dentées).
- [6] Boumahdi, M. (2011). Développement d'un système expert pour le diagnostic des machines tournantes [Thèse de doctorat, ENP d'Alger]. (Dans ses premiers chapitres, il dresse une classification claire des types de machines pour son arborescence de diagnostic).
- [7] Bouhalais, M. L. (2020). Développement et mise en œuvre d'outils de surveillance des machines tournantes par analyse vibratoire en régime variable [Thèse de doctorat, Université de Guelma].
- [8] Bessous, N. (2017). Contribution au Diagnostic des Défauts dans les Machines Asynchrones : Comparaison entre l'Analyse Vibratoire et l'Analyse du Courant d'Alimentation [Thèse de doctorat, Université de Biskra].
- [9] Karef, M. S. (2019). Etude comparative entre MCSA et analyse vibratoire pour le diagnostic d'un moteur asynchrone [Mémoire de magistère, USTO-MB].
- [10] Merah, K. (2016). Diagnostic des défauts de roulement d'un moteur par analyse vibratoire (Etude comparative avec l'analyse du courant statorique) [Mémoire de magistère, USTO-MB]. (Discute des pertes énergétiques et du comportement global du moteur).
- [11] De Fornel, B., & Sabonnadière, J. C. (2002). Machines électriques tournantes : Principes de base et constitution. Techniques de l'Ingénieur.
- [12] Abdelkader, R. (2019). Contribution au diagnostic de défauts de roulements par analyses de signaux vibratoires [Thèse de doctorat, USTO-MB]. (Excellente base sur la physique de la création des chocs et des vibrations mécaniques).
- [13] Djebala, A. (2008). Application de la transformée par ondelettes à l'étude et l'analyse vibratoire des systèmes mécaniques [Thèse de doctorat, Université de Annaba]. (Traite de la nature non-stationnaire des phénomènes physiques associés).
- [14] Moumene, I. (2010). Identification des défauts mixtes d'engrenage et de roulement par analyse vibratoire [Mémoire de magister, Université de Guelma]. (Pour les interactions physiques et frottements lors de défauts combinés).

- [15] Ounoughi, S. E. (2020). Diagnostic des défauts de machines tournantes par analyse vibratoire : Surveillance et diagnostic des défauts de roulements par analyse spectrale [Mémoire d'ingénieur, ENP d'Alger].
- [16] Mellel, N. (2016). Etude et Identification des Problèmes de Vieillessement des Structures Tubulaires par Analyse vibratoire [Thèse de doctorat, Université Blida 1].
- [17] Belaid, S. (2023). Maintenance conditionnelle par analyse vibratoire : application aux roulements à bille [Thèse de doctorat, Université de Boumerdes].
- [18] Zarour, D. (2019). Approche numérique et expérimentale d'aide à la détection des défauts dans le cadre d'une maintenance préventive conditionnelle par l'analyse vibratoire : application aux roulements [Thèse de doctorat, Université de Constantine].
- [19] Girdhar, P & Scheffer, C. (2004). Practical machinery vibration analysis and predictive maintenance. Newnes (Elsevier Science).
- [20] Dufour, R., & Chatelet, E. (2010). Dynamique des rotors : Modélisation et comportement vibratoire. Techniques de l'Ingénieur, traité Génie mécanique.
- [21] Lalonde, S., & Guilbault, R. (2008). Modélisation de la rigidité d'engrènement des roues dentées fissurées. Journal of Mechanical Design, 130(7), 072601.
- [22] Lavoie, J. (2004). Analyse de l'impact des paramètres géométriques des fissures de fatigue sur la rigidité des engrenages (Mémoire de maîtrise, École de technologie supérieure, Montréal).
- [23] Pachaud, C., Salvétat, R., & Fray, C. (1997). Crest factor and kurtosis contributions to bearings condition monitoring. Condition Monitoring, 97, 41-52.
- [24] (Association Française de Normalisation [AFNOR], 2001) pour la première fois, puis (AFNOR, 2001) pour les suivantes.
- [25] McCarthy, J. (2007). From here to human-level AI. Artificial Intelligence, 171(18), 1174–1182. <https://doi.org/10.1016/j.artint.2007.10.009>
- [26] Russell, S., & Norvig, P. (2020). Artificial intelligence : A modern approach (4e éd.). Pearson.
- [27] Choug, A. (2022). Détection et analyse vibratoire pour le diagnostic des systèmes électromécaniques (Publication No. 2022-ANN) [Thèse de doctorat, Université Badji Mokhtar - Annaba].
- [28] Azencott, C.-A. (2018). Introduction au Machine Learning. Dunod. <https://www.dunod.com/sciences-techniques/introduction-au-machine-learning-0>
- [29] Lei, Y. (2016). Intelligent fault diagnosis and remaining useful life prediction of rotating machinery. Butterworth-Heinemann.
- [30] Dahmane, K. (2020). Analyse d'images par méthode de Deep Learning appliquée au contexte routier en conditions météorologiques dégradées [Thèse de doctorat, Université Clermont Auvergne]. HAL Open Science. <https://tel.archives-ouvertes.fr/tel-03022934>
- [31] Dreyfus, G. (Dir.). (2004). Réseaux de neurones : Méthodologie et applications (2e éd.). Eyrolles.
- [32] Widrow, B., & Lehr, M. A. (1990). 30 years of adaptive neural networks: Perceptron, Madaline, and backpropagation. Proceedings of the IEEE, 78(9), 1415–1442. <https://doi.org/10.1109/5.58323>
- [33] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. The Bulletin of Mathematical Biophysics, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- [34] Bataoui, R., & Bahloul, S. (2023). Maintenance et caractérisation des anomalies par CND à base des réseaux de neurones (Mémoire de Master en Aéronautique, option Structure). Institut d'Aéronautique et des Études Spatiales (IAES), Université Saad Dahlab de Blida I, Algérie.

- [35] Rezgane, A., & Bedda, M. R. (2023). Détection et classification des défauts dans les réseaux électriques par les réseaux de neurones [Mémoire de Master académique, Université Kasdi Merbah Ouargla].
- [36] Abbassi, A., & Meddeur, A. (2015). Application des réseaux de neurones pour la caractérisation géométrique et physique d'une plaque conductrice [Mémoire de Master académique, Université Kasdi Merbah Ouargla].
- [37] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [38] Al-Mushiaa, M. M., & Aoukli, Z. (2022). Technique de diagnostic des défauts dans les systèmes électriques par les réseaux de neurones (machine asynchrone) [Mémoire de Master, Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj].
- [39] Harouz, A. (2015). Reconstitution de défauts complexes avec la méthode des réseaux de neurones. Application pour l'évaluation non destructive (Mémoire de Master académique, Université Mouloud Mammeri de Tizi-Ouzou). FGEI / Département d'Électrotechnique
- [40] Azencott, C.-A. (2018). Introduction au Machine Learning. Dunod.
- [41] Dahmane, K. (2020). Analyse d'images par méthode de Deep Learning appliquée au contexte routier en conditions météorologiques dégradées (Publication No. 2020CLFAC020) [Thèse de doctorat, Université Clermont Auvergne]. HAL Open Science.
- [42] Özgenel, Ç. F. (2018). Crack detection with deep learning: An exemplary study of data design in architecture [Unpublished doctoral dissertation]. Middle East Technical University.
- [43] Dreyfus, G. (2023). Réseaux de neurones : Méthodologie et applications (2e éd.). Eyrolles. (Utilisé pour valider la formalisation mathématique de la somme pondérée, l'intégration du biais comme entrée augmentée et la formulation algébrique générale — Équations III.1, III.2 et III.4).
- [44] Azencott, C.-A. (2012). Introduction au Machine Learning. Dunod. (Utilisé pour sourcer la définition de la fonction d'activation et la sortie du neurone — Équation III.3).
- [45] Goodfellow, I., Bengio, Y., & Courville, A. (2018). L'apprentissage profond (A. Blouet, Trad.). Massot Éditions. (Ouvrage original publié en 2016 chez MIT Press). (Utilisé pour appuyer la démonstration mathématique sur la nécessité de la non-linéarité pour éviter l'effondrement d'un réseau profond en une simple transformation linéaire).
- [46] Minsky, M., & Papert, S. (1969). Perceptrons : An introduction to computationnel géométry. MIT Press. (Référence historique incontournable, utilisée pour appuyer la démonstration des limitations théoriques du perceptron monocouche face aux problèmes non linéairement séparables).
- [47] Ghessab, F. Z. (2011). Application des réseaux de neurones dans la prévision du comportement des ponts renforcés par matériaux composites (Mémoire de Master II, Université Saad Dahleb de Blida, Algérie).
- [48] Bataoui Rania, Bahloul Sirine,(2023), Maintenance et Caractérisation des Anomalies par CND à Base des Réseaux de Neurones, [Master e Aéronautique et projet startup, Université de Blida I].
- [49] Oukacine Nassima (2012). Utilisation des réseaux de neurones pour la reconstitution de défauts en évaluation non destructive,[Mémoire de Magister en électrotechnique , Université Mouloud Mammeri de Tizi-ouzou]
- [50] Boulenger, A. (2004). Maintenance conditionnelle par analyse des vibrations. *Techniques de l'Ingénieur*, Réf. [mt9285].
- [51] Augeix, D. (2010). Analyse vibratoire des machines tournantes. *Techniques de l'Ingénieur*, Réf. [BM 5 145].

- [52] Karef, M. S. (2019). Etude comparative entre MCSA et analyse vibratoire pour le diagnostic d'un moteur asynchrone (Mémoire de magistère en électrotechnique). Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf (USTO-MB), Oran, Algérie.
- [53] Hadj Said, B. (2009). Détection des défauts d'engrenage des machines tournantes par les méthodes d'analyse vibratoire et expérimentale [Mémoire de magister, École Nationale Polytechnique d'Alger].
- [54] Mellel, N. (2016). Etude et Identification des Problèmes de Vieillessement des Structures Tubulaires par Analyse vibratoire [Thèse de doctorat, Université Blida 1]
- [55] Mert Sehri ; al, (2025), "Towards a Universal Vibration Analysis Dataset: A Framework for Transfer Learning in Predictive Maintenance and Structural Health Monitoring", International Journal of Prognostics and Health Management, ISSN 2153-2648, 2025.
- [56] Vijayalakshmi K, Amuthakkannan Rajakannu Intelligent, (2024), "Fault Diagnosis of Rotating Machinery Using Deep Learning Algorithms: A Comparative Analysis of MLP, CNN, RNN, and LSTM", International Journal of Electrical and Electronics Engineering, Volume 11 Issue 9, 294-315, September 2024.
- [57] Fasikaw Kibrete, Dereje Engida Woldemichael, (2025), "Fault Diagnosis of Rotating Machines Based on Combination of One-Dimensional Convolutional Neural Network and Long Short-Term Memory in Variable Working Conditions", Wiley Journal of Engineering, Volume 2025, Article ID 1670810, 13 pages.
- [58] Elara Vandermeer, Kairav Mahadevan, (2025), Disease Prediction Using Electronic Health Records with Long Short-Term Memory Networks, Journal of Computer Technology and Software, ISSN:2998-2383 Vol. 4, No. 1, 2025.
- [59] <https://www.pei-france.com/article/alternateur-industriel-avec-des-performances-accrues-et-un-systeme-de-refroidissement-optimize/>
- [60] https://www.researchgate.net/figure/Figures-9a-b-c-Temperature-distribution-inside-motor-1-Total-input-power-263W_fig3_295105988
- [61] <https://itafran.com/choisir-le-bon-engrenage/>
- [62] <https://www.aubearing.com/fr/the-ultimate-guide-to-causes-of-bearing-failure/>
- [63] <https://fr.wikidid.org/wiki/Neurone>