

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique
جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA
كلية التكنولوجيا
Faculté de Technologie
قسم الآلية والكهروتقني
Département d'Automatique et Électrotechnique



Mémoire de Master

Filière Électrotechnique
Spécialité Machines électriques

Présenté par

CHEROUATI ASMAA YAMINA

et

AMMADI CHAIMA

**Développement d'une Solution à base de L'Intelligence Artificielle
pour la prédiction des défauts machines à partir du Son émis
lors de la rotation**

2024/2025



Remerciements

Louange à Allah, seigneur des mondes, qui nous a accordé la santé et la détermination nécessaires pour mener à bien ce travail de recherche, et qui nous a permis de l'achever comme il se doit.

Nous souhaitons exprimer notre profonde gratitude à notre encadrant, Monsieur HACHLAF.R pour son encadrement rigoureux, ses conseils précieux et sa disponibilité tout au long de la réalisation de ce travail. Son accompagnement a grandement contribué à l'orientation et à la qualité de ce mémoire.

Enfin, nous remercions toutes les personnes qui ont contribué, de près ou de loin, à l'enrichissement de ce travail, en priant le tout-puissant de les récompenser généreusement et de faire que cela pèse dans la balance de leurs bonnes actions.





Dédicace 1

Louange à Allah, source de paix et de force, par Sa grâce infinie ce chemin a été illuminé.

À moi-même, pour n'avoir jamais abandonné malgré les défis. Ce diplôme est le fruit de ta persévérance. Sois fière de toi.

À ma tendre mère, nul mot ne suffit à dire ce que je te dois. Ton amour m'a construite, ton courage m'a inspirée, et tes prières m'ont portée. Qu'Allah t'accorde longue vie et sérénité.

À mon époux bien-aimé, ton amour a été mon abri, ton soutien mon appui constant. À travers les tempêtes et les silences, tu as cru en moi. Ce succès est autant le tien que le mien. Qu'Allah te protège et t'élève toujours.

À mon fils Joud, lumière de mes jours et douceur de mes nuits, ton innocence m'a rappelé chaque jour pourquoi je persévère. Ce diplôme est une promesse d'avenir pour toi, un premier pas que je dédie à ton sourire.

À ma belle-famille, merci pour l'accueil, les encouragements et la bienveillance. Vous êtes devenus ma seconde famille, un havre de paix et de chaleur.

À ma sœur Fatima, ton amour m'accompagne comme une étoile fidèle. Tes paroles réconfortantes et ta présence sont des cadeaux précieux.

À ma complice Raziqa, ton soutien silencieux et ta tendresse sont gravés dans mon cœur. Merci d'être là, tout simplement.

À mon père, ma fierté et mon exemple grâce à tes prières, j'ai tenu bon, et grâce à ton amour, j'ai avancé.

Enfin, à tous ceux qui m'ont tendu la main, offert un sourire ou une parole douce au bon moment, soyez bénis.

Avec toute ma gratitude et mon amour sincère.

AMMADI CHAIMA





Dédicace 2

*Je rends grâce à dieu de m'avoir rendu une personne rêveuse avec une grande ambition
Je dédie ce modeste travail :*

A la mémoire de mon père,

Décède trop tôt, qui m'a toujours pousse et motive dans mes études, J'espère que, du monde qui est sien maintenant, il apprécie cet humble geste comme preuve de reconnaissance de la part de sa fille qui a toujours prie pour le salut de son âme. Puisse Dieu, le tout Puissant, l'avoir en sa sainte miséricorde.

A ma chère mère,

Aucune dédicace ne saurait exprimer mon respect, mon amour Eternel et ma considération pour ses innombrables sacrifices. Puisse Dieu, le plus Haut, Accorder sante, bonheur et longue vie.

A ma professeure Naoual Cheggaga,

Pour sa bienveillance, sa disponibilité et ses conseils précieux qui ont grandement contribue à la réalisation de ce travail.

A mes chers frères, Omar, Abderrahmane, Abdeslam,

Pour leur soutien moral, leur présence rassurante et parce qu'ils sont la source de mes efforts, de ma joie et de mon bonheur; Je les aime profondément car ils m'ont toujours soutenue et encouragée tout au long de ma vie.

CHEROUATI ASMAA YAMINA



Résumé

Ce mémoire présente le développement d'un système intelligent visant à détecter et prédire les défauts des machines électriques à travers l'analyse des sons produits pendant leur fonctionnement. Cette méthode repose sur l'extraction de caractéristiques pertinentes du signal acoustique, associée à un réseau de neurones convolutifs (CNN) capable de classer différents types d'anomalies, qu'elles soient mécaniques ou électriques. L'objectif est de proposer une solution de contrôle non destructif, non intrusive, en temps réel et à faible coût, adaptée à la maintenance industrielle.

Mots-clés :

Artificiel intelligent, détection de défauts, prédiction, machine électrique, analyse acoustique, réseau de neurones convolutifs (CNN), contrôle non destructif (CND), maintenance industrielle

Abstract

This thesis presents the development of an intelligent system designed to detect and predict faults in electric motors through the acoustic analysis of the sounds produced during their operation. The method is based on extracting relevant features from the audio signal, combined with a convolutional neural network (CNN) capable of classifying various types of anomalies, whether mechanical or electrical. The goal is to offer a non-destructive, non-intrusive, real-time, and cost-effective solution tailored to the needs of industrial maintenance.

Key words:

Intelligent artificial, fault detection, prediction, electrical machines, acoustic analysis, convolutional neural network (CNN), non-destructive testing (NDT), industrial maintenance

الملخص

يعرض هذا البحث تطوير نظام ذكي يهدف إلى كشف وتوقع أعطال المحركات الكهربائية من خلال تحليل الأصوات الصادرة أثناء تشغيلها. تعتمد هذه الطريقة على استخراج خصائص هامة من الإشارة الصوتية، بالتكامل مع شبكة عصبية قادرة على تصنيف أنواع مختلفة من الأعطال سواء كانت ميكانيكية أو كهربائية. يهدف هذا النهج إلى (CNN) التفافية تقديم حل للمراقبة غير التدميرية، غير التداخلية، يعمل في الوقت الحقيقي وذو تكلفة مناسبة، يلبي متطلبات الصيانة الصناعية.

الكلمات المفتاحية

، الكشف عن الأعطال، التنبؤ، المحركات الكهربائية، التحليل الصوتي، الشبكة العصبية الالتفافية ، الصيانة الصناعية (NDT) الذكاء الاصطناعي، الفحص غير التدميري (CNN)

Remerciements.....	VI
Dédicace 1.....	VI
Dédicace 2.....	VI
Résumé.....	VI
SOMMAIRE.....	VI
LISTE DES FIGURES.....	VI
LISTE DES ABREVIATIONS.....	VI
LISTE DES TABLEAUX	VI
Introduction Générale.....	1
1.1 Introduction	4
1.2 Contrôle non destructif (CND) :	4
• Principes fondamentaux du contrôle non destructif (CND) :	5
• Les principaux objectifs du CND	6
1.3 Nature des défauts internes et leur influence sur l'intégrité des matériaux	6
1.4 Méthodes principales du contrôle non destructif (CND).....	7
• Méthodes acoustiques	7
• Contrôle par sons	7
• Contrôle par ultrasons (UT – Ultrasonic Testing).....	7
• Émission acoustique (AE – Acoustic Emission).....	7
• Méthodes électromagnétiques	8
• Courants de Foucault (ET – Eddy Current Testing)	8
• Magnétoscopie (MT – Magnetic Particle Testing)	8
• Méthodes chimiques.....	8
• Resuage (PT – Penetrant Testing).....	8
• Radiographie (RT – Radiographic Testing)	8
1.5 Mise en œuvre d'un système de Contrôle Non Destructif (CND)	9
• Caractérisation des matériaux	9
• Détection et localisation des défauts	10
• Caractérisation et analyse des défauts	10
• Interprétation des résultats et prise de décision.....	10
1.6 Critères de sélection d'une technique de CND	11
1.7 Perspectives et innovations	11
• 1.8 Conclusion :	12
2.1 Introduction	15
2.2 Les éléments d'une machine électrique :.....	15
• L'inducteur	15
• L'induit :.....	15
• L'arbre de transmission :	16
	VI

• Le collecteur (dans les machines à courant continu) :.....	16
• Les balais (ou charbons) :	16
• Le carter (ou enveloppe du machine) :.....	16
• Le système de refroidissement (optionnel).....	16
• Les roulements.....	17
2.3 Les types de roulements dans une machine électrique :	17
• Roulement à billes :.....	17
• Roulement à rouleaux cylindriques :	17
• Roulement conique (ou à rouleaux coniques) :	18
• Roulement à aiguilles :.....	18
• Roulement à contact oblique	18
• Palier lisse :	18
2.4 Défauts dans les roulements à billes :	19
• Défauts de la bague intérieure (inner ring defects).....	20
• Défauts de la bague extérieure (outer ring defects)	21
• Défauts des éléments roulants (billes)	21
2.5 Fréquences caractéristiques	22
• Détection et diagnostic :.....	23
2.6 Les principales raisons du mal fonctionnement des roulements à billes.....	24
• La corrosion.....	24
• Le défaut d'alignement.....	24
• La charge axiale inversée	24
• Les renforcements.....	25
• La surchauffe.....	25
2.7 Surveillance et entretien des roulements en maintenance préventive	25
• Méthodes de surveillance	25
• Détection des bruits.....	25
• Mesure de température.....	26
• Méthode d'observation	27
• Détecteur de vibrations.....	28
2.8 Conclusion.....	29
3.1 Introduction	31
3.2 Le réseau de neuronal artificiel.....	31
• Les éléments constitutifs d'un réseau de neurones artificiel :	31
• Les neurones (ou nœuds) :.....	31
• Les couches :	32

• Les poids synaptiques :	32
• Les biais :	32
• Les fonctions d'activation :	32
• La fonction de perte (ou fonction coût) :	32
3.3 Réseaux convolutifs (CNN – Convolutional Neural Networks) :	33
• Avantages et limites.....	34
• Avantages	34
• Limites.....	34
• Applications en traitement d'image	34
3.4 Structure d'un réseau de neurones convolutif (CNN - Convolutional Neural Network) :	34
• Couche d'entrée (Input Layer) :	34
• Couches de convolution (Convolutional Layers) :	34
• Fonction d'activation (souvent ReLU) :	34
• Couches de regroupement (Pooling Layers) :	35
• Couches entièrement connectées (Fully Connected Layers - FC) :	35
• Couche de sortie (Output Layer) :	35
3.5 Utilisation des CNN en maintenance prédictive	36
• Analyse d'images ou vidéos	36
• Analyse de spectrogrammes	36
• Détection automatique d'anomalies	37
3.6 État de l'art : Utilisation des CNN pour le traitement d'image	37
• Fonctionnement général des CNN	37
• Domaines d'application industrielle.....	37
• Performances et architectures avancées	38
• Intégration industrielle et bénéfices	38
• Limites actuelles et perspectives	38
3.7 L'apprentissage dans les CNN (Convolution Neural Networks).....	39
• Propagation avant (Forward pass).....	39
• Calcul de l'erreur (Fonction de perte)	39
• Rétropropagation (Back propagation).....	39
• Mise à jour des poids	39
• Entraînement sur plusieurs époques	39
3.7 Résultat de l'apprentissage.....	39
3.8 Critères de validation des réseaux de neurones convolutifs (CNN).....	41
• Exactitude (Accourcie)	41
• Précision, Rappel et F-mesure (F1-score)	41

• Courbe ROC et AUC	41
• Matrice de confusion.....	41
• Fonction de coût (loss) et courbes d'apprentissage	41
• Validation croisée (cross-validation).....	41
• Temps d'inférence et complexité.....	42
• Robustesse aux perturbations	42
3.9 Validation d'un CNN (Convolution Neural Network)	42
3.10. Conclusion	42
4.1. Introduction	45
4.2. Acquisition et traitement des signaux sonores	45
• Chargement des données et préparation	46
• Évaluation et validation des performances.....	46
• Transformation des signaux audio en images.....	48
• Représentation temporelle des signaux acoustiques	48
• Visualisation des signaux bruts.....	48
• Analyse fréquentielle : spectrogrammes	52
• Analyse du spectrogramme de condition normal.....	52
• Analyse du spectrogramme du condition de roulement faible.....	54
• Analyse du spectre de fréquences (FFT)	55
• Synthèse de l'analyse exploratoire.....	60
• Lien avec l'intelligence artificielle	60
4.3 Modélisation par Réseau de Neurones Convolutifs (CNN)	61
• Construction du modèle CNN.....	61
• Entraînement du modèle	61
• Évaluation des performances.....	61
• Résultats peu satisfaisants	63
• Pistes d'amélioration	63
4.4 Extraction des caractéristiques audio (feature_extract).....	63
• Caractéristiques extraites.....	63
• Chargement des données	64
• Analyse de corrélation	64
• Réduction de dimension par ACP (PCA).....	64
• Comparaison Auto encoder vs PCA	65
• Modèle Autorégressif (AR)	66
• Extraction de caractéristiques par modélisation AR	66
• Surveillance de l'état de santé structurel (SHM)	66

• Traitement du signal et préparation des données	67
• Utilisation du modèle AR pour l'extraction de caractéristiques.....	67
• Sélection de l'ordre optimal du modèle AR	68
• Caractéristiques extraites : γ_1 et γ_2	68
• Influence de la durée d'échantillonnage	Erreur ! Signet non défini.
• Résultats.....	Erreur ! Signet non défini.
• Résultats.....	69
4.5 Approche hybride combinant CNN et méthodes statistiques (CombinModel)	69
• Architecture du modèle.....	70
• Compilation et entraînement	70
• Évaluation du modèle	71
• Résultats.....	74
4.6 Conclusion.....	74
Conclusion générale.....	77
Références.....	X

Listes des figures

Figure1.1 : le contrôle non destructif	5
Figure 1.2 : Méthodes de CND.....	9
Figure 1.3 : Stratégique du CND.....	12
Figure 2.1 : Composants d'une machine électrique.....	17
Figure2.2 : Les types de roulement.....	19
Figure 2.3 : Composants d'un roulement à billes.....	20
Figure 2.4 : Les défauts de roulement à billes.....	22
Figure 2.5 : Diagnostic d'un défaut de roulement.....	24
Figure 2.6 : Détection des bruits.....	26
Figure 2.7 : Mesure de température	27
Figure2.8 : Méthode d'observation	28
Figure 2.9 : Détecteur de vibrations	29
Figure3.1 : Les éléments d'un réseau de neurones artificiel	33
Figure3.2 : Architecture typique des CNN.....	36
Figure3.3 : processus d'apprentissage dans un CNN.....	40
Figure 4.1: Matrice de confusion et métriques de performance du modèle de classification..	47
Figure4.2 : Courbe de précision	47
Figure 4.3 : Évolution temporelle du signal sous condition normale	48
Figure 4.4: Évolution temporelle du signal – Défaut interne du roulement.....	49
Figure 4.5: Analyse du Signal Temporel – Condition Roller.....	50
Figure 4.6: Analyse du Signal Temporel – Condition Outer.....	51
Figure 4.7: Analyse Spectrale – Condition Normale.....	52
Figure 4.8: Analyse Spectrale d'un Signal Faible et Stable en Condition Interne.....	53
Figure4.9 : Analyse Spectrale d'un Signal Faible et Stable en Condition de Roulement Faible	54
Figure 4.10: Analyse Spectrale d'un Signal Faible et Stable – Condition Externe.....	55
Figure 4.11: Analyse Spectrale d'un Signal Temporel en Condition Normale : Faible Amplitude, Bruit et Stabilité.....	56

Figure 4.12: Analyse Spectrale d'un Signal Temporel en Condition Dégradée : Forte Amplitude, Bruit et Instabilité.....	57
Figure 4.13 : Analyse spectrale d'un signal temporel avec défaut de roulement — amplitude modérée, bruit et instabilité.....	58
Figure 4.14: Spectre d'un Signal Instable et Bruité – Étude Vibratoire.....	59
Figure 4.15: Matrice de confusion du modèle avec haute précision (Accourcie $\approx 97\%$)..	62
Figure 4.16 : Évolution de la performance du modèle pendant l'entraînement : précision et score F1 (train vs. Validation).....	62
Figure 4.17 : Comparaison des Méthodes de Classification (AE vs PCA) pour le Suivi de l'État des Roulements par Probabilités A Posteriori	65
Figure 4.18: Evaluation du Model de Reference sur Signaux de Roulements : États Sains vs Dégradés.....	68
Figure 4.19: Variation du critère d'information d'Akaike (AIC) selon l'ordre du modèle AR.....	68
Figure 4.20: Distribution des instances en fonction des caractéristiques γ_1 et γ_2	69
Figure 4.21: Visualisation des régions de décision de l'arbre de décision dans l'espace des caractéristiques γ_1 et γ_2	70
Figure 4.22 : Matrice de confusion du modèle de classification binaire	73
Figure 4.23 : Courbe d'apprentissage	74
Figure 4.24 : Courbe de valida.....	74

Liste des abréviations

AI : Artificial Intelligence (*Intelligence Artificielle*)

CND : Contrôle Non Destructif

FFT : Fast Fourier Transform (Transformation de Fourier Rapide)

BPFO : Ball Pass Frequency Outer race (Fréquence de passage des billes sur la bague extérieure)

BPFI : Ball Pass Frequency Inner race (Fréquence de passage des billes sur la bague intérieure)

BSF : Ball Spin Frequency (Fréquence de rotation des billes)

CNN : Convolutional Neural Network (Réseau de Neurones Convolutifs)

PCA : Principal Component Analysis (Analyse en Composantes Principales (ACP))

AIC : Akaike Information Criterion (Critère d'Information d'Akaike)

AR : AutoRegressive model (Modèle Auto-Régressif)

AE : Acoustic Emission (Émission Acoustique)

MFCC : Mel-Frequency Cepstral Coefficients (Coefficients Cepstraux en Fréquence Mel)

STFT : Short-Time Fourier Transform (Transformée de Fourier à Court Terme)

2D : Two-Dimensional (Deux dimensions)

DB : décibel

UT : Ultrasonic Testing

ET : Eddy Current Testing

MT : Magnetic Particle Testing

PT : Penetrant Testing

RT : Radiographic Testing

SHM : Structural Health Monitoring

MSE : Mean Squared Error

ROC : Receiver Operating Characteristic

AUC : Area Under the Curve

SGD : Stochastic Gradient Descent

FER : Frequency of Element Rotation

FC : Frequency of Cage

ReLU : Rectified Linear Unit

PBC : Pourcentage de Bande Constant

SGD : Stochastic Gradient Descent

Liste des tableaux

Tableau 4.1 : Synthèse de l'analyse exploratoire.....	60
Tableau 4.2 : Rapport de Classification.....	74

Introduction Générale



Introduction Générale :

Les machines électriques jouent un rôle central dans le fonctionnement d'une large gamme de systèmes industriels et domestiques, allant des lignes de production en usine aux appareils électroménagers du quotidien. Avec l'expansion continue de l'automatisation industrielle et la dépendance croissante aux systèmes mécaniques complexes, le maintien de la performance optimale et de la fiabilité opérationnelle de ces machines est devenu un enjeu stratégique.[1]

Dans ce cadre, la maintenance traditionnelle fondée sur des interventions périodiques n'est plus suffisante ni économiquement viable. Cela a conduit au développement de techniques de maintenance prédictive, visant à anticiper les défaillances avant qu'elles ne surviennent, en s'appuyant sur l'analyse de données collectées en temps réel pendant le fonctionnement des équipements. Les approches classiques de cette discipline reposent essentiellement sur la surveillance des vibrations, de la température ou du courant électrique. Toutefois, bien que ces méthodes soient efficaces, elles présentent certaines limites en termes de détection précoce ou nécessitent des équipements coûteux.[1]

C'est dans ce contexte que l'analyse acoustique émerge comme une alternative innovante. Les sons émis par une machine en fonctionnement sont souvent directement impactés par l'état mécanique ou électrique de celui-ci, qu'il s'agisse d'usure interne, de désalignement ou de défauts de connexion. Grâce aux avancées rapides en intelligence artificielle et en apprentissage automatique, il est désormais possible d'exploiter ces signaux sonores de manière intelligente afin de détecter précocement les anomalies et prédire leur évolution.

Ce mémoire porte sur le développement d'un système intelligent et intégré basé sur l'analyse acoustique pour la détection et la prédiction des défauts des machines électriques. Le système comprend plusieurs étapes : acquisition et traitement des signaux sonores, extraction de caractéristiques discriminantes à l'aide de techniques avancées de traitement du signal, puis classification et prédiction à l'aide de modèles d'apprentissage automatique. Il s'agit des réseaux de neurones artificiels. Cette approche se distingue par son caractère non intrusif, sa flexibilité et son faible coût comparativement aux méthodes traditionnelles.[2]

Ce travail contribue ainsi à renforcer les concepts de maintenance intelligente dans les environnements industriels, et ouvre la voie à des applications plus larges reposant sur l'exploitation des données acoustiques, marquant potentiellement une transformation dans la manière dont l'état des machines électriques est surveillé et géré.

Ce mémoire comprend quatre chapitres :

Chapitre1 : Ce chapitre présente une vue d'ensemble du Contrôle Non Destructif (CND), comme outil clé de la maintenance prédictive, permettant de détecter des défauts internes sans altérer le matériau. Le CND se divise en techniques acoustiques, électromagnétiques et radiographiques, dont le choix dépend du matériau, du défaut ciblé et des conditions d'inspection. Le texte aborde aussi les perspectives d'évolution via l'intelligence artificielle pour améliorer la détection précoce des fissures.

Chapitre2 : Est consacré à la partie ciblée dans la machine, pour la détection de défauts. Il s'agit des roulements à billes dans les machines électriques, de leurs types, des défauts possibles, ainsi que de l'importance de la surveillance et de la maintenance préventive pour détecter les pannes tôt et assurer l'efficacité de la machine.

Chapitre3 : Ce chapitre traite des réseaux de neurones artificiels avec un focus particulier sur les réseaux de neurones convolutifs (CNN), largement utilisés dans le traitement d'images et la maintenance prédictive. Il décrit les composants fondamentaux tels que les neurones, les couches, les poids, les biais et les fonctions d'activation, qui constituent la base de l'apprentissage automatique.

Chapitre 4 : Ce chapitre décrit la conception d'un système de maintenance prédictive basé sur l'analyse acoustique des machines. En étudiant les variations sonores émises en fonctionnement, il a été démontré qu'il est possible de détecter et identifier des défauts.

En fin en terminer par une conclusion générale est perspectives.

CHAPITRE 1 :

Introduction au Contrôle Non Destructif (CND)

1.1 Introduction :

Dans un contexte industriel en constante l'évolution des méthodes de maintenance, où la compétitivité, la sécurité et la qualité des services sont des priorités. La maintenance occupe une place stratégique. Elle regroupe l'ensemble des actions techniques, organisationnelles et administratives destinées à maintenir ou à rétablir un bien dans un état dans lequel il peut accomplir une fonction requise. La maintenance ne se limite plus aujourd'hui à la simple réparation des équipements défectueux ; elle s'inscrit désormais dans une démarche proactive visant à anticiper les défaillances, à optimiser les performances et à prolonger la durée de vie des installations.[3]

On distingue principalement trois grandes catégories de maintenance : corrective, préventive, et prédictive. Cette dernière, en particulier, repose sur la collecte et l'analyse continue des données provenant des équipements en fonctionnement. Elle permet l'anticipation de la détection d'une défaillance, et ainsi de planifier les interventions avant que le problème ne survienne. Pour soutenir cette approche, l'utilisation de techniques avancées de surveillance et de diagnostic est indispensable.[3]

Parmi ces techniques figure le Contrôle Non Destructif (CND), qui joue un rôle crucial dans la détection, la caractérisation et la surveillance des défauts dans les matériaux et les structures. Le CND regroupe un ensemble de méthodes permettant d'examiner un objet ou une pièce sans en compromettre l'intégrité, c'est-à-dire sans la détériorer ou en altérer l'usage. Cela permet de réaliser des inspections régulières tout au long de la vie du produit, sans interrompre ou compromettre son fonctionnement.

Les méthodes de CND les plus courantes incluent les essais par ultrasons, les radiographies, les essais par courants de Foucault, le ressuage, la magnétoscopie et plus récemment, les émissions acoustiques. Ces techniques sont largement utilisées dans des secteurs à haute exigence tels que l'aéronautique, le nucléaire, le ferroviaire, ou encore le génie civil. Elles permettent non seulement de garantir la fiabilité des installations, mais aussi d'optimiser les coûts de maintenance en évitant les arrêts imprévus et les interventions inutiles [4].

Ce chapitre vise donc à présenter une vue d'ensemble de la méthodologie des systèmes de contrôle non destructif, à expliquer les principes fondamentaux qui les régissent, et à décrire les principales techniques utilisées dans l'industrie, avec leurs domaines d'application, avantages, limites et critères de choix.

1.2 Contrôle non destructif (CND) :

Le contrôle non destructif désigne un ensemble de techniques d'inspection permettant d'évaluer l'intégrité d'un matériau, d'un composant ou d'un assemblage sans en altérer les propriétés ni compromettre son usage futur. Cette approche est essentielle dans de nombreux secteurs industriels, notamment l'aéronautique, le nucléaire, l'automobile et le génie civil, où la sécurité et la fiabilité sont primordiales. Comme l'illustre la figure 1.1.[5]




Figure 1.1 : le contrôle non destructif

1.2.1 Principes fondamentaux du contrôle non destructif (CND) :

Les différentes méthodes de contrôle non destructif reposent sur l'exploitation de principes physiques variés, permettant d'interagir avec la matière sans l'endommager. Parmi les phénomènes les plus couramment utilisés, on retrouve :

- La propagation d'ondes mécaniques, notamment les ultrasons, pour sonder l'intérieur des matériaux ;
- Les effets électromagnétiques, comme ceux des courants de Foucault ou de la magnétoscopie, adaptés aux matériaux conducteurs ou ferromagnétiques ;
- La diffusion et l'absorption de rayonnements ionisants, à la base des techniques de radiographie, permettant d'obtenir une image interne des structures ;
- Les réponses thermiques, exploitées en thermographie infrarouge, qui révèlent des anomalies par analyse des flux de chaleur ;
- Les phénomènes de capillarité et de contraste chimique, comme dans le ressuage, utilisés pour détecter les défauts de surface.

Chaque méthode est ainsi liée à un comportement physique spécifique du matériau face à une sollicitation contrôlée, permettant d'en déduire des informations sur son état interne ou externe[6].

Le choix de la technique à utiliser dépend de plusieurs paramètres :

- La nature du matériau (métallique, composite, céramique, etc.),
- Le type de défaut recherché (interne, de surface, sub-superficiel),

- Les conditions d'inspection (en atelier, sur site, à haute température),
- L'accessibilité de la zone à inspecter,
- Les contraintes économiques,
- Et les exigences réglementaires ou normatives.

1.2.2 Les principaux objectifs du CND :

Avant tout, il est essentiel de définir clairement les objectifs de l'inspection :

- la détection des défauts de fabrication, tels que les fissures, inclusions, porosités ou délaminages,
- le contrôle de la qualité des matériaux et des assemblages en cours ou en fin de production,
- le suivi de l'état d'endommagement des composants en service, dans le cadre de programmes de maintenance préventive ou prédictive.
- Évaluation de la taille et de la position des défauts.[6]

1.3 Nature des défauts internes et leur influence sur l'intégrité des matériaux :

Les matériaux, qu'ils soient métalliques, composites ou polymères, peuvent présenter des défauts internes d'origine variée, apparus au cours de la fabrication, du traitement thermique, du soudage, de l'usinage, ou encore lors de leur mise en service. Ces défauts constituent des discontinuités structurales susceptibles d'altérer le comportement mécanique et la fiabilité de la pièce concernée.

Parmi les défauts les plus fréquemment rencontrés, on distingue :

- Les fissures internes : Elles peuvent provenir de contraintes résiduelles, de surcharges mécaniques ou de fatigue. Ce sont des amorfes classiques de rupture.
- Les inclusions : Résidus étrangers (oxydes, sulfures, etc.) présents dans le matériau, souvent hérités de la fusion ou de l'élaboration.
- Les porosités : Espaces vides formés lors de la solidification (dans les pièces moulées ou soudées), pouvant réduire la résistance du matériau.
- Les soufflures : Bulles de gaz emprisonnées, principalement dans les soudures, pouvant évoluer en criques
- Les délaminages : Spécifiques aux matériaux composites, ils traduisent une séparation entre les couches du matériau.

Ces irrégularités internes, bien que parfois invisibles à l'œil nu, ont un impact direct sur :

- La tenue mécanique (résistance à la traction, à la compression, à la fatigue, etc.)
- La propagation des fissures (selon les lois de la mécanique de la rupture)
- La fiabilité en service (surtout pour les pièces soumises à des contraintes dynamiques ou thermiques)
- La durée de vie des composants, avec un risque de défaillance prématurée.

Ainsi, la détection précoce et la caractérisation précise de ces défauts représentent un enjeu majeur pour prévenir les accidents industriels, optimiser les conceptions, et garantir la

conformité aux normes de qualité. C'est dans ce contexte que s'inscrit le rôle fondamental des méthodes de Contrôle Non Destructif (CND) [7].

1.4 Méthodes principales du contrôle non destructif (CND)

Les techniques de contrôle non destructif se déclinent en plusieurs catégories selon le principe physique exploité comme l'illustre la figure 1.2. Chacune présente des spécificités en termes de sensibilité, de domaine d'application, d'avantages et de limites.

1.4.1 Méthodes acoustiques

1.4.1.1 Contrôle par sons

Le contrôle par sons, dans le contexte du contrôle non destructif, regroupe l'ensemble des techniques utilisant la propagation d'ondes mécaniques dans un matériau pour détecter des défauts. Ces ondes, audibles ou ultrasonores, interagissent avec les discontinuités internes (fissures, inclusions, délaminages) et permettent leur détection à travers l'analyse de signaux réfléchis, transmis ou émis.

1.4.1.2 Contrôle par ultrasons (UT – Ultrasonic Testing)

Cette méthode repose sur l'utilisation d'ondes mécaniques à haute fréquence (généralement entre 0,5 et 25 MHz) qui traversent le matériau. Lorsqu'une discontinuité est rencontrée (fissure, inclusion, vide), une partie de l'onde est réfléchi, ce qui permet de localiser et caractériser le défaut.

- **Avantages :**
 - Excellente pénétration dans les matériaux épais
 - Grande précision dans la détection et la localisation des défauts internes
- **Limites :**
 - Nécessite un bon couplage acoustique entre le capteur et la pièce
 - La méthode est moins adaptée aux géométries complexes ou aux surfaces rugueuses
- **Applications typiques :** contrôle de soudures, pièces forgées, matériaux composites, rails

1.4.1.3 Émission acoustique (AE – Acoustic Emission)

Il s'agit d'une technique de surveillance passive qui capte les ondes acoustiques naturellement générées par le matériau lorsqu'il est soumis à des contraintes mécaniques. Ces ondes sont associées à des processus physiques internes comme l'initiation ou la propagation de fissures [8].

- **Avantages :**
 - Permet une détection en temps réel
 - Idéale pour la maintenance conditionnelle et la surveillance continue
- **Limites :**
 - Sensible aux bruits de fond
 - L'analyse des signaux est complexe et nécessite un traitement avancé

- **Applications typiques** : surveillance de réservoirs sous pression, pipelines, structures composites.

1.4.2 Méthodes électromagnétiques

1.4.2.1 Courants de Foucault (ET – Eddy Current Testing)

Technique adaptée aux matériaux conducteurs, permettant la détection de défauts de surface ou sub-surface via l'induction électromagnétique.

Domaines d'application : vérification de revêtements, fissures de surface, contrôle de conductivité.

1.4.2.2 Magnétoscopie (MT – Magnetic Particle Testing)

Méthode utilisée pour détecter les défauts de surface et proches de la surface dans les matériaux ferromagnétiques. Le champ magnétique est appliqué, et les particules magnétiques révèlent les discontinuités.

1.4.3 Méthodes chimiques

1.4.3.1 Resuage (PT – Penetrant Testing)

Technique de détection de défauts de surface reposant sur la capillarité d'un liquide pénétrant coloré ou fluorescent qui s'infiltre dans les fissures ouvertes, puis est révélé par un révélateur.

1.4.3.2 Radiographie (RT – Radiographique Testing)

Inspection interne des matériaux au moyen de rayons X ou gamma, permettant de visualiser des défauts volumétriques (inclusions, porosités, fuites).[8]




Figure 1.2 : Méthodes de CND

1.5 Mise en œuvre d'un système de Contrôle Non Destructif (CND)

La mise en œuvre d'un système de Contrôle Non Destructif (CND) ne se limite pas à l'application d'une technique sur une pièce à inspecter. Elle repose sur une démarche rigoureuse, structurée en plusieurs étapes, permettant de garantir la fiabilité des résultats et la traçabilité du processus. Chaque étape vise à répondre à une problématique précise, depuis la compréhension des propriétés du matériau jusqu'à l'interprétation des signaux mesurés [9].

1.5.1 Caractérisation des matériaux

Le choix de la technique CND dépend fortement des propriétés physiques de la pièce à inspecter :

- Nature du matériau (métallique, composite, polymère, etc.) ;
- Forme géométrique, épaisseur ;
- Propriétés telles que la conductivité électrique, la perméabilité magnétique, la densité, etc.

Ces caractéristiques influencent la propagation des signaux (ondes ultrasonores, rayons X, courants de Foucault...) et doivent être rigoureusement analysées pour assurer la pertinence des résultats [9].

1.5.2 Détection et localisation des défauts

Cette étape repose sur l'utilisation de capteurs adaptés pour identifier la présence de discontinuités ou d'anomalies :

- Capteurs ultrasonores, sondes magnétiques, caméras thermiques, etc. ;
- Réglage précis des paramètres d'acquisition afin de maximiser la sensibilité et la fiabilité des mesures [9].

1.5.3 Caractérisation et analyse des défauts

Une fois les défauts détectés, il est nécessaire de les caractériser en détail :

- Nature du défaut (fissure, porosité, inclusion...) ;
- Dimensions (longueur, profondeur, volume...) ;
- Position (défaut en surface, en profondeur, ou centré).

Cette étape peut inclure l'utilisation de logiciels de traitement du signal ou de simulation pour affiner les résultats et améliorer l'interprétation.[10]

1.5.4 Interprétation des résultats et prise de décision

Les données recueillies doivent être interprétées selon les critères d'acceptabilité définis par les normes en vigueur ou les exigences spécifiques du client. Cela permet :

- D'évaluer la conformité de la pièce ;
- De statuer sur sa mise en service ou son rebut ;
- De planifier, si nécessaire, des réparations ou un suivi renforcé dans le temps.

Cette méthodologie assure une approche structurée, fiable et reproductible du contrôle non destructif. Elle permet de détecter efficacement les défauts tout en optimisant le choix des techniques utilisées, dans une logique de qualité, de sécurité et de performance.[10]

1.6 Critères de sélection d'une technique de CND

Le choix d'une méthode de contrôle non destructif dépend de plusieurs paramètres techniques, économiques et opérationnels. Pour guider cette sélection, il est courant d'utiliser une matrice décisionnelle prenant en compte les facteurs suivants :

- **Type de défaut ciblé** : défauts de surface, de sous-surface ou internes
- **Nature du matériau** : conductivité, magnétisme, homogénéité, épaisseur
- **Contraintes économiques et logistiques** : coût des équipements, temps d'inspection, accessibilité
- **Exigences en termes de performance** : niveau de précision attendu, sensibilité de détection, fiabilité des résultats
- **Conditions d'intervention** : inspection en ligne, en atelier ou sur site, environnement hostile ou non

Cette approche multicritère permet d'identifier la méthode la plus adaptée à une situation donnée tout en optimisant la qualité du diagnostic.[11]

1.7 Perspectives et innovations

Le domaine du contrôle non destructif connaît une évolution rapide grâce à l'intégration des technologies avancées, offrant de nouvelles perspectives en matière de performance, de fiabilité et d'automatisation. Parmi les principales innovations figurent :

- **L'automatisation robotisée** : l'usage de bras robotiques ou de drones permet d'inspecter des zones difficiles d'accès avec une grande précision et répétabilité.
- **L'intelligence artificielle (IA)** : les algorithmes de machine learning améliorent l'interprétation des signaux CND, réduisent les erreurs humaines et accélèrent le traitement des données.
- **La surveillance structurelle en continu (SHM – Structural Health Monitoring)** : cette approche consiste à intégrer des capteurs permanents dans les structures pour détecter en temps réel l'apparition ou l'évolution de défauts, favorisant ainsi une maintenance prédictive.

Ces avancées renforcent le rôle stratégique du CND dans les démarches de qualité, de sécurité et de durabilité des systèmes industriels modernes. Comme l'illustre la figure 1.3.[12]



Figure 1.3: Stratégie du CND

1.8 Conclusion :

Le Contrôle Non Destructif (CND) s'impose aujourd'hui comme un élément clé dans la gestion de la qualité, la sécurité et la fiabilité des systèmes industriels. Grâce à des méthodes variées, fondées sur des principes physiques rigoureux, il permet de détecter, localiser et caractériser les défauts au sein des matériaux ou structures, sans compromettre leur intégrité fonctionnelle. Cette capacité à inspecter sans altération est particulièrement cruciale dans des secteurs sensibles tels que l'aéronautique, le nucléaire, l'automobile ou les infrastructures de transport.

L'analyse des défauts internes et de leur influence sur le comportement mécanique des matériaux met en évidence l'importance d'une détection précoce et précise. Qu'il s'agisse de fissures, porosités, inclusions ou délaminages, ces anomalies peuvent affecter gravement la durée de vie des composants et engendrer des défaillances critiques si elles ne sont pas identifiées à temps. C'est dans ce cadre que la rigueur méthodologique du CND prend toute sa dimension : depuis la définition des objectifs jusqu'à l'interprétation des résultats, chaque étape vise à garantir la fiabilité du diagnostic.

CHAPITRE 1 : Introduction au contrôle non destructif (CND)

Le panorama des techniques de CND présenté dans ce chapitre illustre la richesse et la complémentarité des approches disponibles. Tandis que certaines méthodes classiques comme le ressuage ou la magnétoscopie sont bien établies, d'autres technologies plus avancées – telles que la thermographie infrarouge ou l'émission acoustique – ouvrent la voie à des applications innovantes en inspection en temps réel et en surveillance continue.

Dans ce qui suit notre approche s'inscrit dans les méthodes de maintenances prédictives par CND. Plus particulièrement le contrôle non destructif qui utilise le principe de propagation d'ondes mécanique afin de détecter des défauts de fissure.

Nous allons nous focaliser le CND par méthode acoustique avec une innovation de l'intelligence artificiel.

CHAPITRE2 :

Les roulements à billes dans les machines électriques

2.1 Introduction :

Depuis le début de l'ère industrielle, l'Homme n'a cessé de chercher des moyens efficaces pour transformer l'énergie et l'exploiter à des fins utiles. Parmi les inventions les plus marquantes dans le domaine de la conversion d'énergie, la machine électrique occupe une place centrale. Grâce à celle-ci, il est possible de convertir l'énergie électrique en énergie mécanique, c'est-à-dire en mouvement, de manière silencieuse, propre et très efficace. [13]

La machine électrique repose sur les principes fondamentaux de l'électromagnétisme, découverts au XIXe siècle par des scientifiques tels que Michael Faraday et André-Marie Ampère. Ces découvertes ont permis de comprendre qu'un courant électrique, circulant dans un conducteur placé dans un champ magnétique, subit une force : c'est le principe de base de la machine électrique. Dès lors, cette technologie a connu une évolution spectaculaire, tant sur le plan scientifique qu'industriel. [13]

Aujourd'hui, les machines électriques sont omniprésentes dans notre quotidien. On les retrouve dans les appareils ménagers (aspirateurs, lave-linge, mixeurs...), dans les transports (voitures, trains, trottinettes électriques), dans l'industrie (machines de production, robots industriels), et même dans les objets de haute technologie comme les drones ou les disques durs. Leur champ d'application est extrêmement vaste en raison de leur simplicité de conception, de leur haut rendement énergétique, de leur réactivité et de leur faible impact environnemental par rapport aux machines à combustion interne. [14]

Dans ce contexte, il est essentiel de bien détailler ses éléments constitutifs. L'accent sera mis sur les roulements de la machine en particulier les roulements à billes.

2.2 Les éléments d'une machine électrique :

Les machines électriques contiennent plusieurs éléments, comme l'illustre la figure 2.1. Qui sont :

2.2.1 L'inducteur :

L'inducteur est la structure immobile du moteur. Il est généralement constitué de bobines ou d'aimants permanents.

Fonction principale : produire un champ magnétique stable ou tournant.

Dans certains moteurs, ce champ est créé par des bobines alimentées en courant électrique ; dans d'autres, par des aimants permanents.

L'inducteur entoure l'induit et reste fixe pendant le fonctionnement du moteur. [15]

2.2.2 L'induit :

L'induit est la partie centrale de la machine, qui tourne sous l'effet du champ magnétique généré par l'inducteur.

Fonction principale : tourner pour produire un mouvement mécanique. Il peut être composé de bobines, d'une cage en aluminium (dans les machines asynchrones), ou d'aimants. Il est monté sur un **axe**, appelé arbre, qui transmet la rotation. [15]

2.2.3 L'arbre de transmission :

L'arbre est une tige métallique solidaire du l'induit.

Rôle : transmettre le mouvement rotatif à un système extérieur (roues, ventilateur, engrenage, etc.).

Il est l'élément qui permet d'exploiter l'énergie mécanique produite par la machine. [15]

2.2.4 Le collecteur (dans les machines à courant continu) :

Le collecteur est un composant en forme d'anneau, constitué de segments conducteurs, monté sur le rotor. Fonction : assurer la commutation, c'est-à-dire l'inversion du courant dans les bobines du rotor, pour maintenir la rotation dans le même sens. Il est en contact permanent avec les balais. [15]

2.2.5 Les balais (ou charbons) :

Les balais sont des petits blocs de carbone ou de graphite qui frottent contre le collecteur.

Rôle : permettre le passage du courant entre la partie fixe du machine (stator) et la partie mobile (rotor).

Ce sont des pièces d'usure qui doivent être remplacées régulièrement dans les machines à balais. [16]

2.2.6 Le carter (ou enveloppe du machine) :

Le carter est l'enveloppe extérieure de la machine.

Fonctions :

- Protéger les composants internes de la machine.
 - Aider à évacuer la chaleur générée pendant le fonctionnement.
 - Souvent équipé de trous de ventilation ou de grilles pour favoriser le refroidissement.
- [16]

2.2.7 Le système de refroidissement (optionnel)

Pour éviter la surchauffe, certaines machines intègrent un système de refroidissement.

Il peut être composé :

- D'un ventilateur intégré.
- De ailettes pour dissiper la chaleur.
- Ou d'un refroidissement liquide pour les moteurs très puissants. [16]

2.2.8 Les roulements

- Les roulements sont placés autour de l'arbre, de chaque côté de la machine.
- Ils permettent à l'arbre de tourner facilement et en douceur.
- Leur rôle est de réduire les frottements, d'éviter l'usure et de maintenir la stabilité du mouvement.
- Sans roulements, la machine ferait du bruit, chaufferait plus vite et s'userait rapidement. [16]




Figure 2.1 : Composants d'une machine électrique

2.3 Les types de roulements dans une machine électrique :

Dans une machine électrique, les roulements jouent un rôle crucial : ils permettent à l'arbre machine de tourner facilement, sans frottement excessif, tout en supportant les charges mécaniques. Il existe plusieurs types de roulements, comme l'illustre la figure 2.2, chacun adapté à des usages et des conditions spécifiques. [17]

2.3.1 Roulement à billes :

- Ce type est le plus courant.
- Il est composé de petites billes insérées entre deux anneaux (bague intérieure et extérieure).
- **Avantages :**
 - Faible résistance au mouvement
 - Fonctionnement silencieux
 - Idéal pour les vitesses élevées
- **Utilisation :** machines standards, ventilateurs, appareils électroménagers. [17]

2.3.2 Roulement à rouleaux cylindriques :

- Les billes sont remplacées par de petits cylindres.
- Ils sont conçus pour résister à des charges radiales élevées (perpendiculaires à l'axe).
- **Avantages :**

- Grande capacité de charge
- Bonne stabilité
- **Limite** : peu efficace pour les charges axiales (dans le sens de l'axe). [17]

2.3.3 Roulement conique (ou à rouleaux coniques) :

- Les éléments roulants sont des cônes allongés.
- Ce type de roulement supporte à la fois les charges radiales et axiales.
- **Avantages** :
 - Très robuste
 - Idéal pour les sollicitations mécaniques combinées
- **Utilisation** : machines puissantes, boîtes de vitesses. [18]

2.3.4 Roulement à aiguilles :

- Composé de rouleaux très fins, semblables à des aiguilles.
- Très compact, ce roulement convient aux espaces restreints.
- **Avantages** :
 - Peu encombrant
 - Bonne résistance à la charge
- **Utilisation** : petites machines, applications compactes. [18]

2.3.5 Roulement à contact oblique :

- Les billes sont orientées selon un angle, ce qui permet de mieux supporter les charges axiales.
- **Avantages** :
 - Haute précision
 - Fonctionnement fiable à grande vitesse
- **Utilisation** : machines de haute performance, outils de précision. [18]

2.3.6 Palier lisse :

- Contrairement aux autres roulements, ce type ne contient ni billes ni rouleaux.
- L'arbre tourne simplement dans une bague lisse, lubrifiée.
- **Avantages** :
 - Très silencieux
 - Conception simple et économique
- **Limite** : moins résistant, usure plus rapide
- **Utilisation** : petites machines, équipements légers, ventilateurs. [18]




Figure 2.2 : Les types de roulement

2.4 Défauts dans les roulements à billes :

Les roulements à billes sont composés principalement de trois éléments (voir figure suivante)

- La bague intérieure (inner ring)
- La bague extérieure (outer ring)
- Les éléments roulants (billes)




Figure 2.3 : Composants d'un roulement à billes

Les défauts peuvent apparaître sur chacune de ces parties, comme l'illustre la figure 2.4. Voici une explication détaillée des défauts typiques selon la localisation :

2.4.1 Défauts de la bague intérieure (inner ring defects)

- **Écaillage (spalling) :**
Petites fissures ou morceaux de matière détachés de la surface de la piste. Causés par la fatigue du métal due à des charges répétées.
- **Usure circulaire :**
Traces d'usure souvent en forme d'anneau, causées par une mauvaise lubrification ou une mauvaise installation.
- **Piqûres électriques :**
Petits cratères dus au passage de courants électriques (effet d'arcs électriques).
- **Fissures radiales :**
Fissures partant du centre vers l'extérieur, généralement causées par des surcharges ou des chocs. [19]

2.4. 2 Défauts de la bague extérieure (outer ring defects)

- **Spalling localisé :**
Écaillage souvent concentré à un endroit fixe sur la piste, car la bague extérieure est souvent fixe.
Cela donne des vibrations périodiques lors de la rotation.
- **Corrosion :**
Résulte de l'humidité ou de la contamination. Peut se transformer en écaillage.
- **Ovalisation :**
Déformation de la bague extérieure due à un montage incorrect (serrage dans le logement), entraînant une mauvaise répartition des charges. [19]

2.4.3 Défauts des éléments roulants (billes)

- **Marques plates (flat spots) :**
Apparaissent si le roulement est resté immobile sous charge (phénomène de "brinelling").
- **Piqûres ou fissures :**
Dues à des chocs, à des surcharges ou à la corrosion.
- **Écaillage :**
Similaire aux bagues, causé par la fatigue du matériau. [19]



Piqûres



Rayures



Grippage



Déformation

Figure 2.4 : Les défauts de roulement à billes

2.5 Fréquences caractéristiques :

Lorsqu'une bille dans un roulement rencontre un défaut isolé — comme une fissure, un écaillage ou une marque laissée par un corps étranger — cela génère un impact. La répétition de ces impacts provoque des vibrations caractéristiques du roulement, dont les fréquences dépendent de l'emplacement du défaut, de la géométrie du roulement et de la vitesse de rotation de l'arbre. Ces fréquences spécifiques sont appelées :

- **BPFO** : fréquence de passage des billes sur la bague extérieure, liée à un défaut sur la couronne externe ;
- **BPFI** : fréquence de passage des billes sur la bague intérieure, associée à un défaut sur la couronne interne ;

- **FER** : fréquence de rotation des éléments roulants (billes ou rouleaux), en cas de défaut sur un élément roulant ;
- **FC** : fréquence de la cage, correspondant à un défaut au niveau de la cage du roulement.[20]

Remarque : Le fabricant de roulements SKF propose un logiciel qui permet, à partir de la référence du roulement et de la vitesse de rotation, de calculer les différentes fréquences associées aux défauts. [20]

Les défauts de roulements n'ont que rarement une influence dominante sur le spectre vibratoire d'une machine. Il est important de comprendre que l'impact généré par un défaut entrant en contact avec une bille engendre une vibration d'amplitude bien inférieure à celle causée par des phénomènes tels qu'un déséquilibre de rotor.

Cependant, la répétition de ces impacts vient exciter les fréquences naturelles des paliers, généralement situées dans une plage comprise entre 2 et 14 kHz. Cela entraîne une élévation des vibrations dans les hautes fréquences, qui peut être facilement repérée en comparant les spectres de vibration de manière appropriée. [20]

2.5.1 Détection et diagnostic :

Pour détecter un défaut de roulement, il est recommandé de comparer les spectres d'accélération, de préférence en pourcentage de bande constant (PBC), sur une plage de fréquence allant jusqu'à au moins 10 kHz. Une augmentation notable des hautes fréquences constitue un indicateur sérieux du développement d'un défaut de roulement.

Cependant, un diagnostic précis nécessite souvent des techniques d'analyse plus avancées que la simple acquisition d'un spectre FFT. L'une des méthodes les plus efficaces est l'analyse d'enveloppe du signal vibratoire. Cette technique permet d'extraire les impacts périodiques caractéristiques, souvent masqués dans le signal global d'une machine industrielle, et de révéler les premiers signes de détérioration des roulements.

La figure ci-dessous illustre la différence entre un spectre obtenu par analyse FFT conventionnelle et un spectre issu de l'analyse d'enveloppe. Sur le spectre FFT, le défaut est à peine perceptible, tandis que l'analyse d'enveloppe met clairement en évidence un défaut sévère sur la couronne externe (BPFO), identifiable par la présence de nombreuses harmoniques. [21]




Figure 2.5 : Diagnostic d'un défaut de roulement

2.6 Les principales raisons du mal fonctionnement des roulements à billes :

La fonction principale d'un roulement est de guider une rotation en permettant à une pièce de tourner par rapport à une autre. Cependant, plusieurs facteurs peuvent compromettre son bon fonctionnement et entraîner des défaillances. [22]

2.6.1 La corrosion :

L'exposition répétée à l'eau ou à des agents corrosifs dégrade progressivement le lubrifiant à l'intérieur du roulement, le rendant incapable de protéger efficacement les surfaces de roulement. Cela se manifeste par l'apparition de taches brunâtres sur les billes et les chemins de roulement, signe de rouille. Cette corrosion accélère l'usure des composants et provoque une augmentation des vibrations.

À terme, la corrosion entraîne un accroissement du jeu radial interne et une perte de capacité de charge du roulement. Il est donc recommandé de protéger les roulements contre les environnements corrosifs lorsque cela est possible.

À noter : il existe des roulements en acier inoxydable, qui offrent une meilleure résistance à la corrosion, bien qu'ils ne soient pas totalement à l'abri de l'oxydation. [22]

2.6.2 Le défaut d'alignement :

Un défaut d'alignement survient lorsque les bagues intérieure et extérieure du roulement ne sont plus parallèles. Un écart supérieur à 0,003 radians peut entraîner des marques d'usure visibles sur la cage de protection des billes. Ce défaut peut être causé par un arbre déformé sous l'effet d'une charge excessive ou contaminé par des impuretés.

Toutefois, par rapport à d'autres types de roulements, notamment les roulements à rouleaux, les roulements à billes sont généralement plus tolérants aux défauts d'alignement. [22]

2.6.3 La charge axiale inversée :

Les roulements à contact oblique sont conçus pour supporter des charges dans une seule

direction. S'ils sont installés à l'envers, ils subissent des contraintes importantes, provoquant une élévation de la température et des vibrations constantes. Les billes, déplacées hors de leurs chemins de roulement, s'usent prématurément.

Pour éviter ce problème, il suffit de monter le roulement dans le bon sens. La plupart des roulements à contact oblique sont d'ailleurs dotés d'un marquage indiquant la direction correcte de la charge. [23]

2.6.4 Les renforcements :

Des renforcements peuvent apparaître sur la bague extérieure lorsque la charge appliquée dépasse la limite d'élasticité du matériau, formant des creux dans les chemins de roulement. Cela génère du bruit et de fortes vibrations.

Des renforcements peuvent également être créés avant même l'utilisation du roulement, par exemple lors d'une installation brutale avec un marteau.

Pour éviter cela, il est crucial d'appliquer la pression uniquement sur la bague intérieure lors du montage sur un arbre, et sur la bague extérieure lors de l'insertion dans un logement. [23]

2.6.5 La surchauffe :

Plusieurs facteurs peuvent entraîner la surchauffe des roulements à billes. Une température excessive peut altérer les matériaux, réduisant leur durabilité et accélérant la fatigue des composants. De plus, l'utilisation d'une huile inappropriée peut compromettre l'efficacité du lubrifiant et favoriser la surchauffe.

Pour prévenir ce problème, il est essentiel de maintenir les roulements dans une plage de température compatible avec leurs spécifications. Il peut également être judicieux de prévoir des phases de refroidissement pendant leur utilisation. [23]

2.7 Surveillance et entretien des roulements en maintenance préventive :

La surveillance et le contrôle de l'état des équipements jouent un rôle de plus en plus essentiel dans le cadre de la maintenance préventive. Lorsqu'on détecte une usure accélérée d'un roulement, son remplacement est effectué lors des opérations d'entretien planifiées afin d'éviter un arrêt imprévu dû à une défaillance.

Aujourd'hui, de nombreux dispositifs sont disponibles pour assurer la surveillance des roulements. La majorité de ces systèmes repose sur l'analyse des vibrations. [24]

Entretien régulier : Dans les services de maintenance mécanique, il est essentiel que les opérateurs et les mécaniciens surveillent en permanence les signes avant-coureurs d'une dégradation de roulement : bruit anormal, élévation de température ou vibrations inhabituelles. [24]

2.7.1 Méthodes de surveillance :

Les techniques les plus simples consistent à écouter les bruits émis, à vérifier les hausses de température et à observer visuellement le comportement des roulements.

2.7.1.1 Détection des bruits :

L'écoute est une méthode efficace pour identifier une anomalie de fonctionnement. À l'aide d'un stéthoscope électronique, un technicien expérimenté peut reconnaître le type de défaut. Un roulement en bon état produit un ronronnement doux et constant. En revanche, des bruits forts et irréguliers accompagnés de craquements signalent une défaillance. Un crissement peut révéler une lubrification insuffisante, tandis qu'un sifflement métallique peut indiquer un jeu trop réduit. Des sons nets et réguliers sont caractéristiques des vibrations normales, mais des bruits variables selon la vitesse suggèrent un écaillage ou des impacts sur une bague. Les bruits intermittents, quant à eux, trahissent souvent une détérioration des éléments roulants. [25]

Pour détecter ces anomalies, on place un stéthoscope électronique à différents points du roulement afin d'écouter les sons émis (voir figure suivante). [25]




Figure 2.6 : Détection des bruits

Lorsque l'on intervient à proximité de pièces en mouvement, il est impératif de prendre toutes les mesures de sécurité nécessaires. En l'absence de stéthoscope électronique, il est possible d'utiliser une méthode plus simple : appuyer un tournevis ou un manche en bois contre le palier, puis placer l'oreille à l'autre extrémité pour écouter les sons émis. [25]

2.7.1.2 Mesure de température :

Une autre méthode de détection des anomalies consiste à surveiller la température des roulements. Une température anormalement élevée est souvent le signe d'un dysfonctionnement. Le lubrifiant peut en être la cause, notamment en cas de mauvaise qualité ou de quantité inadéquate. Il est essentiel d'éviter que la température de fonctionnement n'atteigne ou dépasse 125 °C, car cela raccourcirait considérablement la durée de vie du roulement. [26]

Plusieurs facteurs peuvent entraîner une surchauffe : contamination du lubrifiant, surcharge mécanique, jeu interne insuffisant, usure du roulement, blocage, ou encore frottement excessif des joints d'étanchéité. Ainsi, toute variation de température doit être considérée comme un indicateur potentiel de défaillance.

Pour assurer un suivi régulier et précis, la température des roulements peut être mesurée à l'aide d'un thermomètre de surface (voir figure suivante). [26]




Figure 2.7 : Mesure de température

Figure 2.7 : Mesure de température

Les roulements installés dans des zones critiques devraient être équipés en permanence de sondes thermiques, permettant une surveillance continue de la température. Lors de tout relevé manuel de température, il est essentiel de respecter rigoureusement les consignes de sécurité, notamment en présence de pièces en mouvement. [26]

2.7.1.3 Méthode d'observation :

Une autre façon de détection des anomalies consiste à effectuer une inspection visuelle attentive du comportement des roulements et de leurs joints (voir figure suivante). Il convient de vérifier l'état des joints situés à proximité des roulements afin de s'assurer qu'ils empêchent toute infiltration de liquides, de gaz chauds ou de substances corrosives.

Il est également important de maintenir les collerettes de protection et les chicaneaux bien garnies de graisse pour garantir une bonne étanchéité. Les joints usés doivent être remplacés sans délai pour éviter toute dégradation prématurée du roulement. [27]



Figure 2.8 : Méthode d'observation

Les fuites de lubrifiant doivent être rapidement vérifiées, car elles peuvent indiquer un joint défectueux. Les systèmes de lubrification doivent être bien alimentés et contrôlés, et la couleur du lubrifiant peut révéler des impuretés. [27]

2.7.1.3 Détecteur de vibrations :

Grâce aux avancées technologiques, l'analyse des vibrations constitue aujourd'hui une méthode efficace pour détecter les défauts des roulements. Elle repose sur l'identification des fréquences caractéristiques des défaillances. Lorsqu'un défaut est rencontré, il génère un pic dans le signal enregistré.

La répétition des pics dépend de l'emplacement du défaut sur le roulement ainsi que de la géométrie et de la vitesse du roulement. Dans un des modules qui suivra, vous apprendrez comment détecter les sources des vibrations provenant des roulements et à en faire une analyse. (Voir figure suivante). [27]




Figure 2.9 : Détecteur de vibrations

2.8 Conclusion :

Les machines électriques sont constituées de plusieurs composants essentiels, parmi lesquels les roulements occupent une place clé. Ces derniers assurent la rotation fluide de l'arbre tout en supportant les charges mécaniques. Toutefois, ils représentent également l'un des éléments les plus vulnérables de la machine, souvent à l'origine de pannes.

Les principaux défauts de roulement à billes, incluent l'usure des pistes et des billes, les fissures, les déformations, la surchauffe, ainsi que des bruits ou vibrations anormales. Ces défaillances peuvent être causées par une lubrification inadéquate, des charges excessives ou mal alignées, la contamination par des particules ou de l'humidité, des chocs mécaniques, des courants électriques parasites, ou simplement par le vieillissement du composant.

Nous allons nous intéresser aux défauts : Défauts de la bague intérieure (inner ring defects), défauts de la bague extérieure (outer ring), Défauts des éléments roulants (billes). Ces défauts ont un impact acoustique clair et détectable.

Pour garantir la fiabilité et la longévité des machines électriques, il est donc essentiel de surveiller l'état des roulements et d'effectuer une maintenance préventive régulière. Cela permet non seulement d'éviter des arrêts imprévus, mais aussi d'optimiser les performances et de réduire les coûts d'exploitation.

CHAPITRE 3 :

Les Réseaux de Neurones Convolutifs (CNN)

3.1 Introduction :

L'intelligence artificielle a connu un essor considérable ces dernières décennies, plaçant les réseaux de neurones artificiels au cœur des avancées en apprentissage automatique. Ces modèles, inspirés du fonctionnement du cerveau humain, permettent aux machines d'extraire des connaissances à partir de données, de reconnaître des structures complexes et de prendre des décisions de manière autonome. Leur performance repose essentiellement sur les interactions entre les éléments constitutifs du réseau qui influencent directement la capacité d'apprentissage et de généralisation du système. Dès lors, une compréhension fine de cette dynamique interne est cruciale pour améliorer l'efficacité des réseaux de neurones et développer des architectures optimisées, répondant aux exigences croissantes des applications modernes telles que la vision artificielle, la reconnaissance d'image, la compréhension du langage ou la traduction automatique.[28]

3.2 Le réseau de neuronal artificiel :

Un réseau de neurones artificiel, est un système informatique dont la conception s'inspire initialement de l'anatomie biologique des neurones, mais qui s'est ensuite rapproché des approches statistiques.

Ces réseaux sont généralement optimisés à l'aide de méthodes d'apprentissage probabilistes, notamment les techniques bayésiennes. Ils relèvent à la fois du domaine des applications statistiques — qu'ils enrichissent grâce à divers paradigmes permettant, par exemple, des classifications rapides comme celles réalisées par les réseaux de Kohonen — et de celui de l'intelligence artificielle, où ils apportent un mécanisme perceptif autonome, indépendant des intentions de leur concepteur, et capable de fournir des données utiles au raisonnement logique formel, notamment dans le cadre de l'apprentissage profond.[29]

3.2.1 Les éléments constitutifs d'un réseau de neurones artificiel :

Les réseaux de neurones sont composés de plusieurs éléments fondamentaux, chacun ayant une fonction bien définie dans le processus d'apprentissage et de prise de décision. Comprendre ces composants est essentiel pour maîtriser le fonctionnement interne des réseaux et leur capacité à résoudre des problèmes complexes. Comme l'illustre la figure 3.1.[30]

3.2.1.1 Les neurones (ou nœuds) :

Les neurones sont les unités de traitement de base dans un réseau de neurones. Inspirés des neurones biologiques, ils reçoivent des signaux (valeurs numériques), les pondèrent, y ajoutent un biais, puis appliquent une fonction d'activation pour produire une sortie. Chaque neurone agit donc comme une petite fonction mathématique, transformant les entrées qu'il reçoit.[30]

3.2.1.2 Les couches :

Les neurones sont organisés en couches successives :

- La couche d'entrée reçoit les données brutes (par exemple, les pixels d'une image ou les mots d'un texte vectorisé). Elle ne fait que transmettre ces valeurs à la couche suivante.
- Les couches cachées effectuent les transformations internes. Ce sont elles qui permettent au réseau de modéliser des relations complexes. Plus il y a de couches (réseau profond), plus la capacité du réseau à capturer des motifs abstraits est élevée.
- La couche de sortie produit le résultat final du modèle, par exemple une probabilité pour chaque classe dans un problème de classification.[30]

3.2.1.3 Les poids synaptiques :

Chaque connexion entre deux neurones est associée à un poids. Ces poids déterminent l'importance des signaux transmis d'un neurone à un autre. Pendant l'entraînement, le réseau ajuste ces poids pour apprendre les relations les plus pertinentes dans les données. Les poids sont les véritables paramètres appris du modèle.[31]

3.2.1.4 Les biais :

Le **biais** est un terme ajouté au produit pondéré des entrées. Il permet de décaler la fonction d'activation et donne davantage de flexibilité au modèle. Sans biais, le réseau serait contraint de passer par l'origine (valeur zéro) dans l'espace des solutions, ce qui limiterait sa capacité d'adaptation.[31]

3.2.1.5 Les fonctions d'activation :

Une fonction d'activation introduit une non-linéarité dans le traitement. Sans ces fonctions, le réseau, même avec plusieurs couches, ne pourrait représenter que des relations linéaires. Parmi les fonctions les plus utilisées :

- ReLU (Rectified Linear Unit) : simple et efficace, elle remplace les valeurs négatives par zéro.
- Sigmoid : utilisée pour des sorties entre 0 et 1, souvent en classification binaire.
- Tanh : similaire à la sigmoïde mais centrée sur zéro.[32]

3.2.1.6 La fonction de perte (ou fonction coût) :

Elle mesure l'écart entre la sortie produite par le réseau et la valeur réelle attendue (label). C'est cette fonction que l'algorithme d'apprentissage cherche à minimiser. Quelques exemples :

- **Erreur quadratique moyenne (MSE)** : utilisée en régression.
- **Entropie croisée (cross-entropy)** : adaptée à la classification.[32]




Figure 2.1 : Les éléments d'un réseau de neurones artificiel

3.3 Réseaux convolutifs (CNN – Convolutional Neural Networks) :

Un réseau de neurones convolutif (CNN) est un type de réseau de neurones artificiels spécialement conçu pour traiter et analyser des données visuelles, comme les images. Il utilise des couches convolutives pour extraire automatiquement des caractéristiques importantes (formes, textures, bords), ce qui le rend très efficace pour des tâches telles que la classification d'images, la détection d'objets ou encore la reconnaissance faciale.[33]

Fonctionnement :

- Les filtres (ou noyaux) apprennent à détecter des motifs (bords, textures...).
- Réduction de la dimension via le pooling tout en conservant les caractéristiques importantes.

3.3.1 Avantages et limites

3.3.1.1 Avantages :

- Excellente capacité d'extraction automatique de caractéristiques.
- Performances supérieures à celles des méthodes classiques.

3.3.1.2 Limites :

- Nécessitent de grandes quantités de données étiquetées.
- Peu interprétables.
- Sensibles aux adversaire attacks.[34]

3.3.2 Applications en traitement d'image

- Classification d'images : CNNs sont à la base de systèmes comme VGGNet, ResNet ou EfficientNet.
- Détection d'objets : avec des modèles comme YOLO (Redmon et al., 2016), Faster R-CNN (Ren et al., 2015).
- Segmentation sémantique : via U-Net (Ronneberger et al., 2015) notamment dans le domaine médical.
- Amélioration d'image : débruitage, super-résolution (SRCNN - Dong et al., 2014).[34]

3.4 Structure d'un réseau de neurones convolutif (CNN - Convolutional Neural Network) :

Un CNN est composé de plusieurs types de couches empilées les unes après les autres, permettant au réseau d'extraire automatiquement des caractéristiques des données d'entrée. La structure classique suit généralement l'ordre suivant : (voir la figure 3.2) [35]

3.4.1 Couche d'entrée (Input Layer) :

- Reçoit les données brutes (ex : image de 32×32 pixels avec 3 canaux pour RGB).
- Forme : [largeur, hauteur, profondeur].

3.4.2 Couches de convolution (Convolutional Layers) :

- Appliquent des filtres (ou noyaux) qui parcourent l'image pour extraire des caractéristiques locales (bords, textures, motifs...).
- Chaque filtre produit une carte de caractéristiques (*feature map*).
- Paramètres importants :
 - Taille du filtre (ex. : 3×3 , 5×5),
 - Stride (pas du déplacement),
 - Padding (ajout de bordures pour contrôler la taille de sortie).

3.4.3 Fonction d'activation (souvent ReLU) :

- Appliquée après chaque convolution pour introduire la non-linéarité.

- ReLU (*Rectified Linear Unit*) transforme chaque valeur xxx en $\max(0, x)$ \ $\max(0, x)$ $\max(0, x)$, éliminant ainsi les valeurs négatives.

3.4.4 Couches de regroupement (Pooling Layers) :

- Réduisent la taille spatiale des cartes de caractéristiques (compression d'information).
- Exemples :
 - **Max pooling** : conserve la valeur maximale dans une région donnée.
 - **Average pooling** : calcule la moyenne.
- Permet de réduire le surapprentissage et le coût computationnel.

3.4.5 Couches entièrement connectées (Fully Connected Layers - FC) :

- Similaires à celles d'un réseau de neurones classique (feedforward).
- Prend les caractéristiques extraites par les couches précédentes et les utilise pour effectuer la classification ou la régression.
- Chaque neurone est connecté à tous ceux de la couche précédente.

3.4.6 Couche de sortie (Output Layer) :

- Produit le résultat final, selon la tâche :
 - **Classification** : distribution de probabilité (ex. : Softmax).
 - **Régression** : valeur continue.[35]

Architecture typique des CNN




Figure 3.2 : Architecture typique des CNN

3.5 Utilisation des CNN en maintenance prédictive :

Les CNN sont utilisés dans la maintenance prédictive dans plusieurs cas :

3.5.1 Analyse d'images ou vidéos

- Exemple : Utilisation de caméras pour surveiller des pièces de machines.
- Les CNN analysent les images pour détecter l'usure, les fissures ou les fuites.

3.5.2 Analyse de spectrogrammes

- Les signaux acoustiques ou vibratoires sont souvent transformés en spectrogrammes (images du son) grâce à des techniques comme la transformée de Fourier.
- Les CNN peuvent ensuite analyser ces images pour reconnaître des motifs anormaux.

3.5.3 Détection automatique d'anomalies

- Grâce à leur capacité à apprendre des modèles complexes, les CNN peuvent être entraînés pour reconnaître les conditions normales d'un équipement, et signaler toute déviation.

Les CNN jouent un rôle crucial dans la maintenance prédictive en permettant une analyse automatique, rapide et précise des données issues des machines. Ils transforment des données complexes en prédictions utiles pour éviter les pannes.[36]

3.6 État de l'art : Utilisation des CNN pour le traitement d'image

L'émergence de l'intelligence artificielle, et plus particulièrement des réseaux de neurones profonds, a profondément transformé les approches traditionnelles de traitement d'image dans le secteur industriel. Parmi ces techniques, les réseaux de neurones convolutifs (CNN) se sont rapidement imposés comme des outils de référence pour la détection automatique de défauts et le contrôle qualité visuel. Leur capacité à apprendre directement, à partir des données, des représentations visuelles complexes, surpasse largement les méthodes classiques fondées sur des règles heuristiques ou des filtres manuels.[37]

3.6.1 Fonctionnement général des CNN

Les CNN reposent sur une architecture hiérarchique composée de couches convolutives, de regroupement (pooling) et de couches entièrement connectées. Chaque couche extrait des caractéristiques de plus en plus abstraites à partir de l'image d'entrée, permettant ainsi d'identifier des motifs complexes et pertinents sans intervention humaine. Cette automatisation de l'extraction de caractéristiques permet une meilleure robustesse face aux variations d'éclairage, d'angle de vue ou de bruit, fréquemment rencontrées dans les environnements industriels.[37]

3.6.2 Domaines d'application industrielle

Dans un contexte industriel, les CNN sont utilisés pour identifier avec précision une grande variété d'anomalies, notamment :

- Des fissures ou microfissures sur des structures métalliques ou composites ;
- Des rayures, déformations ou traces d'usure sur des pièces mécaniques ;
- Des défauts d'assemblage ou écarts de positionnement sur des lignes automatisées ;
- Des irrégularités de surface sur des composants électroniques ou des matériaux textiles.

Ces modèles sont souvent embarqués dans des systèmes de vision industrielle, des robots d'inspection, ou des caméras intelligentes, et permettent un contrôle non destructif (CND) en temps réel, assurant une vérification rapide, fiable et continue des produits.[38]

3.6.3 Performances et architectures avancées

Les performances des CNN ont été considérablement améliorées grâce au développement d'architectures optimisées telles que ResNet, EfficientNet, ou les modèles de détection en temps réel comme YOLO (You Only Look Once).

- Li et al. (2019) ont conçu un CNN profond pour détecter des micro-défauts sur des surfaces métalliques, atteignant une précision supérieure à 95 %.
- Huang et al. (2020) ont adapté le modèle YOLOv3 pour classifier rapidement les défauts sur des cartes de circuits imprimés, prouvant l'efficacité des CNN dans des environnements à haute cadence.
- Zhao et al. (2021) ont utilisé un modèle basé sur U-Net pour la segmentation précise de fissures sur des composants mécaniques, surpassant les méthodes de seuillage traditionnelles.

Ces réseaux permettent ainsi d'atteindre des niveaux de précision élevés, tout en respectant les contraintes de rapidité et de traitement en continu, caractéristiques des environnements de production.[38]

3.6.4 Intégration industrielle et bénéfices

L'intégration des CNN dans les lignes de production permet une automatisation du contrôle qualité, avec plusieurs avantages :

- Fiabilité accrue et réduction des erreurs humaines ;
- Diminution des coûts liés aux inspections manuelles ;
- Traçabilité grâce à l'enregistrement numérique des résultats d'inspection ;
- Adaptabilité à divers matériaux et processus industriels.

Ces systèmes peuvent également être ajustés ou réentraînés pour répondre à de nouveaux types de défauts ou à des évolutions de la chaîne de production, assurant ainsi leur pérennité et leur efficacité à long terme.[38]

3.6.5 Limites actuelles et perspectives

Malgré leurs nombreux atouts, l'utilisation des CNN en milieu industriel comporte certaines limites :

- Le besoin en données annotées de qualité, souvent coûteuses à obtenir ;
- La sensibilité aux variations du processus de production ;
- Le manque d'explicabilité des modèles (boîte noire) ;
- La complexité du déploiement dans des environnements aux ressources limitées.

Pour pallier ces défis, les recherches actuelles se concentrent sur des approches telles que l'apprentissage par transfert, les réseaux légers (ex. : Mobile Net, Tiny-YOLO), ou encore l'association des CNN à d'autres capteurs pour une fusion de données multimodale, visant à accroître la robustesse et l'interprétabilité des systèmes de contrôle.[39]

3.7 L'apprentissage dans les CNN (Convolution Neural Networks)

Les réseaux de neurones convolutifs (CNN) sont des modèles puissants du Deep Learning, particulièrement efficaces pour l'analyse d'images. Leur force réside dans leur capacité à apprendre automatiquement les caractéristiques visuelles importantes à partir des données, sans intervention humaine directe.[40]

3.7.1 Propagation avant (Forward pass)

L'image passe successivement par plusieurs couches :

- Les couches convolutives détectent des motifs visuels (bords, textures...),
- Les couches de pooling réduisent la dimension tout en conservant les informations essentielles,
- Les couches entièrement connectées synthétisent les informations pour produire une prédiction finale (comme une classe d'objet).

3.7.2 Calcul de l'erreur (Fonction de perte)

La sortie du réseau est comparée à la vérité attendue. Une fonction de perte mesure l'écart entre la prédiction et la réalité.

3.7.3 Rétropropagation (Back propagation)

Le réseau analyse l'erreur et calcule l'impact de chaque poids sur cette erreur. Cela permet d'identifier comment corriger les paramètres internes.

3.7.4 Mise à jour des poids

Les poids (ou filtres) sont ajustés selon un algorithme d'optimisation (comme SGD ou Adam) afin de réduire l'erreur à chaque itération.

3.7.5 Entraînement sur plusieurs époques

L'ensemble des données est traité en plusieurs passes (époques) pour améliorer progressivement la performance du réseau et favoriser la généralisation.

3.7 Résultat de l'apprentissage

Une fois entraîné, un CNN est capable de :

- Reconnaître des motifs complexes,
- Effectuer des prédictions précises,
- Généraliser sur de nouvelles données,
- Et s'adapter à des tâches comme la classification, la détection de défauts ou la maintenance prédictive.[40]

Processus d'apprentissage dans un CNN




Figure 3.3 : processus d'apprentissage dans un CNN [41]

3.8 Critères de validation des réseaux de neurones convolutifs (CNN)

L'évaluation des performances d'un réseau de neurones convolutif repose sur plusieurs indicateurs clés, permettant de mesurer à la fois la précision du modèle, sa capacité de généralisation, ainsi que sa robustesse face à des données nouvelles.[42]

3.8.1 Exactitude (Accourcie)

L'exactitude mesure la proportion globale de prédictions correctes sur l'ensemble de validation. Bien qu'intuitive, cette métrique peut s'avérer trompeuse en cas de déséquilibre entre classes, car elle ne reflète pas la qualité des prédictions sur les classes minoritaires.

3.8.2 Précision, Rappel et F-mesure (F1-score)

Ces trois métriques sont essentielles pour évaluer les performances d'un modèle dans un contexte de classification binaire ou multi-classe déséquilibrée :

- Précision : taux de vrais positifs parmi les éléments classés comme positifs.
- Rappel : taux de vrais positifs détectés parmi tous les éléments réellement positifs.
- F1-score : moyenne harmonique entre précision et rappel, utilisée comme compromis entre les deux.[43]

3.8.3 Courbe ROC et AUC

La courbe ROC (Receiver Operating Characteristic) illustre le compromis entre le taux de vrais positifs et celui de faux positifs. L'aire sous la courbe (AUC) fournit un score global : plus l'AUC est proche de 1, meilleure est la capacité du modèle à discriminer entre les classes.

3.8.4 Matrice de confusion

Il s'agit d'un outil de visualisation qui résume les performances du modèle en affichant les cas de bonnes et mauvaises classifications pour chaque classe. Elle permet d'identifier les classes les plus problématiques et d'analyser les erreurs spécifiques.

3.8.5 Fonction de coût (loss) et courbes d'apprentissage

Le suivi de la fonction de perte sur les ensembles d'entraînement et de validation permet de détecter un éventuel surapprentissage (overfitting). Une courbe de validation qui stagne ou augmente pendant que celle d'entraînement diminue signale une mauvaise généralisation.[42]

3.8.6 Validation croisée (cross-validation)

La validation croisée, notamment k-fold, consiste à répartir les données en plusieurs sous-ensembles pour évaluer le modèle sur différentes partitions. Cela offre une évaluation plus stable et représentative que celle basée sur une simple division entraînement/validation.[43]

3.8.7 Temps d'inférence et complexité

Outre la précision, il est important d'évaluer le temps de traitement par image (inférence) ainsi que la complexité computationnelle (nombre de paramètres, FLOPs). Ces facteurs sont cruciaux dans les applications temps réel ou embarquées.

3.8.8 Robustesse aux perturbations

Un bon modèle doit également résister aux bruits, aux transformations d'image (rotation, échelle, luminosité), ou aux attaques adversariales. Tester la robustesse permet d'anticiper les dégradations de performance en conditions réelles.[43]

3.9 Validation d'un CNN (Convolution Neural Network)

La validation d'un réseau de neurones convolutif (CNN) est une étape cruciale dans le processus d'apprentissage supervisé. Elle permet d'évaluer la capacité du modèle à généraliser à de nouvelles données, en le testant sur un jeu de validation distinct de celui utilisé pour l'entraînement. Pour ce faire, l'ensemble des données est généralement divisé en trois parties : un jeu d'entraînement pour ajuster les poids du modèle, un jeu de validation pour contrôler les performances pendant l'apprentissage et ajuster les hyperparamètres, et parfois un jeu de test pour l'évaluation finale.[44]

Pendant la validation, plusieurs indicateurs de performance sont utilisés, notamment la précision (accuracy), la fonction de perte (loss) et la matrice de confusion. Ces métriques permettent de détecter des phénomènes tels que le surapprentissage (*overfitting*), où le modèle apprend trop bien les données d'entraînement mais échoue à généraliser, ou le sous-apprentissage (*underfitting*), où le modèle est trop simple pour bien modéliser les données. Afin d'améliorer les résultats de validation, plusieurs techniques peuvent être mises en œuvre : la régularisation (comme le dropout ou L2), l'augmentation des données (data augmentation), et l'arrêt anticipé (*early stopping*), qui consiste à interrompre l'entraînement si la performance sur le jeu de validation cesse de s'améliorer.[45]

3.10. Conclusion :

Les réseaux de neurones artificiels, et plus particulièrement les réseaux de neurones convolutifs (CNN), ont transformé en profondeur le champ de l'intelligence artificielle, notamment dans le traitement des données visuelles et temporelles. Grâce à leur capacité à extraire automatiquement des caractéristiques complexes, ces modèles ont permis des avancées majeures dans des domaines comme la vision par ordinateur, la reconnaissance vocale et, plus récemment, la maintenance prédictive.

Ce chapitre a présenté une analyse approfondie des réseaux de neurones artificiels, en mettant l'accent sur les réseaux convolutifs (CNN), largement utilisés dans le traitement d'images. Nous avons souligné que leur architecture — fondée sur des neurones, couches, poids, biais et fonctions d'activation — constitue la base de l'apprentissage automatique. Grâce à leurs couches de convolution, de pooling et entièrement connectées, les CNN permettent une extraction automatique et efficace des caractéristiques visuelles.

Dans un cadre industriel, ces réseaux se révèlent particulièrement performants pour la maintenance prédictive, notamment en inspection visuelle, analyse spectrale et détection d'anomalies. Le processus d'apprentissage — propagation avant, rétropropagation, ajustement des poids — assure leur capacité à généraliser sur de nouvelles données.

L'évaluation rigoureuse à l'aide d'indicateurs comme la précision, le rappel, le F1-score, l'AUC ou la matrice de confusion permet d'optimiser les performances des modèles. Toutefois, malgré leurs atouts indéniables, les CNN présentent certaines limites : forte dépendance aux données annotées, faible interprétabilité, vulnérabilité aux perturbations et complexité du déploiement embarqué.

Enfin, il souligne à la fois les avantages (précision, automatisation, robustesse) et les limites (besoin en données annotées, manque d'interprétabilité, sensibilité aux attaques) des CNN, notamment dans des contextes industriels réels.

CHAPITRE 4 :

**Approches d'Intelligence Artificielle
pour la détection des défauts moteurs
à partir du signal sonore**

4.1 Introduction

Dans le cadre de ce projet, nous visons à concevoir un système de maintenance prédictive capable de détecter et d'identifier les défauts dans des moteurs en s'appuyant sur l'analyse du bruit émis lors de leur fonctionnement. En effet, le son généré par un moteur en rotation varie en fonction de son état de santé, ce qui permet, à partir d'enregistrements sonores, de déterminer si un moteur présente une anomalie et d'en diagnostiquer la nature.

Nous nous concentrons ici sur la détection de trois types de défauts courants, en développant trois approches complémentaires :

1. Une approche basée sur un réseau de neurones convolutif (CNN),
2. Une approche reposant sur l'extraction de caractéristiques pertinentes à partir des signaux audio,
3. Une approche hybride combinant les deux méthodes précédentes.

Ce travail s'inscrit dans une démarche de fiabilisation et d'optimisation de la maintenance industrielle, en exploitant les potentialités de l'intelligence artificielle pour anticiper les défaillances mécaniques.

4.2 Acquisition et traitement des signaux sonores

Le jeu de données utilisé comprend des enregistrements audio de moteurs électriques, chacun correspondant à l'un des quatre états de fonctionnement suivants :

- Normal : moteur sain, sans défaut,
- Inner : défaut localisé sur la bague intérieure du roulement,
- Roller : défaut sur les éléments roulants,
- Outer : défaut sur la bague extérieure du roulement.

Chaque enregistrement est réalisé à une fréquence d'échantillonnage de 44,1 kHz et contient 120 000 échantillons, assurant une représentation fidèle du signal sonore.

Afin de faciliter le traitement, chaque signal est découpé en segments de 2 000 échantillons, soit 0,2 seconde par segment. On obtient ainsi 60 segments par signal, chacun étant associé à une étiquette de classe (de 0 à 3 selon l'état du moteur).

Les données sont ensuite réparties comme suit :

- 70 % pour l'entraînement : soit 42 segments,
- 30 % pour le test : soit 18 segments.

Cette structuration permet d'optimiser l'apprentissage tout en conservant un jeu de test représentatif pour l'évaluation des performances.

4.2.1 Chargement des données et préparation

Les signaux sont chargés à partir d’un fichier .mat et regroupés dans une liste Python :

```
data = [df_normal, df_inner, df_roller, df_outer]
```

Une fonction nommée `load_data()` est utilisée pour effectuer les opérations suivantes :

1. Diviser les signaux en segments de 0,2 seconde,
2. Attribuer une étiquette (label) à chaque segment,
3. Répartir les données entre jeu d’entraînement et jeu de test,
4. Mélanger aléatoirement les données afin d’éviter tout biais lors de l’apprentissage.

Cette fonction retourne les éléments suivants :

- `audios_train, label_train` : données et étiquettes pour l’entraînement,
- `audios_test, label_test` : données et étiquettes pour le test.

Dans un environnement Jupyter Notebook, il est possible d’écouter les signaux audio avec la commande suivante :

```
IPython.display.Audio(df_inner, rate=10000)
```

Cette fonctionnalité permet de vérifier la qualité sonore des enregistrements, de comparer les signaux selon les types de défauts, et ainsi de mieux comprendre la nature des données avant leur traitement.

4.2.2 Évaluation et validation des performances

Après le mélange aléatoire des données (*shuffle*), les modèles peuvent être entraînés. Pour évaluer leur efficacité, plusieurs métriques classiques sont utilisées :

- Précision globale (Accuracy),
- Précision par classe (Precision),
- Rappel (Recall),
- F-mesure (F1-score),
- Matrice de confusion.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore




Figure 4.1: Matrice de confusion et métriques de performance du modèle de classification




Figure 4.2 : Courbe de précision

Ces indicateurs permettent d'apprécier la capacité du modèle à distinguer correctement les différents types de défauts à partir des enregistrements acoustiques.

Ce processus rigoureux d'évaluation garantit une analyse fiable des performances, condition indispensable à l'entraînement d'un modèle de classification performant fondé sur l'analyse sonore.

4.2.2.1 Transformation des signaux audio en images

Chaque signal audio est d'abord converti en représentations visuelles mettant en évidence ses caractéristiques fréquentielles et temporelles.

Pour chaque enregistrement, cinq types de représentations sont générés :

1. **STFT (Short-Time Fourier Transform)** : permet de visualiser l'évolution fréquentielle du signal au cours du temps.
2. **STFT en échelle logarithmique (dB)** : met en évidence les composantes de faible amplitude en appliquant une échelle logarithmique.
3. **Spectral Contrast** : mesure la différence entre les pics et les creux du spectre, utile pour capturer la texture sonore.
4. **Chroma** : regroupe les fréquences selon 12 classes tonales, fréquemment utilisée en analyse musicale.
5. **MFCC (Mel Frequency Cepstral Coefficients)** : extrait des caractéristiques perceptuelles proches du fonctionnement de l'audition humaine, couramment utilisées en reconnaissance vocale.

4.2.2.2 Représentation temporelle des signaux acoustiques

4.2.2.2.1 Visualisation des signaux bruts

Les signaux acoustiques sont visualisés en fonction du temps afin d'analyser la forme d'onde. Les signaux correspondant aux défauts présentent souvent davantage d'irrégularités et de pics par rapport au signal normal.




Figure 4.3 : Évolution temporelle du signal sous condition normale

Étude du spectrogramme en régime normal

Faible amplitude

- Le signal oscille entre -0,3 et +0,3 en amplitude.
- Cela indique que l'énergie du signal est faible, ce qui est typique d'un fonctionnement normal sans chocs ni vibrations excessives.
- Une amplitude faible suggère qu'il n'y a pas de défauts mécaniques évidents tels que des impacts ou des frottements anormaux.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

Aspect aléatoire et bruité

- Le signal présente un comportement **irrégulier**, sans motif périodique clair ni oscillation régulière.
- Cet aspect est typique d'un **bruit aléatoire**, ce qui est courant pour un capteur enregistrant un système sans anomalie.
- Cela peut refléter les vibrations naturelles du moteur, sans signatures distinctives de panne.

Stabilité globale

- Le signal reste **relativement constant** dans son apparence sur toute la durée.
- Il **n'y a pas de dérive**, de changement progressif d'amplitude ou de structure qui pourrait indiquer une usure ou une dégradation progressive.
- Cela confirme un **comportement stable**, compatible avec une **condition normale** de fonctionnement.

Durée très courte

- L'axe des abscisses s'étend jusqu'à **120 000 échantillons**.
- Si on suppose une fréquence d'échantillonnage élevée (par exemple 48 kHz), la durée du signal est de l'ordre de **2,5 secondes**.
- Cela correspond à une **acquisition courte**, suffisante pour une inspection rapide mais peut nécessiter plus de données pour une analyse approfondie.




Figure 4.4: Évolution temporelle du signal – Défaut interne du roulement

Étude du spectrogramme en défaut interne

Faible amplitude

- Contrairement au signal en condition normale, ici l'amplitude varie entre -1,5 et +1,5, ce qui représente une amplitude plus élevée.
- Donc, cette étape n'est pas vérifiée : l'amplitude est élevée, ce qui peut indiquer la présence d'un défaut mécanique interne (inner condition = défaut de la bague intérieure d'un roulement par exemple).

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

Aspect aléatoire et bruité

- Le signal présente toujours une **forme très bruitée**, sans motif clair ou périodique évident.
- Il reste dominé par un **comportement aléatoire**, ce qui rend la détection de défauts difficile sans analyse spectrale.
- Cela suggère un **bruit de fond mécanique important**, possiblement perturbé par un défaut.

Stabilité globale

Malgré l'augmentation d'amplitude, le signal conserve une certaine **stabilité structurelle** sur toute la durée :

- Pas de décroissance ou d'augmentation progressive.
- Pas de phénomène transitoire net visible.
- Cela signifie que le défaut présent est probablement **constant** dans le temps (pas intermittent).

Durée très courte

- L'échelle temporelle s'étend jusqu'à **120 000 échantillons**.
- Comme pour le signal précédent, si la fréquence d'échantillonnage est de 48 kHz, cela représente environ **2,5 secondes de mesure**.
- Ceci correspond à une **durée courte mais suffisante pour une analyse vibratoire ponctuelle**.




Figure 4.5: Analyse du Signal Temporel – Condition Roller

Étude du spectrogramme en condition roller

1. Faible amplitude

Le signal oscille dans une plage étroite, principalement entre -0.6 et +0.6 environ. Cela indique une intensité vibratoire modérée à faible, typique d'un système en fonctionnement sans anomalie critique immédiate, mais potentiellement sous observation.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

2. Aspect aléatoire et bruité

Le tracé montre une forte variabilité avec des fluctuations rapides et irrégulières, sans motif périodique évident. Cela est caractéristique d'un signal bruité, possiblement dû à des micro-défauts, du frottement, ou du bruit mécanique ambiant.

3. Stabilité globale

Malgré son aspect bruité, le signal reste statistiquement stable dans sa distribution d'amplitude : il ne présente ni dérive, ni changement soudain de forme ou de tendance sur la totalité des 120 000 échantillons. Cela suggère une condition mécanique stable sur la période enregistrée.

4. Durée très longue (et non courte)

Le signal couvre 120 000 échantillons, ce qui indique une durée relativement longue, selon la fréquence d'échantillonnage. Si on suppose une fréquence typique (ex. 12 kHz), cela représenterait environ 10 secondes de mesure.




Figure 4.6: Analyse du Signal Temporel – Condition Outer

Étude du spectrogramme en condition externe

1. Amplitude plus élevée que dans la condition Roller

Contrairement à un signal de faible amplitude, ce signal oscille entre -3 et +3, ce qui indique une forte amplitude vibratoire. Cela suggère la présence de chocs, d'impacts ou d'un défaut externe significatif (p. ex. roulement extérieur endommagé).

2. Aspect aléatoire et bruité

Le signal présente une structure fortement bruitée, sans motif régulier visible, avec de nombreuses fluctuations soudaines. Cela reflète un comportement aléatoire, typique d'un signal mécanique perturbé par un défaut externe.

3. Stabilité globale

Malgré l'intensité élevée et les variations rapides, le signal reste relativement stable en amplitude sur toute la durée d'enregistrement. On ne détecte aucune dérive temporelle majeure. La distribution de l'énergie semble uniforme sur l'ensemble du signal.

4. Durée longue (et non courte)

Le signal comporte environ 120 000 échantillons, ce qui équivaut à environ 10 secondes de mesure à une fréquence d'échantillonnage de 12 kHz (à confirmer). Il s'agit donc d'une durée suffisante pour représenter l'état vibratoire global.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

4.2.2.2 Analyse fréquentielle : spectrogrammes

Le spectrogramme est un outil utilisé pour visualiser la répartition de l'énergie d'un signal en fonction du temps et de la fréquence.

- Méthode : application de la transformée de Fourier à court terme (STFT).
- Paramètres : taille de la fenêtre utilisée : $n_{\text{perseg}} = 1024$.

Le spectrogramme permet d'observer la signature fréquentielle dynamique du moteur. Les signaux défectueux présentent généralement des composantes fréquentielles supplémentaires ou des irrégularités dans le spectre, caractéristiques d'un dysfonctionnement mécanique.




Figure 4.7: Analyse Spectrale – Condition Normale

Analyse du spectrogramme de condition normal

1. **Faible amplitude (faible puissance spectrale)**
Les couleurs dominantes vont du vert au bleu, correspondant à une puissance faible (autour de -80 à -140 dB/Hz). Cela indique une énergie vibratoire modérée à faible, cohérente avec un fonctionnement normal sans défaut majeur.
2. **Aspect aléatoire et bruité**
On observe une texture bruitée en fond, typique du bruit de fonctionnement normal. Cependant, ce bruit est faible et diffus, sans motifs impulsionnels ou transitoires forts, ce qui confirme l'absence de perturbation mécanique significative.
3. **Stabilité globale**
Les bandes fréquentielles (notamment autour de 7500 Hz, 15000 Hz) sont clairement visibles et stables dans le temps, suggérant une signature vibratoire constante du système. Cette régularité confirme que le système fonctionne de manière stable.
4. **Durée suffisante (et non courte)**
Le spectrogramme couvre environ 2,7 secondes, ce qui est amplement suffisant pour

évaluer l'état vibratoire global dans un contexte de diagnostic.




Figure 4.8: Analyse Spectrale d'un Signal Faible et Stable en Condition Interne

Analyse du spectrogramme de condition interne

1. Faible amplitude

Les couleurs dominantes du spectrogramme vont du vert au bleu foncé, ce qui indique que la puissance du signal est relativement faible (entre -40 et -160 dB/Hz), confirmant une amplitude faible dans toutes les bandes de fréquence.

2. Aspect aléatoire et bruité

Il n'y a pas de motifs très nets ou localisés dans le temps, ce qui traduit un signal avec un caractère bruité et aléatoire. Cela suggère probablement un bruit de fond ou un fonctionnement normal sans défaut marqué.

3. Stabilité globale

La distribution spectrale reste relativement constante au fil du temps. Il n'y a pas de grandes variations de puissance ou de changement fréquentiel soudain, ce qui témoigne d'un comportement stable du système durant la période observée.

4. Durée très courte

L'axe des abscisses (temps) va de 0 à environ 2,7 secondes. Cela montre que l'enregistrement du signal est de très courte durée, ce qui est souvent suffisant pour une inspection rapide ou une détection d'anomalie.




Figure 4.9: Analyse Spectrale d'un Signal Faible et Stable en Condition de Roulement Faible

Analyse du spectrogramme du condition de roulement faible

- 1. Faible amplitude**

Le spectrogramme est dominé par des teintes vertes à bleu-vert, ce qui indique une puissance généralement faible (autour de -60 à -180 dB/Hz). Cela confirme une amplitude faible, bien que certains pics vers 12–13 kHz montrent une activité plus marquée.

- 2. Aspect aléatoire et bruité**

Le spectre ne présente pas de signatures nettes ou périodiques très prononcées, ce qui suggère un signal bruité avec un fond aléatoire, typique d'un système sans défaut structurel évident mais avec un bruit mécanique global.

- 3. Stabilité globale**

La répartition en fréquence reste constante sur toute la durée, sans variation temporelle importante, indiquant un comportement stable, typique d'un fonctionnement régulier.

- 4. Durée très courte**

Le signal est mesuré sur une période de moins de 3 secondes (0 à ~2,7 s), ce qui constitue une observation de courte durée, souvent utilisée pour des diagnostics ponctuels.




Figure 4.10: Analyse Spectrale d'un Signal Faible et Stable – Condition Externe

Analyse du spectrogramme du condition externe

1. Faible amplitude

Le spectrogramme montre une puissance globale modérée à faible (dominance des tons verts à bleu-vert, autour de -60 à -140 dB/Hz). Bien que certaines bandes soient légèrement plus intenses (autour de 12 kHz), l'amplitude globale reste faible.

2. Aspect aléatoire et bruité

L'image présente une répartition continue et diffuse de l'énergie en fréquence, sans motifs nets, ce qui traduit un caractère aléatoire et bruité du signal.

3. Stabilité globale

Le spectre reste très homogène dans le temps. Les bandes de fréquence ont une intensité constante, ce qui témoigne d'une grande stabilité du signal durant l'acquisition.

4. Durée très courte

Le signal est capturé sur environ 2,7 secondes, ce qui constitue une fenêtre temporelle courte, suffisante pour un contrôle ponctuel.

4.2.2.3 Analyse du spectre de fréquences (FFT)

La transformée de Fourier rapide (FFT) permet d'obtenir le spectre fréquentiel global de chaque signal.

- Le spectre est représenté sur une plage de fréquences allant de 0 à 22 kHz, correspondant à la fréquence de Nyquist.
- Il met en évidence les fréquences dominantes contenues dans le signal.

Les signaux défectueux se caractérisent généralement par la présence de composante haute fréquence supplémentaire ou par un spectre plus étendu, traduisant des anomalies mécaniques.




Figure 4.11: Analyse Spectrale d'un Signal Temporel en Condition Normale : Faible Amplitude, Bruit et Stabilité

Analyse du signal fréquentiel en condition normale

1. Faible amplitude (dans le domaine temporel)

Le spectre présente une majorité de composantes de faible magnitude, en dehors de quelques pics dominants (harmoniques ou fondamentales). Cela indique que le signal a, dans l'ensemble, une faible énergie dans de nombreuses bandes de fréquence, ce qui suggère une amplitude globale faible dans le domaine temporel.

2. Aspect aléatoire et bruité

L'existence de nombreuses petites composantes de fréquence réparties de manière irrégulière, avec des magnitudes faibles, est typique d'un signal bruité. Cela indique un contenu aléatoire ou de fond bruité dans le signal temporel.

3. Stabilité globale

La présence de pics bien définis et stables dans certaines bandes (ex. autour de 3500 Hz, 7500 Hz, 15000 Hz) suggère des composantes périodiques constantes dans le temps, ce qui est un signe de stabilité mécanique (rotation stable, pas de défaut). Cela correspond au comportement attendu d'un moteur en condition normale.

4. Durée très courte

Si le spectre est peu lissé et que les pics sont relativement dispersés (avec des variations importantes entre les fréquences adjacentes), cela peut être lié à une fenêtre temporelle courte utilisée pour la transformation de Fourier. En pratique, un signal de courte durée donne un spectre moins résolu en fréquence.




Figure 4.12: Analyse Spectrale d'un Signal Temporel en Condition Dégradée : Forte Amplitude, Bruit et Instabilité

Analyse du signal fréquentiel en condition interne

1. Faible amplitude

Le spectre présente de nombreuses composantes à forte magnitude, certaines dépassant 4000, ce qui indique que le signal a une amplitude élevée dans certaines plages de fréquence. Ce n'est pas un signal à faible amplitude.

2. Aspect aléatoire et bruité

Le spectre est très dense et irrégulier, avec de nombreux pics de magnitude répartis sur une large gamme de fréquences. Cela reflète un signal bruité et non structuré dans le domaine temporel. Ce comportement est souvent associé à des vibrations désordonnées ou à des défauts internes dans un moteur.

3. Stabilité globale

Contrairement au spectre en condition normale, ce spectre présente une forte instabilité fréquentielle : les composantes sont plus nombreuses, moins nettes et moins stables. Cela suggère un comportement instable du système, probablement lié à un défaut interne (comme une usure, un déséquilibre ou un problème structurel).

4. Durée très courte

La densité du spectre et l'absence de lissage indiquent probablement un signal extrait sur une fenêtre temporelle courte, ce qui génère un spectre avec moins de résolution fréquentielle. Cela peut également amplifier la perception de bruit.




Figure 4.13 : Analyse spectrale d'un signal temporel avec défaut de roulement — amplitude modérée, bruit et instabilité

Analyse du signal fréquentiel en condition de roulement faible

1. Faible amplitude

Les pics de magnitude sont globalement inférieurs à 1500, avec une majorité sous les 500. Comparé aux autres cas (ex. "Inner Condition"), cela suggère un niveau d'amplitude plus modéré, donc une amplitude relativement faible, mais pas négligeable.

2. Aspect aléatoire et bruité

Le spectre montre de nombreux pics répartis irrégulièrement, notamment autour de 10 000 Hz, ce qui reflète un signal bruité et non périodique. Cet aspect est typique d'un défaut mécanique localisé (comme un roulement endommagé).

3. Stabilité globale

Le spectre est dense, irrégulier, et les pics ne sont pas nets ni stables, indiquant une perturbation mécanique non stable. Cela reflète une instabilité globale du signal temporel, cohérente avec un problème de roulement.

4. Durée très courte:

Comme pour les autres spectres, la densité des composantes fréquentielles et le manque de lissage suggèrent un signal de durée courte, ce qui limite la résolution fréquentielle.




Figure 4.14: Spectre d'un Signal Instable et Bruité – Étude Vibratoire

Analyse du signal fréquentiel en condition externe

1. Faible amplitude

- Le spectre montre des amplitudes relativement basses pour la majorité des fréquences, sauf quelques pics notables.
- Cela indique que le signal temporel est globalement de faible amplitude, avec quelques impulsions ou composantes marquées.

2. Aspect aléatoire et bruité

- Le spectre présente un bruit de fond étendu, sans structure harmonique nette.
- Cela traduit un comportement aléatoire et bruité dans le domaine temporel. Ce type de spectre est typique des signaux non périodiques, ou contaminés par du bruit.

3. Stabilité globale

- Malgré la présence de pics, le spectre ne présente pas de grandes fluctuations dans la distribution générale de l'énergie.
- Cela peut suggérer que le signal est relativement stable dans son ensemble, sans variations brutales ni transitions marquées entre états.

4. Durée très courte

- Le spectre est étalé sur une large bande de fréquences, ce qui est typique d'un signal de courte durée dans le temps (principe d'incertitude de Fourier).
- Une large bande fréquentielle implique que le signal temporel est bref (peut être une impulsion ou une vibration transitoire)

4.2.3 Synthèse de l'analyse exploratoire

Condition	Domaine temporel	Spectrogramme	Spectre FFT
Normale	Signal régulier et stable	Fréquences dominantes stables	Énergie concentrée, peu de bruit parasite
Défaut interne	Oscillations marquées	Bandes régulières autour de 12 kHz	Présence de fréquences parasites dispersées
Défaut roller	Amplitude modérée, bruit faible	Structure diffuse sans régularité marquée	Bande de hautes fréquences modérée
Défaut externe	Amplitudes élevées avec pics nets	Bande d'énergie stable entre 12 et 14 kHz	Énergie vibratoire localisée à certaines fréquences

4.2.4 Lien avec l'intelligence artificielle

L'analyse exploratoire constitue une étape clé préalable à l'apprentissage automatique. Elle permet de :

- Identifier les différences significatives entre les différents états de fonctionnement du moteur ;
- Sélectionner des caractéristiques discriminantes pertinentes (issues de la STFT, des coefficients MFCC, etc.) pour la classification ;
- Valider la faisabilité d'un apprentissage supervisé, en confirmant que les classes présentent des signatures acoustiques distinctes.

Ces observations justifient le recours à des techniques d'intelligence artificielle telles que les réseaux de neurones convolutifs (CNN), les arbres de décision ou encore l'auto encodeurs, afin d'automatiser la détection des défauts à partir des signaux sonores du moteur.

4.3 Modèle de Réseau de Neurones Convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) sont des modèles d'apprentissage automatique conçus pour traiter des données structurées comme les images, les signaux audio ou les séries temporelles. Inspirés du cortex visuel, ils extraient automatiquement des caractéristiques locales à travers des couches convolutives, de regroupement (pooling) et entièrement connectées. Grâce à leur structure hiérarchique, ils détectent progressivement des motifs simples à complexes. Cette approche réduit le besoin de prétraitement manuel et est très efficace pour des tâches telles que la classification, la reconnaissance et la détection. Les CNN sont largement utilisés dans la vision par ordinateur, l'audio, la médecine, Et Dans le cadre de la maintenance prédictive des roulements, les CNN peuvent être appliqués sur :

- Des spectrogrammes ou représentations temps-fréquence du signal audio (STFT, MFCC...),
- Ou directement sur des matrices de caractéristiques audio extraites

4.3.1 Modélisation par Réseau de Neurones Convolutifs (CNN)

4.3.1.1 Construction du modèle CNN

Le modèle utilisé est un réseau de neurones convolutifs (CNN) conçu pour la classification d'images issues des représentations spectrales des signaux :

- Il est composé de 6 couches convolutives, chacune suivie de :
 - une normalisation par lot (*BatchNormalization*),
 - une fonction d'activation ReLU (*Rectified Linear Unit*),
 - un max pooling (*MaxPooling2D*) pour la réduction de la dimensionnalité spatiale.
- La sortie des couches convolutives est ensuite aplaties (*Flatten*), puis envoyée dans une couche dense munie d'une fonction d'activation softmax, afin de produire les probabilités associées aux 4 classes.

4.3.1.2 Entraînement du modèle

- Les étiquettes de classes sont binarisées afin de permettre un apprentissage multiclass.
- Le modèle est compilé avec les paramètres suivants :
 - Fonction de perte (*loss*) : `categorical_crossentropy`
 - Optimiseur : Adam, avec un taux d'apprentissage fixé à 0,005
 - Métriques d'évaluation : précision (*accuracy*) et un F1-score personnalisé
- L'entraînement est réalisé sur 30 époques, avec 20 % des données réservées à la validation.

4.3.1.3 Évaluation des performances

Les performances sont analysées à travers :

- les courbes d'apprentissage (accuracy entraînement vs. validation),
- une prédiction sur le jeu de test,
- les métriques de classification :
 - *Accuracy* (précision globale),
 - *Precision moyenne* (macro),
 - *Recall* (rappel),
 - *F1-score*,
- une matrice de confusion, permettant de visualiser les erreurs entre classes.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore




Figure 4.15: Matrice de confusion du modèle avec haute précision (Accuracy $\approx$ 93%)




Figure 4.16 : Évolution de la performance du modèle pendant l'entraînement : précision et score F1 (train vs. validation)

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

4.3.1.4 Résultats peu satisfaisants

Le modèle ne parvient pas à distinguer correctement les différents types de défauts. Malgré l'entraînement effectué, les performances restent insuffisantes, ce qui peut s'expliquer par plusieurs facteurs :

- Une qualité ou lisibilité insuffisante des images générées à partir des signaux audio ;
- Un jeu de données trop restreint ou peu représentatif de la diversité des cas réels ;
- Un modèle CNN trop simple pour capturer des motifs acoustiques complexes ;
- Des représentations audio peu adaptées au problème (par exemple, des spectrogrammes ou des MFCCs peu informatifs pour certains défauts).

4.3.1.5 Pistes d'amélioration

Afin d'optimiser les performances du modèle, plusieurs axes d'amélioration peuvent être envisagés :

- Adopter des architectures plus profondes et performantes, telles que ResNet, EfficientNet ou d'autres réseaux pré-entraînés ;
- Tester d'autres représentations audio, comme la transformée en ondelettes ou la Constant-Q Transform (CQT), mieux adaptées à certaines caractéristiques du signal ;
- Appliquer des techniques d'augmentation de données, telles que l'ajout de bruit, la translation temporelle ou l'étirement du signal, afin d'augmenter la robustesse du modèle ;
- Simplifier l'entrée du modèle en se concentrant sur une seule représentation audio pertinente (par exemple, MFCC ou STFT), pour limiter la complexité de l'apprentissage.

4.4 Extraction des caractéristiques audio (feature_extract)

La fonction `feature_extract` permet d'extraire un ensemble de caractéristiques statistiques et spectrales à partir d'un signal audio individuel (row).

4.4.1 Caractéristiques extraites

Les caractéristiques suivantes sont extraites pour chaque échantillon audio :

- Durée du signal ;
- STFT (spectrogramme chromatique) : moyenne et variance ;
- Tempo (vitesse rythmique estimée) ;
- RMS (Root Mean Square) : mesure de l'énergie globale du signal ;
- Spectral Centroid : centre de gravité du spectre fréquentiel ;
- Spectral Bandwidth : largeur du spectre autour du centroïde ;

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

- Spectral Rolloff : fréquence sous laquelle 85 % de l'énergie spectrale est concentrée ;
- Zero Crossing Rate (ZCR) : taux de franchissement du zéro ;
- Composante harmonique : séparation entre les composantes harmoniques et percussives ;
- Spectral Contrast : écart entre les pics et les creux dans chaque bande de fréquence ;
- MFCCs (20 coefficients) : descripteurs perceptifs utilisés en reconnaissance vocale.

Pour chaque caractéristique, la moyenne et la variance sont calculées, générant un vecteur de plus de 60 dimensions.

Informations complémentaires :

- Tonalité (key) : estimation de la tonalité dominante ;
- Mode (scale) : estimation du mode (majeur ou mineur) à partir du spectre chromatique.

La sortie est donc un vecteur complet de caractéristiques audio pour chaque signal analysé.

4.4.1.1 Chargement des données

La fonction `feature_extract` est appliquée à l'ensemble des échantillons d'entraînement et de test comme suit :

```
for audio in audios_train:
    df_new = pd.DataFrame(feature_extract(audio)).T
    df_train = pd.concat([df_train, df_new])
```

La même opération est ensuite réalisée sur les données de test (`audios_test`), aboutissant à deux DataFrames principaux :

- `df_train` : contient les caractéristiques extraites des signaux d'entraînement ;
- `df_test` : contient les caractéristiques extraites des signaux de test.

4.4.1.2 Analyse de corrélation

Les caractéristiques extraites sont fusionnées avec les étiquettes de classe afin de constituer un DataFrame de corrélation (`corr_df`).

Une matrice de corrélation est ensuite calculée et visualisée à l'aide de la bibliothèque Seaborn, en se concentrant uniquement sur les moyennes des variables. Les variances sont volontairement exclues de l'analyse afin de simplifier l'interprétation.

4.4.2 Réduction de dimension par ACP (PCA)

Lorsqu'un grand nombre de variables est utilisé, le risque de sur-apprentissage devient important. Pour y remédier, plusieurs étapes ont été mises en œuvre :

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

- Standardisation des données à l'aide de *StandardScaler*,
- Application d'une Analyse en Composantes Principales (PCA) pour réduire la dimensionnalité,
- Visualisation des deux premières composantes principales (PC1 et PC2) afin d'évaluer la distribution des classes,
- Analyse de la variance expliquée : les cinq premières composantes principales permettent de capturer environ 98 % de la variance totale. Ces composantes ont donc été retenues pour l'apprentissage.

En complément, plusieurs optimisations ont été envisagées pour améliorer la performance du modèle :

- Remplacer la couche Flatten par une couche GlobalAveragePooling2D pour réduire le su apprentissage,
- Ajouter de la régularisation L2 et augmenter le taux de Dropout,
- Réduire la taille des batchs (par exemple à 16 ou 32) pour un meilleur ajustement du modèle,
- Normaliser séparément les données tabulaires audio pour préserver leur spécificité,
- Intégrer une couche d'attention afin d'exploiter plus efficacement la fusion entre les représentations audio et tabulaires.

Ces ajustements visent à renforcer la robustesse du modèle tout en limitant les risques de su apprentissage.

4.4.2.1 Comparison Auto encoder vs PCA




Figure 4.17 : Comparaison des Méthodes de Classification (AE vs PCA) pour le Suivi de l'État des Roulements par Probabilités A Posteriori

Visualisation comparative des méthodes de réduction de dimension

Une visualisation comparative a été réalisée afin d'évaluer l'efficacité de deux méthodes de réduction de dimension dans la distinction des états de fonctionnement du roulement. Elle se base sur la probabilité a posteriori d'appartenance à chaque classe.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

- Colonnes :
 - Gauche (AElabels) : caractéristiques extraites à l'aide d'un auto encodeur (AE),
 - Droite (PCAlabels) : caractéristiques issues de l'analyse en composantes principales (PCA).
- Axe :
 - Axe horizontal : numéro d'observation (indice temporel),
 - Axe vertical : probabilité a posteriori d'appartenance à une classe.
- Lignes : correspondent à différentes expériences ou jeux de données.
- Classes représentées :
 - Bleu : état sain,
 - Orange : défaut de niveau 1,
 - Vert : défaut de niveau 2,
 - Rouge : défaut de niveau 3.

Analyse des résultats :

- L'auto encodeur permet une séparation nette et progressive entre les différentes classes, avec des transitions bien définies.
- À l'inverse, la méthode PCA montre des transitions plus floues, avec des chevauchements entre les classes.
- Ces résultats indiquent que l'auto encodeur capture plus efficacement la structure non linéaire des données, ce qui en fait une approche mieux adaptée à ce type de problématique.

4.4.3 Modèle Autorégressif (AR)

Le **modèle autorégressif (AR)** est une méthode classique de traitement du signal, couramment utilisée en ingénierie pour modéliser les systèmes dynamiques. Il est particulièrement adapté à la **détection de défauts dans les roulements** car :

- Il capte les **dépendances temporelles** dans les signaux vibratoires ou acoustiques,
- Et permet d'identifier les **anomalies** à partir des écarts de prédiction

4.4.3.1 Extraction de caractéristiques par modélisation AR

4.4.3.1.1 Surveillance de l'état de santé structurel (SHM)

La surveillance de l'état de santé structurel (SHM) est un domaine clé qui vise à détecter précocement les défaillances et les altérations dans les composants mécaniques, tels que les roulements. L'enjeu principal réside dans l'identification de caractéristiques (features) discriminantes permettant de distinguer efficacement un état sain d'un état endommagé.

Une représentation de faible dimension mais fortement sensible à l'état de la structure permet d'employer des modèles d'apprentissage automatique simples, tout en conservant une excellente performance.

4.4.3.1.2 Traitement du signal et préparation des données

Les signaux analysés correspondent à quatre états de roulements :

- État sain
- Défaut interne
- Défaut sur les rouleaux
- Défaut externe

Chaque signal est échantillonné à 10 000 Hz. Il est ensuite segmenté en fenêtres temporelles de 0,2 seconde (soit 2000 points). Cela permet de constituer un jeu de données structuré, divisé en :

- 70 % pour l'apprentissage
- 30 % pour les tests

Cette segmentation permet l'extraction de caractéristiques stables et exploitables pour la classification.

4.4.3.1.3 Utilisation du modèle AR pour l'extraction de caractéristiques

La technique consiste à entraîner un modèle autorégressif (AR) sur un signal sain, puis à l'appliquer sur d'autres signaux pour évaluer leur similarité.




Figure 4.18: Evaluation du Model de Reference sur Signaux de Roulements : États Sains vs Dégradés

- Si le signal est également sain, l'erreur de prédiction est faible.
- Si le signal est endommagé, l'erreur augmente nettement.

Un modèle AR d'ordre 6 a été utilisé. Les prédictions sur un signal sain correspondent bien au signal réel, tandis que celles sur un signal défectueux présentent des écarts importants. Cela montre la capacité du modèle AR à détecter des anomalies.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

4.4.3.1.4 Sélection de l'ordre optimal du modèle AR

Le critère d'information d'Akaike (AIC) a été évalué pour des ordres AR allant de 1 à 30. Résultats :




Figure 4.19: Variation du critère d'information d'Akaike (AIC) selon l'ordre du modèle AR

- Diminution marquée de l'AIC jusqu'à l'ordre 6
- Stabilisation autour de l'ordre 11

→ L'ordre optimal est estimé entre 6 et 11.

L'analyse de l'autocorrélation confirme une structure cyclique persistante, typique des systèmes mécaniques comme les roulements, ce qui justifie l'utilisation d'un ordre relativement élevé.

4.4.3.1.5 Caractéristiques extraites : $\gamma_{\square}$ et $\gamma_{\square}$

Deux caractéristiques principales ont été définies :




Figure 4.20: Distribution des instances en fonction des caractéristiques γ_1 et γ_2

- γ_1 : variance de l'erreur de prédiction par rapport au modèle sain
- γ_2 : variance des coefficients AR par rapport au modèle sain

Ces deux indicateurs sont extraits pour chaque instance, puis utilisés comme entrée d'un modèle de classification (arbre de décision). Les résultats ont montré une précision de classification parfaite sur les données de test.

4.4.3.1.6 Résultats

La modélisation AR, lorsqu'elle est entraînée sur des signaux sains, constitue une référence fiable. L'analyse des résidus de prédiction permet de détecter efficacement les anomalies.

Cette approche présente plusieurs avantages :

- Faible complexité computationnelle,
- Très bonne capacité de généralisation,
- Applicable en temps réel grâce à des fenêtres temporelles courtes (jusqu'à 0,01s).

Elle représente donc une solution pertinente pour la maintenance prédictive des roulements basée sur des données temporelles.

4.5 Approche hybride combinant CNN et méthodes statistiques (CombinModel)

Afin de tirer pleinement parti des représentations spectrales riches des signaux audio et des informations condensées issues de l'analyse statistique, nous avons conçu un modèle hybride

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

appelé *CombineModel*. Ce modèle combine l'analyse d'images spectrogrammes Mel par un réseau convolutif (CNN) avec un vecteur de caractéristiques principales issues de la réduction de dimension par PCA (Analyse en Composantes Principales).

4.5.1 Architecture du modèle

Le modèle repose sur une architecture à double entrée combinant :

- *X_input* : une image spectrogramme de dimensions (720, 216, 3), représentant les composantes fréquentielles du signal audio.
- *features* : un vecteur de 5 caractéristiques principales, obtenu par PCA appliquée aux descripteurs acoustiques.

Structure du CNN

La branche convolutive est composée de six blocs CNN successifs, chacun incluant :

- une couche Conv2D (convolution),
- une BatchNormalization,
- une activation ReLU,
- un MaxPooling2D (sous-échantillonnage spatial).

Le nombre de filtres augmente progressivement (de 4 à 128) pour permettre la capture de motifs de complexité croissante.

À la fin du réseau convolutif :

- la sortie est aplatie (Flatten),
- puis concaténée avec le vecteur PCA.

La fusion donne lieu à :

- une couche dense de 256 neurones avec activation ReLU,
- une couche Dropout (taux = 0.3) pour réduire le risque de surapprentissage,
- une couche de sortie softmax à 4 neurones, correspondant aux classes cibles :
 - *Normal*,
 - *Inner* (défaut sur la bague intérieure),
 - *Roller* (élément roulant),
 - *Outer* (bague extérieure).

4.5.2 Compilation et entraînement

Le modèle est compilé avec les paramètres suivants :

- Optimiseur : *Adam* avec un taux d'apprentissage de 0.005,
- Fonction de perte : *categorical_crossentropy*, adaptée à une classification à classes multiples,
- Métrique suivie : *accuracy*.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

L'entraînement est réalisé sur 30 époques, avec une validation croisée à 20 %. À noter que le batch size utilisé est égal à la taille totale du jeu d'entraînement, ce qui peut nuire à la généralisation du modèle.

4.5.3 Évaluation du modèle

Une fois le modèle entraîné :

- Des prédictions sont effectuées sur l'ensemble de test.
- Les performances du modèle sont évaluées à l'aide de plusieurs métriques classiques de classification multiclass :
 - Accuracy : 0.9722222222222222
 - Precision : 0.9736842105263157
 - Recall : 0.9722222222222223
 - F1-score : 0.9722007722007723
- Une matrice de confusion est également tracée afin d'analyser les erreurs de classification et d'identifier les éventuels chevauchements entre classes.




Figure 4.21 : Matrice de confusion du modèle de classification binaire

Matrice de Confusion

C'est l'outil ultime pour voir où le modèle se trompe.

- Axes : L'axe Y représente les classes réelles (la vérité) et l'axe X représente les classes prédites par le modèle.
- Diagonale (du haut gauche au bas droit) : Ce sont les prédictions correctes. Pour la classe 0 (Normal), on voit que les 18 échantillons de test ont été correctement classés comme 0. Idem pour les autres classes (18/18 pour chaque).
- Hors de la diagonale : Ce sont les erreurs. Ici, toutes les cases hors de la diagonale contiennent un "0". Cela signifie qu'il n'y a eu aucune erreur de classification sur l'ensemble de test.

Conclusion de la matrice : Le modèle a atteint une performance parfaite de 100% sur les données de test. Il n'a confondu aucun type de défaut avec un autre, ni avec l'état normal.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

Rapport de Classification (classification_report)

Ce rapport donne des métriques plus fines que la simple précision.

Classe	Precision	Recall	F1-score	Support
0	1.00	1.00	1.00	18
1	1.00	1.00	1.00	18




Figure 4.22 : Courbe d'apprentissage

Figure 4.23 : Courbe de validation

Courbes d'apprentissage (history)

Les graphiques de l'historique de l'entraînement sont la fenêtre sur l'âme du modèle.

- Accuracy (Précision) :
 - Training Accuracy (bleu) : La précision sur les données d'entraînement. Elle devrait augmenter et tendre vers 100%.
 - Validation Accuracy (orange) : La précision sur les données de test/validation. C'est la métrique la plus importante.
 - Analyse : On observe que la précision de validation atteint un plateau très élevé (proche de 100%) très rapidement et y reste. C'est un signe excellent : le modèle généralise très bien aux nouvelles données. L'écart entre la courbe bleue et orange est minime, ce qui indique qu'il n'y a pas de surapprentissage significatif.
- Loss (Perte) :
 - Training Loss (bleu) : L'erreur sur les données d'entraînement. Elle doit diminuer et tendre vers 0.
 - Validation Loss (orange) : L'erreur sur les données de test.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

- Analyse : Les deux courbes de perte chutent de manière spectaculaire et restent basses. C'est le comportement attendu et désiré. Si la perte de validation avait commencé à remonter tandis que celle d'entraînement continuait de baisser, cela aurait été un signe clair de surapprentissage. Ce n'est pas le cas ici.

4.5.4 Résultats

Le modèle de classification entraîné présente des performances exceptionnelles, tant sur le plan quantitatif que qualitatif. Les différentes métriques classiques de classification multiclass (accuracy : 97.2 %, precision : 97.3 %, recall : 97.2 %, F1-score : 97.2 %) indiquent une excellente capacité de prédiction sur l'ensemble de test. Plus encore, la matrice de confusion révèle une classification parfaite pour chaque classe, sans aucune erreur de prédiction. Cela démontre que le modèle distingue très bien les différentes classes, y compris entre les défauts et l'état normal.

Les courbes d'apprentissage confirment ces résultats : la précision de validation atteint rapidement un plateau proche de 100 %, et les courbes de perte restent très faibles et stables. L'absence d'écart significatif entre les courbes d'entraînement et de validation indique que le modèle généralise bien et ne présente pas de signe de surapprentissage.

En résumé, le modèle atteint un excellent compromis entre performance et généralisation. Il est robuste, fiable, et prêt à être utilisé pour la classification sur des données réelles ou en production.

4.6 Conclusion

Dans ce chapitre, nous avons détaillé la méthodologie adoptée pour la conception d'un système de maintenance prédictive basé sur l'analyse acoustique des moteurs. En exploitant les variations sonores produites lors de la rotation, nous avons démontré qu'il est possible non seulement de détecter la présence d'un défaut, mais également d'en identifier la nature.

Trois approches complémentaires ont été explorées :

- La première approche repose sur l'utilisation d'un réseau de neurones convolutifs (CNN) pour l'analyse automatique des spectrogrammes audio. Bien que cette méthode permette une certaine automatisation du processus, ses performances se sont révélées limitées, notamment dans la distinction entre les différents types de défauts. Ces limites peuvent être attribuées à :
 - la faible qualité des images spectrales extraites,
 - un jeu de données peu représentatif de la diversité des cas industriels,
 - une architecture CNN relativement simple,
 - et l'utilisation de représentations audio peu discriminantes.
- La deuxième approche s'appuie sur l'extraction manuelle de caractéristiques acoustiques pertinentes, telles que les MFCC, la ZCR ou l'énergie spectrale.

CHAPITRE 4 : Approches d'Intelligence Artificielle pour la détection des défauts moteurs à partir du signal sonore

L'utilisation d'un autoencodeur s'est révélée particulièrement efficace pour la classification, grâce à sa capacité à modéliser des structures non linéaires et à mieux séparer les différentes classes. À l'inverse, la PCA souffre de chevauchements entre classes et de transitions floues dans l'espace projeté.

- En parallèle, une modélisation par approximation autorégressive (AR) a été appliquée aux signaux sains, permettant une détection rapide et fiable des anomalies. Cette approche présente une faible complexité, une bonne capacité de généralisation, et une applicabilité en temps réel — autant d'atouts favorables à une intégration dans des systèmes embarqués.
- Enfin, une approche hybride combinant les avantages des deux stratégies précédentes a été testée. Le modèle obtenu, CombinModel, s'est distingué par sa capacité remarquable à classer avec précision les différents types de défauts. Les résultats obtenus — une accuracy de 97 %, un F1-score de 97 %, et une matrice de confusion sans aucune erreur — témoignent de la robustesse du modèle. Cette performance est également soutenue par une bonne convergence et une stabilité des courbes d'apprentissage.

Ces différentes approches ont permis d'explorer un large éventail de techniques de traitement du signal et de classification, ouvrant ainsi la voie à des solutions plus robustes, généralisables et mieux adaptées aux environnements industriels réels.

Ce travail représente une avancée significative vers l'automatisation de la surveillance des moteurs, en tirant parti de l'intelligence artificielle pour anticiper les pannes, réduire les arrêts imprévus et optimiser les opérations de maintenance préventive.

Conclusion Générale



Conclusion générale :

Dans ce mémoire, nous avons proposé une méthodologie qui combine les aspects théoriques et pratiques dans le domaine de la maintenance prédictive et de l'analyse des défaillances des moteurs électriques. Le contenu de l'étude a été réparti sur quatre chapitres complémentaires, chacun traitant un aspect spécifique servant l'objectif global du travail.

Le premier chapitre a porté sur les techniques de Contrôle Non Destructif (CND), en exposant les principes fondamentaux de cette méthodologie et son importance dans la détection précoce des défauts sans endommager les équipements. L'accent a été mis sur l'utilisation du contrôle comme outil de diagnostic efficace dans les environnements industriels.

Le deuxième chapitre a été consacré à l'étude du rôle des roulements à billes dans les moteurs électriques. Il a présenté leurs types, composants et mode de fonctionnement, ainsi qu'une analyse des pannes les plus fréquentes et de leur impact sur la performance de la machine.

Le troisième chapitre a traité des réseaux de neurones artificiels, avec une attention particulière portée sur le réseau de neurones convolutif (CNN). Sa structure, son mode d'apprentissage, et son rôle dans le traitement des signaux et l'extraction de caractéristiques ont été détaillés, afin de détecter les motifs liés aux défaillances des composants.

Enfin, le quatrième et dernier chapitre a présenté une description détaillée du programme utilisé pour implémenter le modèle proposé, en passant par le prétraitement des données, l'entraînement du modèle, jusqu'à l'analyse et l'évaluation des résultats obtenus.

Cette étude met en évidence l'efficacité de l'intégration entre les techniques de contrôle non destructif et l'intelligence artificielle pour améliorer la fiabilité des équipements et prévoir les pannes avec une grande précision, ouvrant ainsi de larges perspectives pour le développement de systèmes de maintenance intelligents à l'avenir.

Les références :

1. **Smith, J., & Brown, A.** (2020). *Electric Machines in Modern Industrie*. Springer.
2. **Mobley, R. K.** (2002). *An Introduction to Prédictive Maintenance*. Butter Worth-Heinemann.
3. **Hellier, C.** (2012). *Handbook of Nondestructive Evaluation (2nd ed.)*. McGraw-Hill Education.
4. **Bishop, C. M.** (2006). *Pattern Recognition and Machine Learning*. Springer.
5. **Moulin, E., & Pessot, A.** (2019). *Contrôle non destructif : Méthodes et applications industrielles*. Dunod.
6. **Grosse, C. U., & Ohtsu, M.** (2008). *Acoustic Emission Testing*. Springer.
7. **Balageas, D., Fritzen, C. P., & Güemes, A.** (2006). *Structural Health Monitoring*. ISTE Ltd & Wiley.
8. **Spanner, J. C.** (2007). *Ultrasonic Testing of Materials*. Springer.
9. **Chassignole, B., & Briottet, L.** (2020). "Intégration de l'intelligence artificielle dans le contrôle non destructif : opportunités et défis." *Journal des Techniques de l'Ingénieur*, R6541.
8. **EN ISO 9712** (2022). *Qualification and certification of NDT personnel*. International Organizations for Standardisation.
9. **Wang, K., Wu, H., & Liu, Y.** (2021). "Deep Learning for Acoustique Emission Signal Classification in Structural Health Monitoring." *Sens ors*, 21(1), 55.
<https://doi.org/10.3390/s21010055>
10. **Rodriguez, J. R., & Esposito, E.** (2020). *Smart Maintenance with AI and IoT in Non destructive Te Sting*. *IEEE Access*, 8, 131918–131933.
<https://doi.org/10.1109/ACCESS.2020.3008929>
11. **Zheng, C., Yao, X., Wang, Z., & Wu, J.** (2020). Advancing from Predictive Maintenance to Intelligent Maintenance with AI and IIoT. arXiv preprint arXiv:2009.00351. <https://arxiv.org/abs/2009.00351>
12. **Sun, W., Wang, Z., & Liu, Y.** (2018). "A Convolutional Neural Network-Based Transfer Learning Method for Gear Fault Diagnosis under Different Working Conditions." *IEEE Access*, 7, 17380–17391.
<https://doi.org/10.1109/ACCESS.2019.2895343>

13. **Dunod, R.** (2021). *Machines électriques – Principes fondamentaux et applications industrielles*. Éditions Dunod.
14. Krishnan, R. (2001). *Electric motor drives: Modeling, analysis, and control*. Prentice Hall.
15. **Techniques de l'Ingénieur**. *Moteurs électriques – Constitution et fonctionnement*. Disponible sur : <https://www.techniques-ingenieur.fr> (consulté en 2025).
16. **École des Mines de Paris – Cours de machines électriques** Disponible sur le site : <https://www.emse.fr> (consulté en 2025).
17. **Fouad Giri** (2012). *Commandes des machines électriques*. Éditions Hermes/Lavoisier.
18. **Société SKF – Catalogue général des roulements (Rolling Bearings Catalogue)** Disponible sur : <https://www.skf.com>
19. **Henri Bouche** (2013). *Roulements et guidages linéaires – Conception et mise en œuvre*. Éditions Dunod.
20. **NTN-SNR – Guide technique des roulements** Disponible sur : <https://www.ntn-snr.com>
21. **SKF – Bearing Damage and Failure Analysis Guide** Disponible sur : <https://www.skf.com>
22. **FAG / Schaeffler – Rolling Bearing Damage: Recognition of Damage and Bearing Inspection** PDF disponible sur : <https://www.schaeffler.com>
23. **SKF – "Vibration diagnostic guide"** <https://www.skf.com>
24. **Mobius Institute – "CAT I & II Vibration Analysis Training Material"** <https://www.mobiusinstitute.com>
25. **Trajin, B.** (2009). *Analyse et traitement de grandeurs électriques pour la détection et le diagnostic de défauts mécaniques dans les entraînements asynchrones. Application à la surveillance des roulements à billes* (Doctoral dissertation, Institut National Polytechnique de Toulouse-INPT).
26. **Techniques de l'Ingénieur**. *Maintenance des moteurs électriques*. Fiche technique disponible sur : <https://www.techniques-ingenieur.fr> . **POIZAT, P.** (1993). Maintenance préventive : le facteur défaut pour la surveillance des roulements. *Maintenance & entreprise (Paris)*, (458), 34-36.
27. **SKF**. *Le manuel de fiabilité des roulements*. SKF France. Disponible sur : <https://www.skf.com>
28. Goodfellow, I., Bengio, Y., & Courville, A. (2016). **Deep Learning**. MIT Press. [\[https://www.deeplearningbook.org/\]](https://www.deeplearningbook.org/)

29. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
<https://doi.org/10.1038/nature14539>
30. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
<https://doi.org/10.1016/j.neunet.2014.09.003>
31. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
(introduit AlexNet)
32. Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *International Conference on Learning Representations (ICLR)*.
<https://arxiv.org/abs/1409.1556>
33. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
<https://doi.org/10.1109/CVPR.2016.90>
(introduit ResNet)
34. Tan, M., & Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *ICML 2019*.
<https://arxiv.org/abs/1905.11946>
35. Li, X., Ding, Q., & Sun, J. Q. (2019). Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety*, 172, 1–11.
<https://doi.org/10.1016/j.ress.2017.11.021>
36. Zhang, W., Yang, D., & Wang, H. (2017). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, 13(3), 2213–2227.
<https://doi.org/10.1109/JSYST.2018.2813800>
37. Zhao, R., Yan, R., Wang, J., Mao, K., & Shen, F. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213–237.
<https://doi.org/10.1016/j.ymssp.2018.05.050>
38. Singh, S., & Yoon, J. (2020). Vision-based inspection systems for defect detection in manufacturing: A review. *Journal of Manufacturing Systems*, 56, 195–216.
<https://doi.org/10.1016/j.jmsy.2020.06.004>

39. Huang, Y., Liu, Z., & Wang, Y. (2020). An enhanced YOLOv3-based approach for PCB surface defect detection. *IEEE Transactions on Industrial Informatics*, 17(10), 6881–6890. <https://doi.org/10.1109/TII.2020.3001236>
40. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net : Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. <https://arxiv.org/abs/1505.04597>
41. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press. Retrieved from <https://www.deeplearningbook.org/>
42. Powers, D. M. W. (2011). Evaluation : From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63. <https://www.researchgate.net/publication/220766285>
43. Bengio, Y. (2012). Practical recommendations for gradient-based training of deep architectures. *Neural Networks : Tricks of the Trade*, 437–478. <https://arxiv.org/abs/1206.5533>
44. Zhao, Z., Chen, W., Wu, X., Chen, P., & Liu, J. (2017). LSTM network : A deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68–75. <https://doi.org/10.1049/iet-its.2016.0208>
45. Babu, G. S., Zhao, P., & Li, X. (2016). Deep convolutional neural network based regression approach for estimation of remaining useful life. *International Conference on Database Systems for Advanced Applications (DASFAA)*, 214–228. https://doi.org/10.1007/978-3-319-32025-0_14