



Mémoire de Master

Filière : Electronique

Spécialité : Electronique des systèmes embarqués

Présenté par : HOCEINE FATIMA

Maintenance préventive des moteurs par émission acoustique

Proposé Par :

Mme CHEGGAGA Nawal.

Année Universitaire : 2024-2025.

Remerciement

Avant tout, je rends grâce à Dieu le Tout-Puissant et Miséricordieux, qui est pour moi la source de l'énergie, de la patience, et de la persévérance, tout au long de ce travail.

Je tiens à exprimer mes sincères remerciements à Mme Che gaga pour son accompagnement, ses conseils et sa disponibilité. Son expertise a été un soutien des plus précieux et opérationnels dans la réalisation de ce projet.

Nous tenons également à exprimer notre profonde gratitude aux membres de notre jury, Mme KAOULA et Mme BOUGHRIRA H. Pour l'honneur qu'elles nous font en prenant part à ce jury. Leurs compétences, ainsi que leurs remarques constructives, ont grandement contribué à l'enrichissement de notre travail

Je remercie la famille pour sa présence, son soutien constant, et ses encouragements tout au long de cette étude.

Ainsi que toutes les personnes qui ont contribué, de près ou de loin, à l'élaboration de ce travail.

Dédicace

Ce présent travail est le fruit de toute ma reconnaissance :

À toi mon cher Papa,

Qui as toujours su donner toute la mesure du travail, de l'effort, du sérieux à la vie. Ton soutien inconditionnel, ton amour discret, ta confiance ont été pour moi les fondations de l'histoire ce que je suis. Que Dieu te donne la santé, la paix, la longue vie.

À toi, ma chère Maman, Tes câlins, ta patience, ta force tranquille ont été pour moi des sources inépuisables d'inspiration. Ton amour m'a portée à chaque moment de ce chemin. Que Dieu t'accompagne et te donne tous les bonheurs de cette terre.

À mon frère et à mes sœurs, Merci pour votre présence, votre affection et vos encouragements. Chacun de vous a contribué, à sa manière, à rendre ce chemin plus doux et plus riche de sens. Ce travail vous est dédié avec tout mon amour.

À ma chère Luna, Ta présence à mes côtés, ton écoute, ta patience et ton soutien continus m'ont beaucoup réconforté. En te remerciant pour ta gentillesse, pour chaque mot, chaque geste. Puisse la vie de te rendre la bienveillance que tu sais distribuer autour de toi.

À toute ma famille, Merci pour chaque marque d'attention, chaque conseil, chaque prière. Votre amour et votre confiance ont été essentiels tout au long de cette aventure.

Et à toutes celles et ceux qui, de près ou de loin, ont contribué à la réalisation de ce travail,

Recevez l'expression de ma plus sincère reconnaissance.

الملخص

يعد هذا المشروع جزءاً من نهج مبتكر لتطوير نظام صيانة وقائية للمحركات، استناداً إلى التحليل الصوتي مع الذكاء الاصطناعي. والهدف من ذلك هو اكتشاف الأعطال الميكانيكية في المحامل في مرحلة مبكرة، مثل الشقوق الدقيقة أو عيوب التلامس أو اختلال المحاذاة. ويستخدم النظام شجرة قرارات لتصنيف حالات تشغيل المحرك تلقائياً، مما يسهل التدخل السريع والموجه. هذا النظام مناسب للأنظمة الموجودة على متن الطائرة، خاصة في البيئات الصعبة مثل الفضاء الجوي،

ويزيد من موثوقية الماكينة ويقلل من تكاليف الصيانة التصحيحية ويمنع عمليات الإغلاق غير المخطط لها

الكلمات المفتاحية: الصيانة الوقائية، التحليل الصوتي، الذكاء الاصطناعي، شجرة القرار، أعطال المحامل، الأنظمة المدمجة

Résumé

Ce projet s'inscrit dans une démarche innovante visant à développer un système de maintenance préventive pour moteurs, en s'appuyant sur l'analyse acoustique associée à l'intelligence artificielle. L'objectif est de détecter précocement les défaillances mécaniques au niveau des roulements, telles que les microfissures, les défauts de contact ou les désalignements. Le système utilise un arbre de décision pour classer automatiquement les états de fonctionnement du moteur, facilitant ainsi une intervention rapide et ciblée. Adapté aux systèmes embarqués, notamment dans les environnements exigeants comme l'aéronautique, ce dispositif permet d'augmenter la fiabilité des machines, de réduire les coûts liés à la maintenance corrective et de prévenir les arrêts non planifiés.

Mots clés : Maintenance préventive, Analyse acoustique, Intelligence artificielle, Arbre de décision, Défauts de roulements, Systèmes embarqués.

Abstract

This project is part of an innovative approach to developing a preventive maintenance system for motors, based on acoustic analysis combined with artificial intelligence. The aim is to detect early mechanical failures in bearings, such as microcracks, contact defects or misalignments. The system uses a decision tree to automatically classify motor operating states, facilitating rapid, targeted intervention. Suitable for on-board systems, particularly in demanding environments such as aeronautics, this system helps to increase machine reliability, reduce corrective maintenance costs and prevent unplanned downtime.

Keywords: Preventive maintenance, Acoustic analysis, Artificial intelligence, Decision tree, Bearing faults, Embedded systems.

Liste des acronymes et abréviations

AFNOR : Association Française de Normalisation.

AMDEC : Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité.

AT : Test Acoustique.

BPFO : Ball Pass Frequency Outer.

BPFI : Ball Pass Frequency Inner.

BSF : Ball Spin Frequency.

BTS :Brevet de Technicien Supérieur.

CBM : Condition-Based Maintenance.

CND :Contrôle Non Destructif.

EA :Émission Acoustique.

END :Essais Non Destructifs.

FTF :Fundamental Train Frequency.

GMAO :Gestion de Maintenance Assistée par Ordinateur.

HSE :Hygiène, Sécurité, Environnement.

IA : Intelligence Artificielle.

IEE :Institute of Electrical Engineers.

IRT : InfraRouge Thermographie .

LOT : Internet des Objets Industriels.

LT : Test d'Étanchéité.

MP : Maintenance Préventive.

MT : Magnétoscopie.

MTBF : Mean Time Between Failures.

MTTR : Mean Time To Repair.

NDT : Non-Destructive Testing.

PDM : Predictive Maintenance.

PT : Contrôle par ressuage.

SNR : Rapport Signal sur Bruit.

USA : United States of America.

UT : Ultrasons Testing.

Table des matières

Remerciement

Dédicace

Résumé

Liste des acronymes et abréviations

Introduction générale 1

Chapitre I : Fondements théoriques de la maintenance préventive

I.1 Introduction 4

I.2 Définition de la maintenance 4

I.2.1. Évolution historique de la maintenance 5

I.2.2 Utilité de la maintenance en milieu industriel 8

I.2.3 Les différents niveaux de complexité de maintenance 9

I.2.4 Typologie des Stratégies de Maintenance..... 10

I.2.5 Types de maintenance préventive 11

I.2.6 Les opérations de la maintenance préventive 13

I.2.7 Analyse Comparative des Stratégies de Maintenance 13

I.3 La Gestion de Maintenance Assistée par Ordinateur(GMAO) 14

I.4 Risques liés à l'absence de maintenance 15

Conclusion 17

Chapitre II : Description des défauts visés

II.1 Introduction..... 19

II.2.CND (le contrôle non destructif) 19

II .2.1L'importance de contrôles non destructifs 19

II.2.2Principes généraux..... 20

II.2.3 Les domaines de CND 20

II.2.4 Différentes méthodes de contrôle	21
II.3 les avantages	23
II.4 Désavantages.....	24
II.5 Les moteurs d'engins industriels	24
II.5 .1 Généralité sur les roulements	24
II.5.2 architecture de roulement	25
II.5.3 Matériaux utilisés pour les roulements	25
II.6 Défauts rencontrés sur les roulements	26
II.6 .1Types de défauts localisés	26
II.6 .2 Causes principales de dégradation.....	27
II.7les phases de défaillance des roulements	28
II.8 Les défauts courants détectés par émission acoustique	29
Conclusion	31

Chapitre III : Analyse des données acoustiques et classification des défauts

III.1Introduction	33
III.2L'arbre de décision (Fondements et application)	33
III.2.1Principe de l'arbre de décision	33
III.2.2 Les Avantages et les Inconvénients des Arbres de décision.	34
III.2.3 Apprentissage et optimisation (paramètres, critères de division)	35
III.3 Évaluation de la performance du modèle de classification	36
III.3.1 Utilisation d'un ensemble de test.....	37
III.3.2 Métriques utilisées.....	37
III. 4 Développement de l'approche	39
III. 4.1Collect de données	39
III.4.2 Analyse physique des défauts par observation directe.....	41
III.5 Séparation des données et prétraitement	43
III.6 Évaluation des performances du modèle	45

III.7 Influence de la durée de l'échantillonnage sur l'efficacité de la classification	47
Conclusion	51

ChapitreIV: testes de robustesses

IV .1Introduction	53
IV.2 Bruit.....	53
IV.2 .1Bruit et apprentissage automatique	53
IV.2 .2Les différents types de bruits	54
IV.3Résultats du test de robustesse.....	57
IV.3.1 Enregistrements bruités	56
IV.3.2 Évaluation des performances du modèle	58
IV .3.3 Analyse comparative.....	61
IV.3.4 : Analyse des matrices de confusion	63
IV.3.5 Comparaison des performances avant et après ajout du bruit.....	64
IV.4 Interprétation avec arbre de décision.....	66
IV.5 Test de Robustesse par Allongement de la Durée des Signaux Audio	67
IV.5.1 Comparaison des métriques de classification par classe avant et après bruit et allongement du signal.....	71
IV.6 Discussion des limites du modèle et pistes d'amélioration.....	72
IV.6.1 Limites du modèle.....	72
Conclusion.....	73
Conclusion générale	76
Référence	78

Liste des figures

Figure I. 1 : Illustration d'une opération de maintenance — état avant et après intervention[10].....	5
FigureI .2: Évolution chronologique de la maintenance industrielle [12].	8
FigureI.3: Importance stratégique de la maintenance industrielle [14].	9
FigureI .4:présente les principales catégories de maintenance [16].....	10
FigureI. 5 : GMAO(La Gestion de Maintenance Assistée par Ordinateur) [25].....	14
Figure II.6: Synoptique de la mise en œuvre d'un système CND [30].	20
Figure II.7: Principaux Domaines d'Application du CND.	21
Figure II. 8:Tableau présentant les différentes méthodes de CND [32].	21
Figure II. 9:Architecture d'un roulement à bille [38].	25
Figure II. 10:Organigramme des matériaux des éléments roulants [39].....	25
Figure II. 11:Montre les éléments cruciaux d'un roulement à billes [41]	27
Figure II.12: Représentation du signal sonore en fonctionnement normal du moteur.....	29
Figure II.13: Représentation du signal sonore en présence d'un défaut de la bague intérieure.	30
Figure II.14: Représentation du signal sonore en présence d'un défaut de rouleau.....	30
Figure II. 15: Représentation du signal sonore en présence d'un défaut de la bague extérieure.....	31
Figure III. 16: La figure illustre les principaux composants d'un arbre de décision.....	34
Figure III.17: Représentation graphique d'un arbre de décision et partition de l'espace des attributs [49].	36
Figure III. 18: Comparaison des méthodes de séparation : partition itérative des variables (gauche) vs. Combinaison linéaire des variables (droite) [49].....	36
Figure III.19: Illustration de la matrice de confusion [50].	37
Figure III. 20: illustrer l'usage des spectres temps-fréquence.	40
Figure III.21: Observation supervisée des signaux temporels pour différents états de roulements (normal, défaut interne, sur rouleaux et externe).	41
Figure III.22: illustrer l'usage des spectre temps-fréquence (après traitement).....	42
Figure III. 23: Premier Arbre de Décision Généré pour la Classification les données.	43
Figure III. 24: Arbre de Décision pour la Classification des Défauts à Partir de Données de Spectrogramme.....	44
Figure III. 25: Arbre de Décision après Test de Classification des Défauts Vibratoires et Acoustiques d'un Moteur.....	44
Figure III. 26: Matrice de confusion du modèle de classification.	45
Figure III. 27: Évaluation des Performances avec les Données Propres.....	46
Figure III. 28: Matrice de confusion du modèle après allongement des échantillons à 1 seconde.....	48
Figure III. 29: Analyse de l'Arbre de Décision après Augmentation à 1 Seconde.	49
Figure III.30: Évaluation des Performances après Augmentation de la Durée à 1 Seconde.	49
Figure IV. 31:Signaux audio bruités pour les quatre classes de roulements.	56
Figure IV.32: Spectrogrammes bruités pour les quatre conditions de roulements.....	57

Figure IV.33: Matrice de confusion du modèle sur les signaux audio bruités.....	58
Figure IV. 34: Performances avec données bruitées.	59
Figure IV.35: Arbre de Décision pour la classification des défauts de roulements (après ajout de bruit).	60
Figure IV. 36: Représentation des signaux vibratoires selon les types de défauts et la présence de bruit.....	61
Figure IV. 37: Spectrogrammes des signaux vibratoires selon les types de défauts avec la présence de bruit.....	62
Figure IV.38: Comparaison des matrices de confusion avant et après ajout de bruit sur les signaux acoustiques.	64
Figure IV. 39: Performances avec données propres (avant bruit).....	66
Figure IV. 40: Performances avec données bruitées (après ajout de bruit).....	66
Figure IV.41: Signaux audio bruités prolongés (1 seconde) pour les quatre classes de roulements.	67
Figure IV. 42: Spectrogrammes bruités pour les quatre classes de roulements (durée 1 seconde).	68
Figure IV. 43: Matrice de confusion du modèle en condition bruitée (durée 1 seconde). ..	69
Figure IV.44: Arbre de Décision pour la classification des défauts (durée 1 seconde).	70
Figure IV. 45: Résultats de classification après extension des signaux à 1 seconde et ajout de bruit blanc gaussien.....	71
Figure IV.46: Comparaison des performances par classe selon différentes méthodes de traitement (avant bruit, après bruit, après bruit + 1s) sur les métriques de précision, rappel et F1-score.	72

Liste des tableaux

Tableau I. 1: représente les différents niveaux de complexité de maintenance [15] .	9
Tableau I.2 : présent les stratégies de la maintenance [23].	13
Tableau II.3 : Principales causes de dégradation des roulements et leur répartition en pourcentage [42].	27
Tableau III. 4 : Avantages et Inconvénients des Arbres de décision [47].	34
Tableau IV. 5 : comparatif des signaux audio selon le type de défaut et la présence de bruit.	61
Tableau IV. 6: Comparaison des spectrogrammes des signaux vibratoires selon les types de défauts avec et sans bruit.	62
Tableau IV.7: Comparaison entre l'arbre de décision sans bruit et avec bruit.	66

Introduction générale

Introduction générale

Dans l'industrie actuelle centrée avantageusement sur la confiance, la sécurité et la performance énergétique, la maintenance des moteurs (engins) est une fonction stratégique pour chaque industrie. Certaines pratiques traditionnelles de maintenance qui dépendent de la planification ou de l'intervention de réparation ne répondent plus aux besoins des industriels d'une disponibilité opératoire régulière et ininterrompue. C'est dans cette vision que la maintenance préventive et prédictive devient une fonction d'économie directe pour chaque industriel.

Les moteurs utilisés dans des machines industrielles, qui se retrouvent fréquemment dans des secteurs tels que l'énergie, le transport et la construction, sont soumis à des conditions d'exploitation extrêmes : charges lourdes, vibrations élevées et changements de température. Ces éléments augmentent la probabilité d'apparition des défauts, notamment au niveau des roulements. La détection rapide de ces problèmes préventifs permet d'éviter l'arrêt de production indésirable, de ne pas subir un coût de maintenance important et de ne pas engendrer de problèmes liés à la sécurité de l'exploitation. Les conséquences de cette méthode sont lourdes d'enjeux. Économiquement déjà, le U.S. Département of Energy mentionne une diminution de 35 % [1] des coûts de maintenance corrective et de 45 % [2] des temps d'arrêt machine générés par cette technologie en matière de développement durable. Le développement des méthodes de maintenance préventive permet d'augmenter la durée de vie de système électronique . selon une étude de SKF (2023), la durée de vie des moteurs industriels a augmenté de 20 % [3] , Le Fraunhofer Institute, quant à lui, estime que cette approche permettrait d'abaisser l'empreinte carbone de 15 %[4] grâce à une meilleure gestion des déchets et de l'énergie.

Dans le cadre de ce travail, des enregistrements acoustiques de moteurs en fonctionnement ont été exploités pour documenter différents états : un état de fonctionnement normal, ainsi que des types de défauts précis. grâce auxquels un certain nombre de signatures fréquentielles spécifiques à chaque type de défaut peuvent être identifiées

Pour optimiser l'exploitation des signaux : Les enregistrements seront transformés en spectrogrammes peuvent permettre l'analyse automatisée . ainsi que des analyses temporelles et fréquentielles employée, couplée à un algorithme de classification par arbre de décision.

Cet outil d'intelligence artificielle, entraîné à l'aide de bases de données étiquetées, permet d'effectuer une classification rapide, fiable et peu coûteuse de l'état de fonctionnement. Ce modèle, transparent et adapté aux systèmes embarqués, constitue une solution pertinente pour la mise en œuvre d'une maintenance préventive intelligente.

Mais quels sont les défis techniques et organisationnels à surmonter pour intégrer efficacement une stratégie de maintenance intelligente basée sur l'émission acoustique, capable de détecter avec précision les trois types de défauts majeurs des moteurs industriels ?

La mémoire contient quatre différents chapitres :

- ✚ Le Première chapitre présente la maintenance et les différents types de maintenance.
- ✚ Le deuxième chapitre est consacré à l'étude des techniques de contrôle non destructif appliquées aux moteurs, en mettant particulièrement l'accent sur la détection des défauts de roulements par la méthode d'émission acoustique.
- ✚ Dans ce troisième chapitre, nous analysons en détail l'arbre de décision intégré à notre système embarqué, qui permet une classification rapide et interprétable des défauts moteurs à partir de spectrogrammes.
- ✚ Le quatrième chapitre, nous testons la robustesse de l'approche. L'objectif est d'évaluer sa capacité à détecter les défauts en conditions industrielles perturbées.

Chapitre I :

Fondements théoriques de la maintenance préventive.

Chapitre I : Fondements théoriques de la maintenance préventive

I.1 Introduction

Dans des environnements industriels où la continuité des processus est un impératif et où la performance des équipements est un enjeu central, la maintenance se positionne comme le pilier de la performance. Elle doit contribuer à la fois à la longévité des machines et à la réductions des impacts économiques des arrêts de production[5].

Historiquement, la maintenance s'est révélée tout à fait réactive, c'est-à-dire qu'elle ne s'enclenchait qu'une fois qu'un premier dysfonctionnement était intervenu [6]. Là où elle en était incapable jusqu'ici, la technologie a permis à travers le temps de se mettre au service de tendances plus adaptées à la montée en performance et en compétitivité requise par le champ industriel : préventive, Dès lors, puis prédictive, puis proactive.

Dans le cadre de cette dynamique d'évolution, la GMAO (Gestion de Maintenance Assistée par Ordinateur) occupe une place prépondérante [7]. C'est elle qui offre la meilleure visibilité sur l'état des équipements, qui favorise la planification des interventions, qui optimise la gestion des pièces de rechange, et qui permet d'anticiper les défaillances à l'aide de divers indicateurs tels que le MTTR (temps moyen de réparation) et le MTBF (temps moyen entre pannes)[8].

I.2 Définition de la maintenance

Le maintien des équipements de production représente un enjeu fondamental pour assurer la productivité des entreprises, tout autant que la qualité des produits fabriqués. Face aux évolutions technologiques rapides, cela constitue un véritable défi industriel, nécessitant de remettre en question les structures figées traditionnelles et d'encourager l'adoption de méthodes mieux adaptées aux nouvelles réalités du matériel moderne.

Examinons quelques définitions de la maintenance :

➤ d'après l'AFNOR (NF X 60-010)[9]

« Ensemble des actions permettant de maintenir ou rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé », L'AFNOR explique que la maintenance, c'est toutes les actions qui servent soit à garder une machine dans un état

Chapitre I : Fondements théoriques de la maintenance préventive

précis (par exemple, qu'un moteur tourne sans problème), soit à réparer pour qu'elle puisse à nouveau rendre le service demandé (comme pomper de l'eau, soulever une charge, etc.).

« Maintenir » contient la notion de « prévention » sur un système en fonctionnement, "maintenir" veut dire agir avant qu'il y ait un problème, Par exemple : changer l'huile d'un moteur avant qu'il ne casse. C'est de la prévention.

« Rétablir » implique l'idée de « correction » suite à une dysfonction, « Rétablir » signifie remettre en état après une défaillance : Lorsque qu'un équipement tombe en panne, nous agissons pour résoudre le dysfonctionnement et rétablir son fonctionnement.



Figure I. 1 : Illustration d'une opération de maintenance — état avant et après intervention[10].

✚ Cette figure met en évidence la différence entre l'état défectueux d'un système et son état après réparation, illustrant ainsi la portée des actions de maintenance.

I.2.1. Évolution historique de la maintenance

I.2.1 .1Des Origines aux Années 1940 «La Maintenance Réactive [11]

Chapitre I : Fondements théoriques de la maintenance préventive

- Contexte : Avant la Seconde Guerre mondiale, les machines industrielles, robustes et lentes, fonctionnaient avec peu d'exigences de productivité. Les pannes étaient rares et les interventions se limitaient à des réparations ponctuelles (maintenance corrective).
- Limites : Aucune planification ni prévention. Les arrêts de production n'étaient pas critiques en raison d'une faible intégration des systèmes.

I.2.1.2 Années 1950-1980 (Naissance de la Maintenance Planifiée) [11]

- Post-Seconde Guerre mondiale
- Reconstruction industrielle → Augmentation des cadences de production.
- Pannes plus fréquentes → Coûts des arrêts et réparations en hausse.
- Émergence de la maintenance préventive → Inspections périodiques et graissage systématique.
 - **Image de la maintenance**
- Perçue comme une activité secondaire, axée sur la mécanique et l'électricité.
- Absence de normes ou de stratégies structurées.

I.2.1.3. Années 1980-2000 : Sécurité, Normes et Professionnalisation [11]

- **Prise de conscience sécuritaire**
- Secteurs à risque (chimie, énergie) développent des procédures pour protéger les opérateurs.
- La maintenance devient un levier de prévention des accidents
- **Normalisation**
- 1979-1985 : Normes AFNOR X60 et X60 000 en France.
- 1987-1996 : Normes ISO 9000 (qualité) et ISO 14000 (environnement).
- Formation : Création des premiers BTS et cursus spécialisés (années 1980).
- **Complexification des systèmes**
- Mondialisation → Machines plus spécialisées et intégrées.
- Adoption de concepts innovants (maintenance productive inspirée du Japon).

I.2.1.4. Années 2000-2020 : Défis et Transition vers l'Industrie 4.0 [11]

- **Enjeux économiques**
- Compétitivité accrue → Tolérance zéro pour les pannes.

Chapitre I : Fondements théoriques de la maintenance préventive

- Coûts de maintenance en hausse (complexité technologique).
- **Défis sectoriels**
- Pénurie de main-d'œuvre qualifiée (image peu attractive des métiers de maintenance).
- Délocalisations et pression sur les marges.
- **Émergence des outils numériques**
- GMAO (Gestion de Maintenance Assistée par Ordinateur)
- Centralisation des données (historique des interventions, plans de maintenance).

Exemple : Mobility Work, solution mobile pour planifier et suivre les tâches.

Maintenance prédictive : Capteurs IoT et analyse de données pour anticiper les pannes.

I.2.1.5. Ère Actuelle (2020+) : Vers la Maintenance 4.0 [11]

➤ **Technologies clés**

IA et Big Data : Algorithmes pour prédire l'usure (ex. analyse vibratoire, acoustique).

Digital Twin : Simulation en temps réel pour optimiser les interventions.

Solutions cloud et mobiles : Accès aux données en temps réel (ex. Mobility Work).

➤ **Avantages**

Réduction des temps d'arrêt (MTTR) et augmentation de la fiabilité (MTBF).

Optimisation des coûts (moins de pièces de rechange, interventions ciblées).

➤ **Défis persistants**

- Formation aux nouvelles compétences (IA, IoT).
- Attractivité des métiers techniques auprès des jeunes.

I.2.1.6. Étude de Cas : Mobility Work, un Outil de la Révolution 4.0 [11]

➤ **Fonctionnalités clés**

- Calendrier intelligent : Planification des interventions préventives et correctives.
- Analytique prédictive : Identification des tendances d'usure.
- Collaboration : Partage d'informations entre techniciens et responsables.

➤ **Impact**

Chapitre I : Fondements théoriques de la maintenance préventive

- Transition vers une maintenance proactive (anticipation des pannes).
- Amélioration de la productivité et de la sécurité .




Figure I.2: Évolution chronologique de la maintenance industrielle [12].

L'évolution historique détaillée ci-dessus se concentre dans la Figure (I.2) : Évolution chronologique de la maintenance industrielle, qui montre la montée en maturité des pratiques de maintenance, en lien avec la complexité croissante des systèmes et l'augmentation des données disponibles. Chaque saut technologique correspond à un nouveau paradigme dans la gestion des équipements.

I.2.2 Utilité de la maintenance en milieu industriel


L'intérêt de la maintenance au sein d'une entreprise offre plusieurs bénéfices :

Tout d'abord, l'entretien est indispensable pour assurer la sécurité des utilisateurs des équipements. Elle prévient donc les imprévus risqués et diminue le temps d'interruption en cas de défaillance. Cela pourrait avoir des répercussions dommageables sur le budget de

Chapitre I : Fondements théoriques de la maintenance préventive

l'entreprise. Si les équipements ne sont pas opérationnels, la production est interrompue et la faillite pourrait éventuellement se produire. Ainsi, la maintenance a une grande importance pour la durabilité d'une entreprise. Elle simplifie aussi votre tâche en mettant en place une approche d'analyse. Par exemple, vous êtes capable d'identifier les anomalies d'un équipement et d'organiser par la suite les interventions et actions requises. Cela vous évite d'attendre que la réparation devienne trop onéreuse.

Comme le montre la figure ci-dessous, la maintenance représente à elle seule 67 % du cycle de vie d'un projet logiciel, bien plus que les autres étapes telles que la conception, l'implémentation ou les tests. Cela souligne l'importance stratégique de la maintenance pour garantir la continuité, la performance et la fiabilité des systèmes en exploitation.



FigureI.3: Importance stratégique de la maintenance industrielle [14].

Chapitre I : Fondements théoriques de la maintenance préventive

I.2.3 Les différents niveaux de complexité de maintenance

Tableau I. 1: représente les différents niveaux de complexité de maintenance [15].

Niveau de maintenance	Actions	Intervenants	Moyens
1	Travaux simples (Réglages, contrôle).	Exploitant sur place.	Outillage léger définis dans les consignes de conduites.
2	Travaux courants (réparations et échanges standards simples).	Personnel habilité.	Outillages standard et rechanges situées à proximité.
3	Diagnostic, réparations et remplacements.	Technicien qualifié.	Outillage prédéfinis et appareils de mesure.
4	Travaux importants de maintenance préventive ou corrective.	Technicien ou équipe Spécialisée.	Outillage général et Spécialisé.
5	Travaux de rénovation et reconstruction.	Constructeur du matériel ou société spécialisée.	Moyens importants, proches de ceux du constructeur.

I.2.4 Typologie des Stratégies de Maintenance

Il existe deux principales catégories de maintenance, comme illustré dans la figure (I.4) .




Figure I. 4:présente les principales catégories de maintenance [16].

Chapitre I : Fondements théoriques de la maintenance préventive

I.2.4 .1 Maintenance Corrective

La maintenance corrective est la maintenance réalisée après détection d'une panne, défaillance, d'un défaut ou dysfonctionnement et destinée à rétablir l'équipement ou l'installation, dans un état lui permettant d'accomplir sa fonction.

Deux cas sont distingués :

- **le dépannage :** activités, souvent réalisées dans un délai bref, permettant de pallier provisoirement une panne, défaillance, un défaut ou dysfonctionnement ;
- **la réparation :** activités, réalisées immédiatement ou de façon différée, permettant d'apporter une solution définitive à une panne, défaillance, un défaut ou dysfonctionnement.

I.2.4.2 Maintenance Préventive

La maintenance préventive (MP) également appelée maintenance technique programmée, fait référence à l'action d'effectuer des opérations sur un équipement à des intervalles fixes ou selon des critères établis. Son but principal est de minimiser les risques de défaillance sur les biens, les machines et les équipements, tout en contribuant à l'atteinte d'objectifs plus globaux. C'est la raison pour laquelle une majorité d'usines et de sociétés s'efforcent d'accroître la proportion de maintenance préventive par rapport à la maintenance corrective. Fonctionne aujourd'hui de plus en plus Grâce à la machine Learning, à l'analyse des données opérationnelles et à la surveillance prédictive de l'état des actifs, les ingénieurs peuvent optimiser la maintenance et réduire les risques de fiabilité des opérations, qu'elles concernent une usine ou une entreprise. Les logiciels dédiés à la maintenance préventive contribuent à garantir des opérations constantes, à respecter les garanties et à traiter les dysfonctionnements avant qu'ils ne perturbent la production [19].

I.2.5 Types de maintenance préventive

I.2.5.1 La maintenance préventive systématique ou planifiée (Time-Based)

La maintenance de la prévention systématique est une méthode de gestion active de l'équipement et des systèmes. Contrairement à la maintenance corrective, qui intervient après

Chapitre I : Fondements théoriques de la maintenance préventive

qu'un équipement a connu une panne, la maintenance systématique repose sur des procédures de maintenance régulières et programmées visant à anticiper les incidents.

La fréquence des interventions est établie à compter de la mise en fonctionnement du bien ou à la suite d'une révision partielle ou complète de celui-ci.

Exemple : Le changement d'huile sur une machine peut être défini au bout d'un certain nombre de semaines d'utilisation sans contrôle spécifique préalable [21].

I.2.5.2 La maintenance préventive basée sur les conditions(CBM)

La maintenance préventive fondée sur l'état des équipements s'appuie sur l'utilisation de capteurs et d'instruments pour surveiller leur performance en temps réel. Contrairement à la maintenance planifiée suivant un calendrier fixe, la maintenance conditionnelle intervient uniquement en fonction de l'état réel d'exploitation des équipements.

Par exemple, une analyse régulière des huiles d'une machine permet de repérer les signes de pollution, l'usure des composants et la qualité du lubrifiant. Cela permet de remplacer ce dernier uniquement lorsqu'il ne satisfait plus aux critères nécessaires pour garantir un fonctionnement optimal.

I.2.5.3La maintenance préventive prévisionnelle (PDM)

La maintenance prévisionnelle, également appelée maintenance prédictive, se définit selon l'AFNOR comme une maintenance conditionnelle réalisée à partir de prévisions basées sur l'analyse et l'évaluation de paramètres significatifs liés à la dégradation d'un équipement.

Son objectif principal est d'anticiper les besoins en maintenance, permettant ainsi de prévenir pannes et défaillances. Il s'agit d'une approche appartenant à l'univers de la maintenance 4.0, reposant sur une surveillance continue des variations de certains paramètres, des seuils critiques et des données collectées via différents outils (comme un logiciel GMAO). Cette méthode offre une gestion précise, permettant d'initier les interventions appropriées en fonction des analyses globales effectuées.

L'utilisation d'un logiciel de gestion de maintenance assistée par ordinateur (GMAO) constitue une solution pertinente pour assurer un suivi rigoureux des interventions, collecter des données fiables et élaborer un plan de maintenance optimisé. Grâce à cette approche, on

Chapitre I : Fondements théoriques de la maintenance préventive

mise davantage sur l'anticipation et le prévisionnel, tout en réduisant la part des actions correctives.

I.2.6 Les opérations de la maintenance préventive

Ces opérations peuvent être divisées en quatre catégories d'actions :

- Le premier groupe concerne la maintenance : il comprend les opérations suivantes : le nettoyage, l'assainissement et le traitement de surface.
- La surveillance constitue le deuxième groupe : qui comprend les actions telles que l'inspection, le contrôle et la visite.
- Le troisième groupe concerne la révision : il comprend les opérations suivantes : la révision partielle et la révision intégrale.
- Le quatrième groupe se focalise sur la préservation et comprend les actions suivantes : la conservation, la préservation temporaire et l'opérationnalisation.

I.2.7 Analyse Comparative des Stratégies de Maintenance

Pour mieux saisir les distinctions entre les principales approches de maintenance industrielle, le tableau ci-dessous offre une comparaison basée sur divers critères essentiels, tels que la finalité, la méthode, les coûts, la technologie employée, ainsi que les bénéfices et inconvénients de chaque approche.

Tableau I.1 : présent les stratégies de la maintenance [23].

Paramètres	Maintenance Corrective	Maintenance Préventive
Nature	Réactive	Proactive
Activité	Moins complexe et ne nécessite pas de planification	Plus complexe et nécessite une planification
Mise en œuvre	Après une défaillance de l'équipement	Avant une défaillance de l'équipement
Coût	Initialement économique mais coûteux à long terme	Coûteux au départ mais économique à long terme
Durée de vie de l'actif	Non optimisée	Optimisée
Fréquence de maintenance	Élevée	Faible

Chapitre I : Fondements théoriques de la maintenance préventive

Performance	Performance réduite par rapport à la maintenance préventive	Meilleure performance
-------------	---	-----------------------

I.3 La Gestion de Maintenance Assistée par Ordinateur(GMAO)

La Gestion de Maintenance Assistée par Ordinateur (GMAO) est devenue un atout incontournable pour les entreprises industrielles cherchant à optimiser la gestion de leur maintenance. Grâce à ses fonctionnalités avancées, la GMAO offre une visibilité complète sur les parcs de machines, les stocks de pièces détachées, et les plannings d'intervention des techniciens. Voir la figure(I.5).



FigureI. 5 : GMAO(La Gestion de Maintenance Assistée par Ordinateur) [25].

Réduction des coûts de maintenance

La GMAO permet de réduire significativement les coûts liés à la maintenance. Voici comment :

- Vue d'ensemble des coûts : En centralisant toutes les informations relatives aux coûts de maintenance, les entreprises peuvent mieux planifier et budgétiser leurs dépenses.
- Optimisation des opérations : Grâce à une meilleure organisation des plannings et interventions, les opérations sont plus efficaces.

Chapitre I : Fondements théoriques de la maintenance préventive

- Achats groupés : Les entreprises peuvent regrouper leurs achats de pièces détachées pour bénéficier de tarifs préférentiels.

Amélioration de la productivité

L'un des principaux avantages de la GMAO est son impact positif sur la productivité :

- Estimation des temps de réparation (MTTR) : La GMAO permet de prévoir avec précision la durée des réparations, ce qui facilite la planification des interventions.
- Fréquence des interventions (MTBF) : En analysant les données, la GMAO aide à réduire le nombre d'interventions nécessaires, diminuant ainsi le temps d'indisponibilité des machines.

Augmentation de la durée de vie des équipements

Une maintenance optimisée permet d'allonger la durée de vie des équipements industriels :

- Prolongation de la longévité : Les équipements bien entretenus peuvent voir leur durée de vie prolongée de 5 à 10% [26].
- Rendement à long terme : Des machines en bon état de fonctionnement assurent un meilleur rendement et réduisent le besoin de remplacement fréquent.

I.4 Risques liés à l'absence de maintenance

L'absence ou l'insuffisance de maintenance dans le milieu industriel engendre de nombreux risques, à la fois humains, financiers et organisationnels. Ces risques touchent non seulement les techniciens de maintenance mais aussi le personnel de production.

a) Risques humains (accidents et expositions professionnelles)

Les opérations de maintenance, en particulier les interventions correctives d'urgence, sont parmi les plus accidentogènes. En Europe, 15 à 20 % [27] des accidents du travail et 10 à 15 % [27] des accidents mortels sont liés à la maintenance. Ces accidents surviennent pendant, avant ou après les interventions (réglages, essais, déplacements...).

Les principales victimes sont :

- les techniciens de maintenance (internes, sous-traitants, contractants), qui présentent un risque d'accident deux fois plus élevé que la moyenne.

Chapitre I : Fondements théoriques de la maintenance préventive

- le personnel de production, souvent impliqué dans la maintenance en urgence ou exposé aux conséquences de défaillances techniques non prises en charge.

Des exemples concrets montrent que des manquements dans la communication, l'organisation ou la coordination des interventions peuvent entraîner des blessures graves, notamment lors de Co activités ou d'interventions non sécurisées.

b) Risques financiers : pertes économiques

Les arrêts non planifiés sont causés par des défauts de maintenance qui peuvent entraîner des coûts élevés pour l'entreprise:

- Perte de productivité.
- Dépenses imprévues en réparations d'urgence.
- Pénalités de retard et insatisfaction des clients.

Par exemple, un arrêt de production de quelques heures dans l'industrie automobile peut coûter plusieurs centaines de milliers d'euros.

C) Risques sur l'image de l'entreprise

Un manque de rigueur dans la gestion de la maintenance peut affecter la réputation de l'entreprise :

- Clients mécontents
- Non-conformité réglementaire
- Détérioration de la marque employeur
- Retrait de partenaires ou d'investisseurs.

d) Risques organisationnels

Les petites entreprises sont particulièrement vulnérables, avec un risque d'accident jusqu'à 8 fois plus élevé qu'en grande entreprise, en raison :

- du manque de moyens.
- d'une faible structuration des processus (absence de GMAO, plan de prévention...).
- d'une gestion HSE (Hygiène, Sécurité, Environnement) souvent insuffisante.

Chapitre I : Fondements théoriques de la maintenance préventive

Conclusion

L'évolution des stratégies de maintenance industrielle s'impose comme un enjeu clé pour garantir la performance et la durabilité des équipements, les entreprises peuvent mieux maîtriser les coûts, réduire les arrêts imprévus et prolonger la durée de vie de leurs installations. Dans ce contexte, les moteurs industriels occupent une place importante. Il est utilisé pour faire fonctionner les systèmes de transport et dans le service quotidien de la compagnie dit système embarqué et peu d'entre eux, fonctionne à l'état stationnaire. La maintenance corrective peut imposer des coûts importants, la maintenance préventive est tout aussi importante.

Pour assurer la fiabilité, la sûreté et le coût des moteurs industriels, Il est beaucoup plus rentable de prévoir une panne que de la réparer.

Chapitre II :description des défauts visés

Chapitre II : Description des défauts visés

II.1 Introduction

Dans les environnements industriels exigeants, les moteurs sont soumis à des contraintes sévères qui nécessitent une surveillance rigoureuse de leurs composants. Le contrôle non destructif (CND), notamment par émission acoustique, s'impose comme une méthode efficace pour détecter précocement les défauts sans interrompre le fonctionnement des machines.

Cette technique est particulièrement utile dans la maintenance des moteurs d'engins opérant dans la construction, le transport ou l'industrie, exposés à des conditions extrêmes telles que les vibrations, les charges lourdes et les variations de température.

Parmi les éléments les plus vulnérables figurent les roulements, dont l'usure, les fissures ou le pitting peuvent entraîner des défaillances graves. Des méthodes et techniques adéquates permettent de localiser ces défauts à un stade précoce, ce qui contribue à éviter les arrêts imprévus et les réparations coûteuses. Des rapports spécifiques en la matière sont examinés dans ce chapitre, à savoir les types de défauts les plus fréquents, leur évolution dans le temps, les causes possibles et les solutions techniques pour les éviter ou les corriger efficacement.

II.2.CND (le contrôle non destructif)

Le Contrôle Non Destructif aussi appelé Essais Non Destructif ou Évaluation non destructive, est un domaine qui englobe une série de processus et de techniques qui peuvent être utilisés pour mesurer ou vérifier le respect ou l'intégralité d'une pièce ou d'un matériau sans nécessiter qu'il ne soit endommagé ou modifié de quelque manière que ce soit. Il peut même empêcher le démontage d'un objet ou d'un composant. Les techniques de mesures sans destruction sont essentielles pour l'industrie, permettant des économies substantielles en préservant des pièces coûteuses, tout en remplaçant progressivement les contrôles destructifs. encore trop présent dans l'industrie.

II .2.1L'importance de contrôles non destructifs

Le contrôle non destructif est un outil indispensable pour garantir la sécurité et la qualité des produits et des systèmes. Ce processus de vérification peut aller des fissures et autres défauts à des problèmes plus subtils dans un large éventail de préoccupations industrielles. Le CND aide à éviter des réparations ou des remplacements coûteux en détectant ces problèmes dès le départ.

Ces méthodes sont nécessaires pour assurer la qualité et la sécurité des produits et des matériaux. Elles peuvent être utilisées pour :

- Identifier les défauts.

Chapitre II : Description des défauts visés

- Évaluer la durabilité d'un matériel.
- Inspecter la taille des pièces.
- S'assurer que les produits sont conformes aux normes requises pour le contrôle qualité.

II.2.2Principes généraux

Peu importe la méthode choisie, l'implémentation d'un système CND peut être illustrée selon le schéma suivant : l'objectif est défini par un ensemble de paramètres que nous allons tenter d'évaluer pour établir un diagnostic d'intégrité. L'instauration d'un système CND approprié va générer plusieurs signaux dépendants des paramètres visés. Il est généralement indispensable de passer par une phase « d'inversion », qui peut être plus ou moins complexe, pour retrouver les paramètres d'origine de la pièce, ce qui peut être représenté par le synoptique illustré à la Figure II.6 : Synoptique de la mise en œuvre d'un système CND [30].




Figure II.6: Synoptique de la mise en œuvre d'un système CND [30].

II.2.3 Les domaines de CND

Les CND sont utilisés dans les situations où l'on recherche la sécurité, l'intégrité des matériaux comme illustré dans la Figure(II.7) .On distingue principalement :

- ✓ Maintenance préventive : se donnant pour objectif l'élimination de la possibilité du défaut dans les équipements, structures industrielles.
- ✓ Supervision de la qualité : on vérifie que les produits qu'il faut expédier respectent les normes de qualité.
- ✓ Inspection post-évènement : il serait question d'inspecter les pièces individuelles après défaut ou accident pour en comprendre la raison.
- ✓ Recherche et innovation : accompagner le développement des nouveaux produits et l'amélioration des matériaux utilisés.

Chapitre II : Description des défauts visés




Figure II.7: Principaux Domaines d'Application du CND.

II.2.4 Différentes méthodes de contrôle

Méthode END	symbole
Emission acoustique	AT
Courants de Foucault	ET
Etanchéité	LT
Magnétoscopie	MT
Ressuage	PT
Radiographie	RT
Ultrasons	UT
Examen visuel	VT
Interférométrie de Speckle	ST
Thermographie	IT

Figure II. 8:Tableau présentant les différentes méthodes de CND [32].

a) Le contrôle par ressuage (PT)

Le ressuage (PT) est une technique facile qui détecte les discontinuités ouvertes à la surface. Elle implique l'utilisation d'un fluide fluorescent ou coloré qui, après nettoyage et utilisation d'un révélateur, révèle les anomalies par suintement. Extrêmement sensible (jusqu'à 1 μm d'ouverture), elle n'est cependant pas automatisable, dépend de l'opérateur et produit des résidus non récupérables.

Chapitre II : Description des défauts visés

b) Les rayons X

L'application majeure des rayons-X dans le contrôle non destructif réside dans la réalisation d'images. Leur avantage est de fournir des données directement exploitables concernant l'intérieur des objets ou matériaux. Dans le secteur lourd, l'inspection par rayons X est principalement employée pour les soudures dans les centrales nucléaires ainsi que sur les sites de construction navale et pétrolière, pour la corrosion des tuyaux, l'analyse de la structure des matériaux composites ou encore pour détecter les fissures sur les pièces mécaniques complexes. D'autres techniques radiologiques d'inspection non destructive font appel à la fluorescence et à la spectrométrie.

c) Les ondes ultrasonores (UT)

Les ondes qui sont diffusées et répercutées fournissent des renseignements concernant l'existence ou l'absence de vices et leur caractéristique. Le faisceau sonore produit est réfléchi par les surfaces de l'espace et les défauts, avant de revenir au transducteur. L'analyse des signaux permet de localiser l'anomalie. Cette technique offre une haute résolution spatiale et la capacité d'identifier des anomalies en profondeur. Il est généralement indispensable d'examiner diverses zones de l'objet pour réaliser une modélisation 3D des anomalies.

c) La thermographie infrarouge (IRT)

Les différentes méthodes de contrôle thermique consistent à exciter un matériau ou une structure avec une source d'énergie (énergie mécanique, photonique, échauffement par induction, air chaud...). La chaleur se propage alors dans le matériau et l'influence sur la distribution de température en surface permet de donner des informations sur les propriétés thermo physiques des matériaux utilisés et des défauts éventuels. Les principaux avantages sont la possibilité de contrôle automatique et sans contact. Les inconvénients viennent de la lenteur du contrôle, du coût du matériel et de la complexité d'implantation de la mise en œuvre des étapes d'inversion permettant le diagnostic.

d) La magnétoscopie (MT)

La méthode d'inspection non destructive appelée magnétoscopie consiste à appliquer un important champ magnétique dans un matériau ferromagnétique, ce qui lorsqu'il y a un défaut dans sa trajectoire, « crée » une fuite et attire les particules (colorantes ou fluorescentes) du révélateur pour donner ainsi un titre de défaut, même signature, même symptôme.

Chapitre II : Description des défauts visés

e) L'étanchéité (LT)

Les méthodes de contrôle d'étanchéité reposent surtout sur l'emploi de gaz traceurs, associés à des appareils de mesure très sensibles aux plus faibles concentrations de ces gaz traceurs. Les plus souvent utilisés sont l'hélium, l'hydrogène (azote hydrogéné), l'utilisation du gaz SF6 est lui maintenant exclu par la réglementation. Actuellement, cette méthode n'est pourtant pas codifiée par le COFREND, elle l'est, elle, dans beaucoup d'autres pays [19] USA par exemple.

f) Les méthodes intégrées

Des techniques associées ont émergé récemment et certaines d'entre elles demeurent dans le champ de la recherche : les techniques acoustiques électromagnétiques, ultrasonores ou magnéto-optiques.

g) L'émission acoustique (AT)

L'émission acoustique est une méthode de surveillance qui consiste à collecter le son émis par une pièce ou une structure soumise à des contraintes, comme lors d'un test hydraulique ou pneumatique. La détection des ondes ultrasonores élastiques à travers le matériau, réalisée grâce à un réseau de capteurs, peut permettre une identification en temps réel des sources de dégradations du matériau (comme les fissures) et une estimation de leur gravité. C'est une approche holistique (toute la machine est vérifiée simultanément) et dynamique (les défauts non progressifs ne sont pas identifiés).

II.3 les avantages

Les avantages des CND sont nombreux :

- Préservation de l'intégrité des pièces : permet de tester sans causer de dommages.
- Efficacité économique : réduit les coûts de défaillance et de remplacement.
- Sécurité accrue : aide à prévenir les accidents en détectant les défauts tôt.
- Flexibilité : applicable à une grande variété de matériaux et de structures.
- Efficacité : Offre une évaluation rapide et précise, permettant un contrôle continu des processus de production.

Chapitre II : Description des défauts visés

II.4 Désavantages

Comme ce sont de nouvelles techniques de contrôle des bétons, certaines personnes sont moins enclines à faire confiance et à se fier aux résultats de ces nouvelles technologies. L'exactitude des résultats n'est pas totalement garantie, car plusieurs éléments peuvent les affecter, tels que le taux d'humidité du béton, la température ambiante et celle des matériaux, l'état de la surface examinée et différentes sources de perturbations. Si l'on considère uniquement le test au scléromètre, qui mesure la résistance mécanique du béton, ce dernier ne permet pas d'estimer aussi précisément la résistance qu'un essai de compression, car divers éléments peuvent affecter cette évaluation.

Selon les essais, bon nombre d'entre eux nécessitent une analyse des résultats afin d'obtenir des unités conformes à la qualité désirée.

II.5 Les moteurs d'engins industriels

Un moteur est une machine ou un dispositif conçu pour convertir une forme d'énergie en énergie mécanique [36]. Divers types de moteurs se distinguent selon leur source d'énergie et leur utilisation. Il comporte des composants rotatifs soumis à des forces mécaniques importantes, avec des roulements garantissant un mouvement.

II.5 .1 Généralité sur les roulements

Le roulement est l'un des éléments essentiels dans presque toute machine tournante. Son intérêt réside dans le fait que cet élément est conçu pour réduire le frottement de rotation de l'arbre, pour transférer des charges sur des paliers fixes et pour supporter des charges radiales et axiales. Il peut être aussi utilisé pour assurer un positionnement précis de l'arbre, et corriger des défauts d'alignement. Pour cette raison, la plupart des machines tournantes sont équipées de roulements pour supporter la charge et maintenir les jeux entre les éléments fixes et rotatifs des machines. Selon l'institut des ingénieurs électriciens et électroniciens (IEEE), les roulements, dont l'importance ne saurait être minimisée, sont les composants les plus susceptibles de connaître une défaillance dans un équipement électrique. Leur dysfonctionnement est une des problématiques fréquentes ayant une chance importante de survenir, atteignant parfois jusqu'à 90% [23] dans les machines de petite taille.

Chapitre II : Description des défauts visés

II.5.2 architecture de roulement

Un roulement est un composant composé de deux cercles concentriques, appelés bague intérieure et extérieure, qui renferment des pistes de roulement contenant des éléments roulants disposés régulièrement par le biais d'une cage. Cette cage est placée entre les anneaux et a pour rôle de réduire les frottements en empêchant les éléments de se frotter l'un contre l'autre (voir Figure II. 9). En fonction de l'application prévue, les composants de roulement peuvent être des billes, des rouleaux ou des aiguilles. Chaque type de roulement possède des caractéristiques spécifiques en termes de charges radiales et axiales qu'il est capable de supporter, de la vitesse maximale permise ou encore du degré d'alignement admissible. On trouve aussi des roulements dotés d'une flasque, une protection latérale, qui occupe l'espace entre les deux anneaux, l'un extérieur et l'autre intérieur.




Figure II. 9: Architecture d'un roulement à bille [38].

II.5.3 Matériaux utilisés pour les roulements




Figure II. 10: Organigramme des matériaux des éléments roulants [39].

Chapitre II : Description des défauts visés

La figure (II. 10) présente la répartition des matières constituant les éléments des roulements. Les éléments roulants sont en acier au chrome, renforcé par des traitements de surface et thermiques augmentant leur résistance à l'usure, Les cages sont en acier ou en plastique, en fonction des applications. Ces choix de matériaux permettent d'assurer le fonctionnement en performance et la durée de vie des roulements.

II.6 Défauts rencontrés sur les roulements

II.6 .1Types de défauts localisés

Parmi les défauts de fonctionnement les plus potentiels d'un roulement, on pourrait mettre en avant plusieurs défaillances caractéristiques localisées dans une région de roulement. Le signal de vibration où ces échantillons sont détectés a une fréquence propre. La figure ci-dessous permet de visualiser ces défaillances.

- **BPFO (Ball Pass Frequency Outer) ou fréquence de passage de la balle extérieure :** Correspond physiquement, au nombre de billes ou de rouleaux qui traversent un point spécifique de l'anneau extérieur chaque fois que l'arbre effectue une rotation complète.
- **BPMI (Ball Pass Frequency Inner) ou fréquence de passage de la balle interne :** Physiquement, cela correspond au nombre de billes ou de rouleaux qui traversent un point spécifique de la piste intérieure chaque fois que l'arbre effectue une rotation complète.
- **BSF (Ball Spin Frequency) ou fréquence de rotation de l'élément roulant :** Correspond physiquement au nombre de rotations effectuées par une bille ou un rouleau du roulement chaque fois que l'arbre effectue une rotation complète.
- **FTF (Fundamental Train Frequency) ou fréquence de défaillance de la cage :** Correspond physiquement au nombre de tours que fait la cage de roulement à chaque fois que l'arbre fait un tour complet.

Chapitre II : Description des défauts visés



Figure II. 11:Montre les éléments cruciaux d'un roulement à billes [41] .

Il existe des fréquences distinctives particulières qui peuvent être identifiées dans le spectre : Lorsque l'un des composants du roulement est endommagé, on distingue dans le spectre des fréquences la fréquence fondamentale correspondant à l'élément endommagé, toujours accompagnée d'harmoniques. Dans les cas où les paramètres physiques du roulement ne sont pas connus.

II.6 .2 Causes principales de dégradation

Les roulements représentent les composants les plus essentiels dans le fonctionnement des machines tournantes. Ils sont fréquemment exposés à des stimulations qui entraînent, dans la plupart des situations, une panne partielle ou complète de l'appareil, avec des répercussions désastreuses. D'après les statistiques du SNR [SNR 04], dans 90% [42] des situations, les origines sont à trouver parmi des facteurs externes qui peuvent d'ailleurs être condensés dans le tableau.

Tableau II.2 : Principales causes de dégradation des roulements et leur répartition en pourcentage [42].

Cause de défaut	%
Lubrification inadaptée (choix des lubrifiants, quantité, fréquence de lubrification, ...etc.)	70%
Pollution (poussière, détergents, liquides, ...etc.)	18%
Montage incorrect (brutal, jeu, désalignement, échauffement excessif, ...etc.)	10%
Fatigue (charge, contraintes)	2%

Chapitre II : Description des défauts visés

II.7 les phases de défaillance des roulements

On distingue quatre phases distinctes de défaillance des roulements :

➤ Phase 1

Dans l'étape initiale, nous observerons l'apparition de petites dépressions le long des voies de roulement, et la fréquence ultrasonore de l'élément roulant dans le spectre ne se situe pas dans la plage normale. Il est fort probable qu'à ce point, le roulement opère normalement, par exemple lors de l'examen du spectre de fréquence du roulement à peu près entre 20,000 et 60,000 Hz [43]. Bien que cela ne soit pas un motif pour changer le roulement, cela pourrait signaler une insuffisance de lubrification entre les voies de roulement et les éléments roulants.

➤ Phase 2

Lorsque l'on parvient au second degré de défaillance que l'on voit apparaître les premiers symptômes fréquemment liés à la défaillance défectueuse des roulements : le défaut du roulement commence à vibrer, selon sa fréquence propre oscillant entre 500 et 2 000 Hz [43]. Ces fréquences correspondent souvent à des résonances produites par les éléments du roulement (tels que les bagues ou les éléments roulants), ou bien par la structure qui supporte le roulement. À ce point, il est essentiel d'incorporer les mises en place de maintenance dans le programme.

➤ Phase 3

Durant cette phase, les niveaux de fréquence des défauts de roulement se manifestent clairement et des harmoniques font leur apparition sur le spectre fréquentiel. Il est crucial de déterminer le taux de dégradation si vous êtes en train de résoudre un problème où des défauts sur la voie de roulement sont clairement visibles. Par ailleurs, les roulements (dans les équipements essentiels et non essentiels) qui ont atteint ce niveau de panne doivent être remplacés sans délai.

➤ Phase 4

Les roulements arrivent à ce point lorsque leur durée de vie utile touche à sa fin, et vous constaterez une montée du bruit de la machine à divers niveaux, engendrant ainsi un spectre aléatoire à large bande. « En réalité, le niveau de bruit à haute fréquence et l'amplitude du HFE peuvent se réduire, ce qui indique que le roulement est susceptible de tomber en

Chapitre II : Description des défauts visés

défaillance. » En somme, l'objectif est d'éviter que le roulement n'arrive à ce point, mais si cela se produit, il doit être changé sans tarder.

II.8 Les défauts courants détectés par émission acoustique

Nous disposant de quatre fichiers audio de 12 secondes à partir d'un jeu de données disponible sur Kaggle(Engine Acoustic Emissions). La figure montre les impulsions (signaux) correspondantes, qui ont été générées et enregistrées à l'aide d'un script Python sous VS Code, représentant différentes circonstances opérationnelles du moteur.

- **Signal Normal**

Il apparaît que le niveau sonore du signal est relativement constant, avec des oscillations d'amplitude modérée et régulière. Il n'existe pas de phénomènes impulsifs forts, ce qui indique l'absence ou le manque de défauts mécaniques. En d'autres termes, la figure (II.12) d'un moteur fonctionnant, sans usure mécanique notable et sans bruit anormal.

À noter que dans tout signal vibratoire, l'amplitude oscille naturellement autour de zéro, traduisant les variations mécaniques dans les deux sens (positif et négatif), ce qui est parfaitement normal dans un fonctionnement sain.




Figure II.12: Représentation du signal sonore en fonctionnement normal du moteur.

- **Défaut Interne (anneau interne du roulement)**

Le signal représenté dans la figure (II.13) est caractérisé par une augmentation progressive d'impulsions plus marquées, généralement dues à un impact localisé sur l'anneau interne du

Chapitre II : Description des défauts visés

roulement. Ce type d'impact se manifeste par un son rythmique lorsque les éléments roulants (billes ou rouleaux) passent sur la zone de dégradation. Les oscillations du signal, bien que toujours centrées autour de zéro, révèlent ici des perturbations mécaniques significatives.




Figure II.13: Représentation du signal sonore en présence d'un défaut de la bague intérieure.

- **Défaut sur les éléments roulants (Roller)**

Des impulsions sont enregistrées de manière moins systématique ; elles sont plus diffuses mais plus fréquentes, avec une intensité plus faible. Cela suggère un défaut affectant directement les éléments roulants, causant une perturbation continue du signal. Comme toujours, les variations positives et négatives de l'amplitude sont liées aux alternances du mouvement vibratoire.




Figure II.14: Représentation du signal sonore en présence d'un défaut de rouleau.

- **Défaut Externe (anneau externe du roulement)**

Chapitre II : Description des défauts visés

Le signal contient principalement des impacts soudains, certains survenant en succession rapide, traduisant des dégradations plus brusques. Comme l'anneau externe est généralement fixe (ou faiblement mobile), les impacts sont plus rares mais marqués lorsqu'ils surviennent. Les fortes variations d'amplitude observées dans les deux directions (positive et négative) témoignent ici de chocs mécaniques ponctuels associés aux défauts de l'anneau externe.




Figure II. 15: Représentation du signal sonore en présence d'un défaut de la bague extérieure.

Conclusion

Ce chapitre nous a donné un aperçu sur le rôle du contrôle non destructif dans le suivi des moteurs industriels par la surveillance par émission acoustique. Nous nous sommes d'abord attentivement renseignés sur le fonctionnement des moteurs puis leurs roulements ainsi que les défauts qu'ils peuvent avoir, que ce soit des défauts localisés ou des défauts de type (gradual depletive). L'analyse des pannes des roulements met très bien en évidence l'importance de la détection précoce d'anomalies, pour des arrêts onéreux ou des accidents.

L'émission acoustique s'impose ainsi comme une technique prometteuse pour le suivi de ces composants en temps réel. La capture de signaux (normal, interne, externe, roulement) rend possible l'entraînement de systèmes de diagnostic sophistiqués. Cela impose alors cette question fondamentale : quelles sont les manières les plus éloquentes d'attraper et d'extraire toute information à la fois pertinente et utile sur des signaux acoustiques, et qu'est-ce qui peut apporter le plus à cela pour le rendre plus fiable et plus simple sur le terrain ?

Chapitre III : Analyse des données acoustiques et classification des défauts

III.1 Introduction

L'apprentissage automatique, notamment les arbres décisionnels, détient un rôle primordial dans le champ de la classification et du repérage des défauts dans plusieurs domaines [44]. Dans le cadre de ce travail, cette méthode est utilisée pour identifier les défauts mécaniques à partir des signaux acoustiques générés par les moteurs.

Ce chapitre présente les étapes essentielles de construction du modèle : depuis l'apprentissage basé sur les données jusqu'à la prédiction des classes de défauts. L'accent est mis sur la préparation des données, l'exploitation des spectrogrammes comme source d'information, ainsi que sur l'interprétation des résultats obtenus. Cette approche permet non seulement de détecter des anomalies de manière automatique, mais aussi d'évaluer la robustesse du modèle et ses limites dans un contexte industriel réel.

III.2 L'arbre de décision (Fondements et application)

Un arbre de décision, connu également sous le nom arbre décisionnel ou diagramme de décision, est une représentation graphique des résultats possibles d'une chaîne de choix. Il aide un individu ou une organisation à évaluer des alternatives potentielles selon le coût, la probabilité et le profit associés. Cela peut servir à enclencher un débat informel ou à concevoir un algorithme permettant de choisir rationnellement le meilleur choix qu'une personne se trouve à faire. Les entreprises les utilisent souvent en vue de planifier une stratégie, d'analyser une enquête et d'en tirer des conclusions. Les banques et les établissements de crédit font appel aux arbres décisionnels pour apprécier le risque des prêts qu'elles accordent ainsi que lorsqu'elles examinent une opération d'investissement. Ces diagrammes sont également très courants en infographie, ils apparaissent fréquemment dans les revues de presse comme dans les médias sociaux. Il faut dire que ces arbres s'avèrent aptes à évaluer presque n'importe quelle question et illustrer les résultats possibles.

III.2.1 Principe de l'arbre de décision

Un arbre de décision commence généralement par un nœud d'où découlent plusieurs résultats possibles. Chacun de ces résultats mène à d'autres nœuds, d'où émanent d'autres possibilités.

Le schéma obtenu ressemble à un arbre. Il existe trois types de nœuds différents :

- ✓ Un nœud de hasard, symbolisé par un cercle, indique les probabilités associées à différents résultats.

Chapitre III : Analyse des données acoustiques et classification des défauts

- ✓ Un nœud de décision, représenté par un carré, correspond à un choix à effectuer.
- ✓ un nœud terminal indique le résultat final d'un chemin décisionnel.




Figure III. 16: La figure illustre les principaux composants d'un arbre de décision.

III.2.2 Les Avantages et les Inconvénients des Arbres de décision.

Ce tableau résume les avantages et les inconvénients de l'utilisation des arbres de décision pour la classification en générale.

Tableau III. 3 : Avantages et Inconvénients des Arbres de décision [47].

Avantages	Inconvénients
Ils offrent une représentation visuelle claire du processus de décision.	Leur performance est souvent inférieure à celle d'autres méthodes d'apprentissage statistique.
Ils sont faciles à comprendre et à interpréter par n'importe quelle personne, même sans expertise technique poussée.	Ils sont sensibles au sur apprentissage (overfitting), c'est-à-dire qu'ils peuvent trop bien s'adapter aux données d'entraînement et perdre en capacité de généralisation sur de nouvelles données.
Ils sont considérés comme un reflet du raisonnement humain dans la prise de décision.	Leur utilisation isolée est restée limitée, notamment avec l'apparition de méthodes plus robustes comme les forêts aléatoires (Random Forests), qui combinent plusieurs arbres pour réduire le sur apprentissage et améliorer la précision

	globale.
--	----------

Tableau III.4 : Avantages et Inconvénients des Arbres de décision [47].

III.2.3 Apprentissage et optimisation (paramètres, critères de division)

L'apprentissage, au sens large, désigne l'ensemble des processus par lesquels une personne acquiert des connaissances, des compétences ou des savoir-faire. La personne qui apprend est appelée « apprenant », tandis que celle qui transmet les connaissances est l'« enseignant ». Cela dit, l'apprentissage peut aussi se faire de manière autonome, sans l'intervention directe d'un formateur, par le biais de l'autoformation. Dans le domaine des arbres de décision, l'apprentissage prend une forme particulière : il s'agit de résoudre un problème de classification (quand la sortie attendue est une catégorie) ou de régression (quand on cherche à prédire une valeur numérique), à partir d'un ensemble de données. Chaque exemple de cette base est décrit par un vecteur de caractéristiques, notées par exemple ($X_1, X_2, \dots, X_N$).

➤ Principe de construction de l'arbre

On débute en plaçant tous les exemples au niveau du nœud initial, connu sous le nom de nœud racine.

- ✓ Une variable cible est définie pour chaque exemple. Elle représente ce qu'on cherche à prédire : une étiquette (classification) ou une valeur numérique (régression).
- ✓ À chaque étape, un test est appliqué sur une des variables explicatives pour diviser les données du nœud en sous-groupes plus homogènes, créant ainsi des nœuds fils.
- ✓ Chaque donnée suit un chemin unique dans l'arbre en fonction de ses caractéristiques, jusqu'à aboutir à une feuille.
- ✓ Le choix de la variable à tester à chaque division se fait selon un critère d'optimisation, visant à maximiser la pureté des groupes obtenus par rapport à la variable cible.
- ✓ Le processus se répète de façon récursive, jusqu'à ce que chaque nœud contienne uniquement des données appartenant à une même classe ou ayant une valeur cible identique.

Ce mécanisme de découpe successif (appelé induction descendante) permet à l'arbre d'apprendre progressivement à distinguer les différentes catégories ou valeurs à prédire, à partir des données d'exemple.




Figure III.17: Représentation graphique d'un arbre de décision et partition de l'espace des attributs [49].




Figure III. 18: Comparaison des méthodes de séparation : partition itérative des variables (gauche) vs. Combinaison linéaire des variables (droite) [49].

III.3 Évaluation de la performance du modèle de classification

Après la création d'un arbre de décision pour résoudre un problème de classification, il est primordial d'évaluer son efficacité.

L'objectif est de mesurer la capacité du modèle à prédire correctement la classe de nouveaux éléments et de garantir une bonne généralisation au-delà des données d'apprentissage.

L'évaluation d'un modèle de classification repose généralement sur les étapes suivantes :

Chapitre III : Analyse des données acoustiques et classification des défauts

III.3.1 Utilisation d'un ensemble de test

Après l'apprentissage, le modèle est évalué sur un jeu de données distinct, appelé jeu de test. Ce jeu contient des exemples que l'arbre de décision n'a jamais rencontrés lors de l'entraînement, ce qui permet d'estimer sa capacité de généralisation et sa performance sur des données inédites.

III.3.2 Métriques utilisées

III.3.2.1 Matrice de confusion

Une matrice de confusion est un outil utile pour évaluer les performances d'un modèle de classification en mettant en correspondance ses valeurs réelles et ses valeurs prédites [50]. Dans les tâches de classification binaire, il s'agit d'un tableau qui présente les quatre résultats de prédiction mentionnés ci-dessus : vrais positifs, vrais négatifs, faux positifs et faux négatifs. Cette matrice bidimensionnelle permet aux praticiens de la ML de résumer les résultats de la prédiction afin de calculer de manière transparente la précision, le rappel, le score F1 et d'autres paramètres du modèle. Considérons l'exemple suivant de matrice de confusion :

		Actual Values	
		Positive	Negative
Predicted Values	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

Figure III.19: Illustration de la matrice de confusion [50].

Pour mon projet d'analyse acoustique des moteurs, j'utilise la matrice de classification pour juger de l'efficacité avec laquelle l'arbre de décision catégorise les divers types de défauts :

Défaut intérieur (inner).

Chapitre III : Analyse des données acoustiques et classification des défauts

Défaut extérieur (outer).

Défaut de rouleau (roller).

III.3.2.2 Accuracy

La définition la plus courante est que l'accuracy est un niveau de mesure sans limitation inhérente (c'est-à-dire sans erreur systématique, une autre forme d'erreur d'observation). L'accuracy est définie comme suit :

$$\text{Accuracy} = \frac{TN+TP}{TN+TP+FP+FN} \quad (1)$$

III.3.2.3 Precision

La précision est la part des classes positives identifiées par le modèle qui sont effectivement positives. Elle est définie mathématiquement comme suit:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

III.3.2.4 Recall ou taux de vrais positifs

Le taux de vrais positifs (TVP), ou la proportion de tous les résultats positifs réels qui ont été correctement classés comme tels, est également appelé recall.

Mathématiquement, le recall est défini comme suit :

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

III.3.2.5 F1-Score

Le F1-score est la moyenne harmonique entre la précision et le rappel [23]. Il est particulièrement utile en cas de déséquilibre des classes :

$$\text{F1-Score} = 2 \times \frac{\text{Précision} \times \text{Recall}}{\text{Précision} + \text{Recall}} \quad (4)$$

III.3.2.6 Moyenne macro

Le score F1 macro-moyen est obtenu en faisant la moyenne arithmétique des scores F1 de chaque classe, sans tenir compte du nombre d'exemples par classe. Toutes les classes sont donc considérées de manière égale.

$$\text{Moyenne macro} = \frac{1}{N} \sum_{i=1}^N Si \quad (5)$$

Avec :

N : nombre total de classes.

Si : score obtenu pour la classe.

III.3.2.7 Weighted Average

Le score F1 moyen pondéré est calculé en tenant compte du nombre d'occurrences (support) de chaque classe dans l'ensemble de données. Ainsi, les classes les plus représentées ont un poids plus important dans la moyenne.

$$\text{Weighted Average} = \sum_{i=1}^N \frac{ni}{ntotal} * Si \quad (6)$$

N : nombre total de classes.

ni:nombre d'exemples dans la classe.

ntotal : nombre total d'exemples toutes classes confondues.

Si : score de la classe i.

III. 4 Développement de l'approche

Pour toute application de l'intelligence artificielle, la phase la plus importante est la collecte des données.

III. 4.1Collect de données

Nous disposons de quatre enregistrements de 12 secondes chacun : un pour chaque type de défaut, ainsi qu'un pour l'état sain. À partir de ces enregistrements, nous avons généré des échantillons de 0,01 seconde, chacun étant étiqueté en fonction de son état. Nous avons ensuite produit les spectrogrammes correspondant à ces échantillons.

✓ Spectrogramme temps-fréquence

Le spectrogramme représente l'évolution des fréquences du signal dans le temps. Il permet d'observer l'apparition et la durée d'anomalies vibratoires.

Analyse pratique




Figure III. 20: illustrer l’usage des spectres temps-fréquence.

Dans les spectrogrammes, le changement de l'intensité sonore du moteur est illustré selon le temps et la fréquence. Les moteurs en bon état (normaux) affichent un spectre assez uniforme, montrant peu d'activité principalement aux hautes fréquences. À l'opposé, la présence de défauts mécaniques, comme un défaut sur la bague intérieure (inner), l'élément roulant (roller) ou la bague extérieure (outer), se traduit par une concentration significative d'énergie à certaines fréquences précises. En particulier, on note une augmentation d'énergie dans la plage 1000–3000 Hz pour l'inner, une intensification générale vers 2500 Hz pour le roller, et un important regroupement énergétique entre 2500 et 3500 Hz pour l'outer. Ces anomalies montrent clairement que les imperfections engendrent des vibrations supplémentaires qui sont détectées dans des plages de fréquences spécifiques.

III.4.2 Analyse physique des défauts par observation directe




Figure III.21: Observation supervisée des signaux temporels pour différents états de roulements (normal, défaut interne, sur rouleaux et externe).

La figure ci-dessous illustre les signaux audio correspondant à quatre classes distinctes identifiées à l'issue d'un processus de classification supervisée. Chaque graphique représente une catégorie spécifique de condition du moteur, détectée automatiquement par un algorithme préalablement entraîné à partir de signaux labellisés : normal, inner, roller et outer.

- **Signal audio - normal**

Le modèle a déterminé qu'il y avait un fonctionnement stable, sans défaut, et qu'il était sifflant. Le signal présente des oscillations modérées, régulières et sphériques sans impulsions marquées.

- **Signal audio – inner**

La classification a détecté avec précision un anneau interne souffrant d'un défaut périodique intrinsèque, dit impulsif, facile à discerner. Ces pics rythmiques traduisent des impacts localisés récurrents.

- **Signal audio – roller**

Chapitre III : Analyse des données acoustiques et classification des défauts

Ce pattern s'est accompagné de nombreuses petites impulsions plus irrégulièrement dispersées, correspondant à de l'élément roulant. Les irrégularités correspondent à des défauts sur les rouleaux ou billes.

- **Signal audio – outer**

Le modèle a discrètement identifié une défaillance sur l'anneau externe du roulement observable par des impacts, marqués et bruissements, espacés dans le temps. Les sursauts et trous d'amplitudes exagérées, espacés dans les signaux sont dominants pour ce genre de défaillance.




Figure III.22: illustrer l'usage des spectre temps-fréquence (après traitement).

L'analyse combinée du temps et de la fréquence permet d'obtenir une vision détaillée de l'évolution d'un signal en fonction du temps et de la fréquence. Un moteur en bon état se caractérise par un spectrogramme stable et régulier. En revanche, des défauts mécaniques se manifestent par des zones d'énergie amplifiée à des fréquences spécifiques : entre 1500 et 3000 Hz pour un défaut sur la bague intérieure, autour de 1250 Hz pour les éléments roulants, et entre 2500 et 3500 Hz pour la bague extérieure. Ces concentrations d'énergie sont caractéristiques des instabilités liées à l'usure physique en cas de défaillance.

III.5 Séparation des données et prétraitement

Dans notre cas, les données ont été divisées en deux ensembles : 30 % pour l'apprentissage (jeu d'entraînement) et 70 % pour l'évaluation (jeu de test). Cette répartition permet de disposer d'un volume de test conséquent pour juger de la robustesse du modèle sur de nouveaux exemples.

✓ Division des données

À la suite de l'analyse des spectrogrammes, nous avons examiné la capacité des arbres décisionnels à séparer les différentes classes de défauts :




Figure III. 23: Premier Arbre de Décision Généré pour la Classification des données.

Le premier arbre est relativement basique et bien structuré, car il atteint une séparation adéquate des principales catégories avec des niveaux inférieurs, ce qui le rend rapide à comprendre. En revanche, une complexité insuffisante peut parfois ne pas suffire à différencier des défauts très similaires, tels que le rouleau et l'intérieur.

Chapitre III : Analyse des données acoustiques et classification des défauts




Figure III. 24: Arbre de Décision pour la Classification des Défauts à Partir de Données de Spectrogramme.

Le deuxième arbre présente un niveau de ramification et de structure plus élevé. Avec davantage de composants, cela peut contribuer à augmenter la précision de la classification en prenant en compte certaines subtilités qui pourraient être identifiées comme des anomalies. Il est clair que cet arbre tente de mieux saisir comment une plus grande variation des contours des défauts (rouleau, intérieur, extérieur) est en fait séparée, mais au prix d'une plus grande complexité structurelle.




Figure III. 25: Arbre de Décision après Test de Classification des Défauts Vibratoires et Acoustiques d'un Moteur.

Chapitre III : Analyse des données acoustiques et classification des défauts

Le troisième arbre est plus ramifié que les précédents. Des arbres entièrement ramifiés, plus complexes, sont créés lorsqu'on essaie de maximiser la séparation des classes pour une détection plus fine des défauts. Bien qu'une excellente attribution des classes soit réalisée dans certaines feuilles, un tel arbre est plus difficile à lire et sujet au surajustement, devenant trop adapté aux données d'entraînement et compromettant ainsi la précision sur des données non vues.

En résumé, le premier arbre est simple et rapide à utiliser, mais il manque de précision. Le deuxième arbre propose un équilibre satisfaisant entre précision et complexité, tandis que le troisième est extrêmement précis avec les données disponibles, mais il est plus complexe et présente des risques en matière de généralisation.

III.6 Évaluation des performances du modèle




Figure III. 26: Matrice de confusion du modèle de classification.

Cette matrice montre les erreurs de classification du modèle. Les valeurs diagonales correspondent aux prédictions correctes. On constate que les signaux normaux sont très bien détectés (36 343/36 648), mais qu'il y a une grande confusion entre les défauts de type rouleau, extérieur et intérieur, ce qui indique que ces signaux sont plus difficiles à distinguer d'un point de vue acoustique.

```
Train Accuracy : 0.9589021250989002
Test Accuracy  : 0.960425388075613

Classification Report :
```

	precision	recall	f1-score	support
inner	0.41	0.71	0.52	634
normal	0.99	0.99	0.99	36648
outer	0.34	0.09	0.14	594
roller	0.27	0.16	0.20	583
accuracy			0.96	38459
macro avg	0.50	0.49	0.46	38459
weighted avg	0.96	0.96	0.96	38459

Figure III. 27: Évaluation des Performances avec les Données Propres.

Cette figure présente les résultats de performance d'un modèle d'intelligence artificielle (IA) qui a été entraîné pour reconnaître quatre types de classes : inner, normal, outer, et roller.

Elle contient deux parties principales :

1. Train Accuracy & Test Accuracy

- Train Accuracy (95.89 %) indique que le modèle est très performant sur les données avec lesquelles il a été entraîné.
- Test Accuracy (96.04 %) montre que le modèle reste performant même sur des données nouvelles ; non utilisées lors de l'apprentissage.

2. Classification Report (rapport de classification)

Ce tableau donne les performances du modèle pour chaque classe séparément avec :

❖ Classe normal

Le modèle est excellent ici. Il trouve presque tous les exemples normaux sans se tromper.

C'est aussi la classe qui a le plus d'exemples (36 648).

→ L'IA a eu beaucoup de données pour apprendre cette classe.

→ F1-score de 0.99 = excellente précision + excellent rappel.

Chapitre III : Analyse des données acoustiques et classification des défauts

❖ Classe inner

F1-score = 0.52 → score moyen, car le modèle en rate encore beaucoup.

Précision = 0.41 → sur 100 prédictions "inner", 41 sont correctes.

Recall = 0.71 → sur 100 vrais inner, l'IA en trouve 71.

❖ Classe outer

F1-score = 0.14 : Très mauvais score.

Rappel = 0.09 : il rate presque tous les vrais outer.

F1-score = 0.14 → signifie que le modèle ne sait pas bien quoi faire avec cette classe.

❖ Classe roller

F1-score = 0.20 : Encore un score très faible.

Le modèle a du mal à reconnaître cette classe.

Rappel très bas (0.16) → l'IA ne les trouve presque jamais.

❖ Moyennes globales

Accuracy (96%) : en apparence, le modèle semble bon.

Mais il est bon surtout parce qu'il réussit bien sur la classe normal, qui est très majoritaire.

Macro avg F1-score = 0.46 : moyenne égale sur toutes les classes → montre que les classes rares sont mal détectées.

Weighted avg F1-score = 0.96 : moyenne pondérée (plus de poids à normal) → donc ce score est trop optimiste.

III.7 Influence de la durée de l'échantillonnage sur l'efficacité de la classification

Nous avons prolongé pour ainsi dire le nombre d'échantillons audio de 0,01 à 1 seconde pour obtenir des segments plus riches en information au sein de ces segments audio afin

Chapitre III : Analyse des données acoustiques et classification des défauts

de mieux saisir les caractéristiques dues aux défauts (ou en état sain) du moteur . Les spectrogrammes établis sur ces échantillons constituent ainsi une base plus pertinente à l'analyse et la classification.




Figure III. 28: Matrice de confusion du modèle après allongement des échantillons à 1 seconde.

La matrice ci-dessous fait état des performances de classification du modèle pour quatre états de roulements (normal, inner, roller, outer), sur la base de l'analyse de signaux audio de 1 seconde. Les valeurs sur la diagonale correspondent aux bonnes prédictions, alors que les autres correspondent à des erreurs.

- ✓ Classe normal: Très bien reconnue → 36254 bonnes prédictions.
- ✓ Classe inner: Souvent confondue avec roller (242) et outer (81).
- ✓ Classe outer : Confusions fréquentes avec inner (142) et roller (174).
- ✓ Classe roller : Confusions notées avec inner (188) et outer (96).

Si le modèle fait une bonne reconnaissance de l'état sain, les défauts sont parfois confondus entre eux. Ces erreurs proviennent des signatures acoustiques proches ou peu marquées.

Chapitre III : Analyse des données acoustiques et classification des défauts




Figure III. 29: Analyse de l'Arbre de Décision après Augmentation à 1 Seconde.

L'arbre résultant de l'augmentation à 1 seconde de l'intervalle est à structure plus ramifiée et plus profonde, permettant au modèle de disposer d'une plus grande intégration du signal, et donc de mieux distinguer les différents types de défauts. On note que certaines feuilles de l'arbre permettent une bonne classification, avec des étiquettes bien associées comme inner, normal ou roller.

Mais cette structure complexe présente également le risque d'une lecture et d'une interprétation difficile, voire d'une faible généralisation car on dit qu'un arbre très adapté à l'apprentissage peut être peu performant sur des données nouvelles, ce qu'on appelle le surajustement, d'où la nécessité de trouver un juste équilibre entre complexité et performance.

```

op/fatima/chapitretrois.py
Train Accuracy : 0.959325584764367
Test Accuracy  : 0.9591513039868631

Classification Report :

```

	precision	recall	f1-score	support
inner	0.39	0.44	0.41	634
normal	0.99	0.99	0.99	36648
outer	0.28	0.21	0.24	594
roller	0.29	0.40	0.34	583
accuracy			0.96	38459
macro avg	0.49	0.51	0.49	38459
weighted avg	0.96	0.96	0.96	38459

Figure III.30: Évaluation des Performances après Augmentation de la Durée à 1 Seconde.

Chapitre III : Analyse des données acoustiques et classification des défauts

Cette figure représente les résultats obtenus avec le modèle d'intelligence artificielle qui a été évalué sur des segments de 1 seconde, plutôt que 0.1 sec, pour évaluer si la longueur plus importante du signal impacte la classification des défauts. On notera que deux volets principaux composent la figure :

1. Train Accuracy & Test Accuracy

- Train Accuracy (95.93 %) : le modèle s'est très bien ajusté sur les données d'apprentissage.
- Test Accuracy (95.91%) : le modèle est toujours performant sur de nouvelles données.

→ L'évaluation sur données de test n'a pas montré de sur ajustement lié à l'augmentation de la durée du signal. Le modèle est stable.

2. Classification Report

Ce tableau donne le détail de performance pour chaque classe :

❖ Classe normal (F1-score = 0.99)

Le modèle reconnaît presque parfaitement cette classe ayant, de plus, le plus grand effectif observé dans les données (36 648 exemples). Précision = 0.99, Rappel = 0.99 → Très performant.

❖ Classe inner (F1-score = 0.41)

Précision = 0.39 : parmi les 100 prédictions (inner), on en retrouve 39 de correctes.

Rappel = 0.44 : parmi les 100 vrais inner, l'IA ne trouve que 44.

F1-score = 0.41 → faible score, la classe est difficile à reconnaître.

❖ Classe outer (F1-score = 0.24)

Précision = 0.28, mais rappel très bas (0.21).

Le modèle n'arrive pas à bien identifier les défauts (outer).

F1-score faible → performance à améliorer.

Chapitre III : Analyse des données acoustiques et classification des défauts

❖ Classe roller (F1-score = 0.34)

Résultats un peu meilleurs que outer.

Le modèle commence à détecter quelques cas, mais le rappel est encore faible (0.40).

❖ Moyennes globales

Accuracy (96%) : Très bon score global.

Macro avg F1-score = 0.51 : Moyenne simple sur toutes les classes → on voit que les classes minoritaires sont mal reconnues.

Weighted avg F1-score = 0.96 : Moyenne pondérée (la classe normal influence beaucoup) → ce score est trop optimiste.

Conclusion

Dans ce chapitre nous avons utilisé des méthodes d'arbres de décision pour la classification des signaux de vibrations émis par les roulements des machines tournantes. En termes de résultats, nous avons obtenu une bonne précision pour ce qui concerne la classe normal, alors que certains défauts tels que les défauts externes ou les défauts de roulements, ont moins bien été détectés. Cela peut être dû à la puissance du matériel utilisé.

Au vu des bons résultats obtenus, nous allons procéder à un test de robustesse, visant à reproduire l'ambiance acoustique d'un environnement industriel réel.

Chapitre IV: testes de robustesses

Chapitre IV: Testes de robustesses

IV .1Introduction

Après avoir appliqué des méthodes de classification sur des signaux de vibration de machines tournantes amène à se poser une question essentielle : dans quelle mesure ces modèles restent-ils performants dès lors que les choses se dégradent ? Que devient le modèle si le signal recueilli est bruité, comme c'est souvent le cas dans les environnements industriels réels ? Est-il en mesure de détecter les défauts lorsque l'information est dégradée ?

Ce chapitre vise spécifiquement à tester la solidité de notre système de détection en incorporant intentionnellement du bruit dans les signaux audio que nous utilisons. Ce faisant, nous visons à évaluer la capacité du modèle à maintenir ses performances en conditions bruitées. Nous comparons les résultats de classification obtenus avant l'ajout de bruit et après pour plusieurs enregistrements audio. Nous analysons plus précisément les résultats en explicitant les effets de cette sous-information sur la précision de détection.

Enfin, une méthode de classification reposant sur un arbre de décision doit nous permettre d'interpréter ces résultats afin d'identifier dans quelles conditions le modèle est encore en mesure de distinguer des défauts, et où il commence à échouer. Ces résultats doivent aussi nous permettre d'identifier les limites actuelles du modèle pour chaque signal étudié.

IV.2 Bruit

Un bruit est un son perçu comme indésirable, gênant ou nocif .C'est donc une pollution sonore que l'on cherche à éviter.

IV.2 .1Bruit et apprentissage automatique

Le bruit dans l'apprentissage automatique désigne une variation vindicative ou un défaut des données ne rendant pas une plus vraie réalité des modèles ou des relations sous-jacentes. En effet, le bruit abaisse le rapport signal sur bruit (SNR), qui fait état de la quantité d'informations utiles dans les données par rapport au bruit ; ainsi un rapport signal bruit faible sera une difficulté supplémentaire à surmonter pour l'apprentissage et la généralisation du modèle à partir de ces données qui peut générer un sur ajustement ou un sous-ajustement des données.

Chapitre IV: Testes de robustesses

IV.2 .2Les différents types de bruits

La classification des bruits s'opère selon leur nature, leur origine ou leur mode de transmission en matière acoustique et de propagation sonore. On peut ainsi distinguer différents bruits :

➤ **Bruit aérien – Propagation aérienne**

Il s'agit de bruit qui se propage par voie aérienne, c'est-à-dire dans l'air, contrairement à celui qui se propage dans les solides.

➤ **Bruit ambiant**

Le bruit ambiant est constitué de tous les sons dans un lieu donné en un temps donné. Lorsque l'on souhaite mesurer la gêne que cause une source particulière, on considère le bruit ambiant comme étant le bruit résiduel plus le bruit particulier émis par la source. Il comprend les sons environnants quels qu'ils soient, qu'ils soient éloignés ou proches.

➤ **Bruit rose**

Ce bruit présente une égalité d'énergie dans toutes les bandes d'un octave généralement de 125 à 4000 Hz. Principal bruit de référence pour les essais acoustiques des bâtiments. Caractérisé par une atténuation de 3 dB/ octave en fonction de la fréquence.

➤ **Bruit d'impact**

Dû à un choc physique sur une surface, comme un objet tombé (débris) ou le bruit de pas au sol envers un plancher.

➤ **Bruit de fond**

Les bruits de fond sont l'ensemble des bruits continus présents dans un environnement donné. Ils peuvent être liés au bruit des machines, à la conversation, aux équipements techniques ou encore aux sons émis par des zones voisines.

➤ **Bruit liquidien – Propagation dans un liquide**

Un bruit liquidien est un bruit qui se propage dans un fluide, l'eau ou tout autre liquide. On le retrouve principalement dans les systèmes hydrauliques ou dans le milieu subaquatique.

➤ **Bruit particulier**

Chapitre IV: Testes de robustesses

Un bruit particulier est un bruit que l'on peut identifier dans le bruit ambiant global, souvent considéré comme un bruit gênant. Ce bruit provient d'une source identifiée et fait souvent l'objet d'une analyse ou d'une plainte.

➤ **Bruit résiduel**

Le bruit résiduel est le niveau sonore ambiant mesuré en l'absence du bruit particulier que l'on souhaite étudier. Il est le bruit ambiant habituel d'un lieu.

➤ **Bruit routier (ou bruit route)**

C'est un bruit de référence employé pour reproduire les sons produits par le trafic routier ou ferroviaire. Par rapport au bruit rose, il présente une richesse en basses fréquences et une pauvreté en aigus.

➤ **Bruit solidien – Propagation dans un solide**

Ce type de bruit se transmet à travers les structures matérielles, comme les murs, les sols ou les poutres. La propagation solidienne désigne le déplacement de l'onde sonore à l'intérieur d'un matériau solide.

➤ **Bruit blanc**

C'est un bruit contenant toutes les fréquences audibles, avec la même intensité pour chacune. Il ressemble à un souffle constant et sert souvent de référence pour les tests acoustiques.

Dans le cadre de ce projet, j'ai choisi d'ajouter du bruit blanc gaussien aux signaux audio afin de simuler des conditions de mesure plus réalistes. Ce bruit aléatoire est généré par une distribution normale centrée en zéro, puis ajouté aux signaux des différentes classes (normal, inner, roller, outer).

L'objectif est de tester la robustesse du modèle d'apprentissage automatique (arbre de décision) face à des signaux perturbés, en comparant les performances sur données propres et bruitées. Ce processus reflète des scénarios concrets où les capteurs peuvent enregistrer des signaux contaminés par des bruits ambiants dans un environnement industriel. L'intensité du bruit est quantifiée à l'aide du rapport signal sur bruit (SNR), exprimé en décibels (dB), et défini par la formule suivante :

$$SNR=10\times\log_{10}\frac{P_{signal}}{P_{bruit}} \quad (7)$$

Chapitre IV: Testes de robustesses

Ou :

P signal : est la puissance du signal original.

P bruit : est la puissance du bruit ajouté.

IV.3 Résultats du test de robustesse

IV.3.1 Enregistrements bruités




Figure IV. 31: Signaux audio bruités pour les quatre classes de roulements.

La figure ci-dessous illustre les signaux audio bruités correspondant à quatre classes distinctes de conditions de roulements, obtenus à partir d'un processus de classification supervisée. Chaque graphique représente une catégorie spécifique de défaillance, le bruit ayant été volontairement ajouté pour tester la robustesse du système de diagnostic : normal, inner, roller et outer.

- **Signal audio bruité – normal_noisy**

Ce signal représente un roulement en bon état, sans défaut détecté. Bien qu'un bruit blanc gaussien ait été ajouté pour simuler un environnement acoustique réel, le système ici analysé sans recours à une intelligence artificielle interprète les variations comme des fluctuations normales, n'excédant pas le seuil critique. L'amplitude reste modérée, sans impulsions franches, ce qui traduit un comportement mécanique stable.

- **Signal audio bruité – inner_noisy**

Chapitre IV: Testes de robustesses

L'identification se base sur des signaux d'impulsions plus prononcées avec modulation, ce qui s'explique par la présence d'un défaut sur la bague interne du roulement. Il reste suffisant pour capter des défauts, mais ces structures périodiques sont discernables.

- **Signal audio bruité – roller_noisy**

Il s'exprime par des formes d'oscillation à faible amplitude, correspondant à des imperfections sur les rouleaux. Bien que le bruit recouvre en grande partie les pics, les changements qui perdurent sont dûs au fait que la structure des roulements est atteinte.

- **Signal audio bruité – outer_noisy**

Sur la bague extérieure, ces anomalies se traduisent par des sauts irréguliers de certaines amplitudes. Ces traces sont marquées par des perturbations dont la signification reste très floue. Toutefois, ces irrégularités soutenues demeurent assez frappantes, bien que le bruit soit toujours soufflé, permettant d'identifier des défauts externes.




Figure IV.32: Spectrogrammes bruités pour les quatre conditions de roulements.

L'analyse des temps-fréquences grâce aux spectrogrammes nous révèle l'effet du bruit sur les signaux acoustiques à partir des quatre états de roulements considéré en situation : en état normal, en situation de défaut interne, en situation de défaut sur éléments roulants et en situation de défaut externe. Ainsi, le spectrogramme de roulement normal montre une répartition relativement homogène de l'énergie sur tout le domaine fréquentiel, les pics d'énergie étant plus visibles autour des fréquences les plus hautes. En revanche, les

Chapitre IV: Testes de robustesses

spectrogrammes en défaut parviennent à montrer des zones où l'énergie est plus concentrée à des fréquences caractéristiques des défauts : pour la bague intérieure entre 1500 et 3000 Hz, autour de 1250Hz pour les éléments roulants, et entre 2500 et 3500 Hz pour la bague extérieure. Ces signatures fréquentielles sont toujours plus ou moins perceptibles en ajoutant du bruit, ce qui montre que des informations discriminantes, utiles à la détection et localisation des défauts, sont encore présentes dans des signaux dégradés par le bruit.

IV.3.2 Évaluation des performances du modèle




Figure IV.33: Matrice de confusion du modèle sur les signaux audio bruités.

Cette figure(IV.33) montre comment le modèle s'est comporté pour reconnaître les différentes classes de roulements à partir de signaux bruités. On remarque qu'il réussit très bien à identifier les roulements en bon état, avec plus de 36 000 bonnes prédictions. En revanche, il a plus de mal à différencier les défauts internes, externes et sur les rouleaux. Les trois paires de failures créent des signatures auditives similaires à l'apport d'un bruit, ce qui les rend moins aisées à différencier pour le modèle. Cela met en relief l'impératif des caractéristiques bien distinctes, même sous des conditions audio détériorées.

Chapitre IV: Testes de robustesses

Résultats de la validation croisée : [0.93119249 0.93698449 0.92631425 0.93778869 0.79686927]				
Score moyen de la validation croisée : 0.9058298395997804				
Train Accuracy : 0.9251209753440728				
Test Accuracy : 0.9234566694364339				
	precision	recall	f1-score	support
inner	0.39	0.70	0.50	1218
normal	0.98	0.98	0.98	37228
outer	0.30	0.09	0.14	1269
roller	0.29	0.31	0.30	1203
accuracy			0.92	40918
macro avg	0.49	0.52	0.48	40918
weighted avg	0.92	0.92	0.92	40918

Figure IV. 34: Performances avec données bruitées.

Les résultats de classification du modèle sont présentés dans cette figure alors qu'il s'agit de signaux audio contenant différentes quantités de bruit de type gaussien ; le tableau comporte les principales mesures de performance, précision, rappel (recall), f1-score, ainsi que le nombre d'échantillons (support) pour chaque type de signal (classe).

❖ Classe normal

Le modèle reconnu correctement, il identifie bien un roulement en bon état. Il dispose d'une précision de 0.98 et d'un rappel de 0.98 ce qui le rend opérationnel sur la plupart des cas, preuve qu'il parvient à bien distinguer un roulement en bon état d'un roulement défectueux en dépit du bruit.

❖ Classe inner

Pour les défauts internes, le modèle reconnaît 0.70 des cas, il s'agit d'un bon rappel. En revanche, la précision est plus faible (0.39) cela signifie qu'il confond souvent d'autres défauts avec un défaut interne, ce qui montre que le bruit complique la distinction.

❖ Classe outer

Le modèle éprouve de grandes difficultés avec les défauts externes : il ne reconnaît correctement que 0.09 des cas. De plus, il les confond très souvent avec d'autres défauts. Le f1-score très bas (0.14) confirme cette faiblesse. Cela peut s'expliquer par des signaux trop proches de ceux d'autres défauts lorsqu'ils sont bruités.

❖ Classe roller

Chapitre IV: Testes de robustesses

La classe roller est aussi mal classé. Le modèle ne reconnaît que 0.31 des cas réels et affiche une précision de 0.29, ce qui est insuffisant. Cela signifie qu'il n'arrive pas à repérer clairement ce type de défaut, sans doute à cause de signatures sonores peu distinctes.

❖ Analyse globale

Le taux de bonne classification global (accuracy) est de 0.92 car la classe majoritaire (normal) est très bien détectée. Cependant, le score moyen entre les classes (macro avg f1-score) est beaucoup plus faible (0.48), ce qui montre un déséquilibre : le modèle favorise les classes majoritaires au détriment des classes défectueuses.

Le bruit ajouté masque certaines caractéristiques essentielles, rendant plus difficile la distinction entre les défauts internes, externes et sur les rouleaux.




Figure IV.35: Arbre de Décision pour la classification des défauts de roulements (après ajout de bruit).

La figure(IV.35) présentée est un arbre de décision permettant la classification de divers types de défauts (ou dommages) de roulements à partir de signaux bruités. On remarque que l'arbre commence par une décision engendrant une première bifurcation, suivie de différentes bifurcations, fonction d'un seuil ou d'un choix basé sur la valeur du signal. On peut remarquer que certaines régions permettent d'identifier convenablement la classe normal, même bruitée, en revanche, pour d'autres classes dommages telles que inner, roller ou outer, il semble plus difficile de bien séparer les classes, et plus de bifurcations sont nécessaires pour essayer de

Chapitre IV: Testes de robustesses

distinguer chaque type de défaut, ce qui rend l'arbre plus profond. Cet arbre permet globalement de précipiter une instance en particulier, étapes par étapes vers un état du roulement, mais il n'est pas décevant d'anticiper que le bruit rend le problème plus complexe.

IV .3.3 Analyse comparative




Figure IV. 36: Représentation des signaux vibratoires selon les types de défauts et la présence de bruit.

La figure montre différents signaux d'un roulement (normal et avec défauts) avec et sans bruit. Le tableau compare visuellement chaque type en résumant leur forme et l'effet du bruit. Ensemble, ils aident à mieux repérer les défauts malgré les perturbations. Cette comparaison visuelle et synthétique facilite l'analyse des anomalies mécaniques.

Tableau IV. 4 : comparatif des signaux audio selon le type de défaut et la présence de bruit.

Type de signal	Description	Effet du bruit (version noisy)
Normal	Signal stable, sans anomalies visibles.	Plus de petites fluctuations, signal plus agité visuellement.
Inner	Présence de pics irréguliers, indiquant un défaut sur la bague intérieure.	Pics toujours présents, mais moins nets à cause du bruit ajouté.
Roller	Signal instable, avec des fluctuations d'énergie,	Instabilité conservée, mais bruit masque les détails.

Chapitre IV: Testes de robustesses

	indiquant un défaut sur les rouleaux.	
Outer	Pics nets et réguliers, typiques d'un défaut sur la bague extérieure.	Pics encore visibles mais partiellement masqués par le bruit.




Figure IV. 37: Spectrogrammes des signaux vibratoires selon les types de défauts avec la présence de bruit.

Le spectrogramme montre les différents signaux d'un roulement (normal et avec défauts) avec et sans bruit. Le tableau compare visuellement chaque type de signal en résumant leur forme et l'effet du bruit. Ensemble, ils permettent de repérer plus facilement les défauts, même en présence de perturbations, facilitant ainsi l'analyse des anomalies mécaniques.

Tableau IV. 5: Comparaison des spectrogrammes des signaux vibratoires selon les types de défauts avec et sans bruit.

Type de signal	Observation sans bruit	Effet du bruit (version noisy)
Normal	Énergie assez homogène, peu de variations visibles.	Légères perturbations, mais reste stable.
Inner	Concentration d'énergie à certaines fréquences.	Le bruit atténue légèrement les détails, mais les zones restent visibles.

Chapitre IV: Testes de robustesses

Roller	Énergie un peu plus dispersée, irrégularités visibles.	Les irrégularités sont plus difficiles à distinguer.
Outer	Forte présence à certaines bandes de fréquence.	Détail atténué, mais on voit encore les zones d'énergie marquées.

IV.3.4 : Analyse des matrices de confusion

❖ Classe normal

Avant bruit : 36 343 prédictions justes.

Après bruit : 36 436 prédictions justes.

Observation : le modèle conserve un très bon niveau de performance pour identifier les normes, avec même un surplus de performance bruitée.

❖ Classe inner (défaut sur la bague intérieure)

Avant bruit : 448 bonnes prédictions.

Après bruit : 857 bonnes prédictions.

Observation : mieux dans la reconnaissance de ce type de défaut.

❖ Classe outer (défaut sur la bague extérieure)

Avant bruit : 254 prédictions justes.

Après bruit : 281 prédictions justes.

Observation : petite amélioration, dans l'ensemble, les confusions l'accompagnant d'autres classes persistent.

❖ Classe roller (défaut sur le rouleau)

Avant bruit : 95 bonnes prédictions.

Après bruit : 373 prédictions justes.

Observation : alors qu'auparavant, le bruit ajouté se révélait très peu bénéfique, à présent le bruit aidant s'avère redoutablement bénéfique.




Figure IV.38: Comparaison des matrices de confusion avant et après ajout de bruit sur les signaux acoustiques.

IV.3.5 Comparaison des performances avant et après ajout du bruit

Deux tests de classification ont été réalisés pour évaluer l'impact du bruit sur la détection des défauts mécaniques à partir des signaux acoustiques de moteurs. Le premier test est effectué à partir de données propres, sans bruit ajouté, tandis que le second test utilise les mêmes données après ajout d'un bruit artificiel. Cette comparaison permet de mesurer la robustesse des méthodes de classification face aux perturbations sonores.

1. La classe inner

Avant bruit : précision 0,41, rappel 0,71, F1-score 0,52.

Après bruit : précision 0,39, rappel 0,70, F1-score 0,50.

→ Un léger déclin des trois métriques, qui s'expliquent probablement par une dégradation due au bruit attribué aux caractéristiques discriminatives.

2. La classe normale

Avant bruit : précision 0,99, rappel 0,99, F1-score 0,99.

Après bruit : précision 0,98, rappel 0,98, F1-score 0,98.

→ Un léger décrochement, mais la performance reste très bonne sur la classe majoritaire.

3. La classe outer

Avant bruit : précision 0,34, rappel 0,09, F1-score 0,14.

Chapitre IV: Testes de robustesses

Après bruit : précision 0,30, rappel 0,09, F1-score 0,14.

→ Une perte de précision, et pas de gain en rappel, une performance très faible persistante.

4. La classe roller

Avant bruit : précision 0,27, rappel 0,16, F1-score 0,20.

Après bruit : précision 0,29, rappel 0,31, F1-score 0,30.

→ Un gain net sur toutes les métriques, du bruit qui régulariserait un peu le modèle.

5. Global accuracy

Avant bruit : 0,96.

Après bruit : 0,92.

→ Bien une baisse globale, indiquant un impact global du bruit négatif sur la performance.

6. Macro average

Avant bruit : précision 0,50, rappel 0,49, F1-score 0,46.

Après bruit : précision 0,49, rappel 0,52, F1-score 0,48.

→ Un léger gain rappel/F1-score, peut-être une prise en compte accrue des classes minoritaires malgré le déclin global.

7. Weighted average

Avant bruit : 0,96 pour toutes les métriques.

Après bruit : 0,92 pour toutes les métriques.

→ Une vraie chute, car les performances sur la classe majoritaire ont baissé.

Chapitre IV: Testes de robustesses

```
Train Accuracy : 0.9589021250989002
Test Accuracy  : 0.960425388075613

Classification Report :
              precision    recall  f1-score   support

   inner       0.41       0.71       0.52        634
   normal      0.99       0.99       0.99       36648
   outer       0.34       0.09       0.14        594
   roller      0.27       0.16       0.20        583

 accuracy      0.96       0.96       0.96       38459
 macro avg     0.50       0.49       0.46       38459
 weighted avg  0.96       0.96       0.96       38459
```

Figure IV. 39: Performances avec données propres (avant bruit).

```
Résultats de la validation croisée : [0.93119249 0.93698449 0.92631425 0.93778869 0.79686927]
Score moyen de la validation croisée : 0.9058298395997804
Train Accuracy : 0.9251209753440728
Test Accuracy  : 0.9234566694364339

              precision    recall  f1-score   support

   inner       0.39       0.70       0.50       1218
   normal      0.98       0.98       0.98       37228
   outer       0.30       0.09       0.14       1269
   roller      0.29       0.31       0.30       1203

 accuracy      0.92       0.92       0.92       40918
 macro avg     0.49       0.52       0.48       40918
 weighted avg  0.92       0.92       0.92       40918
```

Figure IV. 40: Performances avec données bruitées (après ajout de bruit).

IV.4 Interprétation avec arbre de décision

Nous avons comparé les arbres de décision des deux cas avant et après l'ajout de bruit. Il peut être vu que pour l'arbre avant l'ajout de bruit, c'est un arbre très simple et bien structuré; il y a une très bonne séparation entre les classes qui attendent d'être bien prédites. Par contre, après l'ajout de bruit, l'arbre de décision semble beaucoup plus complexe avec plus d'entailles, et la visualisation est plus difficile. Le bruit a ajouté plus de complexité à les deux classes qui mène à un plus grand risque de surapprentissage. Ces observations sont résumées dans le tableau ci-dessous.

Tableau IV.6: Comparaison entre l'arbre de décision sans bruit et avec bruit.

Critère	Arbre sans bruit	Arbre avec bruit
Profondeur de l'arbre	Faible	Élevée
Nombre de bifurcations	Limité	Nombreux
Lisibilité / Interprétabilité	Élevée	Faible

Chapitre IV: Testes de robustesses

Risque de surajustement	Faible	Élevé
Précision attendue	Stable	Moins fiable sur données non vues

IV.5 Test de Robustesse par Allongement de la Durée des Signaux Audio

Pour cette expérience, la durée des signaux audio a été étendue de 0,1 seconde à 1 seconde dans le but de tester la robustesse du modèle de classification, car un signal plus long apporte plus d'informations acoustiques utiles à la détection de défauts, mais est également plus sensible au bruit. Cette méthode est bien sûr plus représentative des conditions industrielles auxquelles le modèle sera confronté, puisque l'objectif est de vérifier si la performance du modèle est maintenue sur des données plus riches (complexes). C'est une méthode d'augmentation temporelle des données.




Figure IV.41: Signaux audio bruités prolongés (1 seconde) pour les quatre classes de roulements.

La figure (IV.43) montre les signaux audio bruités associés aux quatre classes de roulements (normal, inner, roller, outer), après allongement de la durée d'enregistrement à 1 seconde. Cette modification vise à tester si le modèle reste capable de reconnaître les défauts lorsque les signaux sont plus longs, et donc plus complexes.

- **Signal audio bruité – normal_noisy**

Le signal étudié correspond à un rouleau fonctionnant dans un état normal. Sur l'ensemble des données acquises, le signal reste stable même s'il est perturbé avec du bruit blanc. Les

Chapitre IV: Testes de robustesses

impulsions ne sont pas marquées, les anomalies sont quasiment absentes. Le contenu spectral est homogène sur la durée de la mesure et confirme qu'il n'y a aucun défaut mécanique sur cette structure.

- **Signal audio bruité – inner_noisy**

Les irrégularités se distinguent plus fortement, où des pics montrent probablement la présence d'un défaut sur la bague intérieure. Cette taille du signal montre également une certaine périodicité perturbée directement observée, en rapport avec des dégradations internes éventuelles.

- **Signal audio bruité – roller_noisy**

À cet endroit, le signal propose un nombre important de petites oscillations, moins régulières, souvent cachées dans le bruit. Ces variations présentes à un niveau disjoint caractérisent davantage les défauts sur les rouleaux des roulements, donc plus difficilement identifiables, surtout lorsque le bruit s'invite à masquer l'aspect typique qui les singularise.

- **Signal audio bruité – outer_noisy**

L'alternance d'impulsions faibles à la fois irrégulières pourrait s'expliquer par les défauts sur la bague extérieure. Par ailleurs, l'allongement du signal permet d'extraire plus d'informations, mais le bruit entraîne une lecture moins lisible, et les indices de défauts sont plus difficiles à isoler.




Figure IV. 42: Spectrogrammes bruités pour les quatre classes de roulements (durée 1 seconde).

Chapitre IV: Testes de robustesses

Le spectrogramme bruité des signaux acoustiques associés à cinq types de roulements (normal, inner, roller, outer) estime la répartition de l'énergie dans le domaine fréquentiel 0–4096 Hz sur une durée d'une seconde.

- ✓ Pour le roulement normal, le spectre se montre assez stable, sans pics vraiment notables, l'énergie est à faible niveau global et surtout en masse à basse fréquence, en particulier inférieure à 1000 Hz.
- ✓ Avec la défaillance de la bague intérieure (inner defect) une meilleure concentration de l'énergie est observée entre 1500 Hz et 3000 Hz témoignant de la répétition de chocs dans le cas de ce type de défaillance.
- ✓ Le spectre du roller defect est beaucoup plus étalé. L'intensité est étendue dans la zone de fréquences entre 500 Hz et 1500 Hz traduisant ainsi une perturbation continue plus liée au défaut affectant les rouleaux.
- ✓ Pour le défaut au niveau de la bague extérieure (outer defect), on note des fluctuations beaucoup plus marquées aux basses fréquences, entre 200 Hz et 1000 Hz, ce qui témoigne ainsi notamment d'une excitation plus marquée dans cette zone plus en lien avec le défaut affectant la sphère d'hypothèse.

Les caractéristiques de différences entre les spectrogrammes des quatre états restent présentes et bien significants malgré le bruit donc qui est venu se superposer.




Figure IV. 43:Matrice de confusion du modèle en condition bruitée (durée 1 seconde).

Chapitre IV: Testes de robustesses

Dans la figure(IV.43), nous avons procédé à l'analyse comparative des performance de notre modèle pour l'appariement correct de quatre types de roulements (inner, normal, outer, roller) à partir des signaux bruités.

- D'excellentes performances sont enregistrées pour la détection des défauts internes : 454 classifications correctes.
- En revanche, les classes normales sont souvent confondues, avec 226 fois la classe inner au lieu de normal.
- On note également des confusions croisées fréquentes entre outer et roller : 265 fois outer est classé comme inner et 177 fois roller est classé pour outer.

Il est très vraisemblable que cette confusion provienne de la similitude des signatures acoustiques des défaillances dans les conditions bruitées en application. Une extraction de caractéristiques discriminantes est souhaitée.




Figure IV.44: Arbre de Décision pour la classification des défauts (durée 1 seconde).

L'arbre de décision présenté est celui utilisé pour le processus de classification des défauts sur les roulements à partir des signaux bruités.


- Il permet de constater que la classe « normal » est bien caractérisée avec peu de sous-classes, ce qui laisse penser que le modèle est robuste dans la détection de roulements sains même sous bruit.

Chapitre IV: Testes de robustesses

- Les classes « inner », « outer » et « roller » sont plus complexes à confondre, c'est pourquoi plusieurs niveaux de décision sont nécessaires pour les séparer, l'arbre est alors plus profond et plus complexe.

On peut penser que cette profondeur plus importante témoigne des difficultés à séparer les classes si le signal est affecté par une dégradation.

L'arbre reste toujours un bon axe d'interprétation, mais l'application du bruit fait que la classification est moins évidente, elle est plus complexe car elle doit lui (le bruit) faire face et qu'elle doit introduire davantage de critères afin de ne pas induire en erreur.



```
Résultats CV : [0.36036585 0.36180598 0.34594265 0.50030506 0.42342892]
Score moyen CV : 0.3983696930013839
Train Accuracy : 0.4465748649119749
Test Accuracy : 0.4225294835298902

Classification Report :
      precision    recall  f1-score   support

   inner       0.35       0.77       0.48        588
   normal       0.77       0.43       0.55        648
   outer       0.48       0.43       0.41        601
   roller       0.35       0.08       0.14        622

 accuracy         0.42         0.42         0.42       2459
 macro avg       0.47       0.43       0.39       2459
weighted avg       0.47       0.42       0.39       2459
```

Figure IV. 45: Résultats de classification après extension des signaux à 1 seconde et ajout de bruit blanc gaussien.

La performance globale du modèle s'avère faible, avec une précision de 42 %. La classe inner est bien présente (rappel de 0,77), mais mal identifiée (précision de 0,35), alors que pour la classe normal, la prédiction s'avère bonne au niveau de la précision (0,77), mais la sensibilité est faible (0,43). Les classes outer et roller sont aux plus bas, surtout roller (rappel 0,08, F1-score 0,14). Les scores moyens (macro et pondérés) confirment ces points faibles. L'ajout de bruit blanc et l'extension des signaux à une seconde ne permettent pas une nette amélioration de la robustesse du modèle.

IV.5.1 Comparaison des métriques de classification par classe avant et après bruit et allongement du signal

- **Avant Bruit**

La class normal est de très bien détectée, par contre les autres classes (roller et outer) ont une performance (f1-score) peu satisfaisante.

Chapitre IV: Testes de robustesses

- **Après Bruit**

Baisse légère de la précision globale (accuracy) (~92%).

Les classes minoritaires conservent des performances similaires à avant, ce qui montre que l'ajout de bruit n'améliore pas vraiment la détection des défauts rares.

- **Après Augmentation de Durée à 1s**

La précision globale baisse très fortement (~42%).

Les performances de toutes les classes baissent surtout celle de normal.

L'augmentation de durée semble avoir nui au modèle car elle dilue les caractéristiques discriminantes.



Figure IV.46: Comparaison des performances par classe selon différentes méthodes de traitement (avant bruit, après bruit, après bruit + 1s) sur les métriques de précision, rappel et F1-score.

IV.6 Discussion des limites du modèle et pistes d'amélioration

Dans cette section, nous analysons les principales limitations du modèle d'arbre de décision appliqué à la classification des signaux acoustiques.

IV.6.1 Limites du modèle

- **Sensibilité au bruit**

Le modèle montre une dégradation de ses performances lorsqu'il est confronté à des signaux bruités, en particulier pour les défauts subtils. Par exemple, les défauts sur les éléments roulants ou la bague extérieure sont difficiles à identifier lorsque le signal est perturbé par du

Chapitre IV: Testes de robustesses

bruit. Cela limite la capacité du modèle à fonctionner efficacement dans des environnements réels, où le bruit est souvent présent.

➤ Surajustement (Overfitting) et complexité

Au fur et à mesure que le modèle s'établit avec des données bruyantes, l'arbre décisionnel est de plus en plus profond et complexe, ce qui conduit à moins d'intelligibilité et engendre un surajustement, c'est-à-dire que le modèle est trop adapté au jeu de données d'apprentissage, sans généralisation sur du non vu.

➤ Déséquilibre des classes

Le modèle est biaisé par la classe majoritaire (les signaux normaux), ce qui l'empêche de bien classer les défauts, notamment les types de défauts rares ou plus subtils. Cette mauvaise gestion des classes déséquilibrées entraîne une diminution de la précision pour les classes minoritaires, limitant ainsi l'utilité du modèle dans des scénarios industriels où les défauts rares sont fréquents.

➤ Limitations dans la généralisation

Les performances du modèle se détériorent lorsqu'il est testé sur de nouvelles données ou des données bruitées. Cela suggère que le modèle manque de robustesse et n'est pas encore optimal pour des applications en conditions réelles, où les signaux peuvent varier en fonction des équipements et des environnements.

Conclusion

Ce chapitre a permis d'explorer la qualité et l'efficacité du modèle de classification fondé sur un arbre de décision lors d'une confrontation avec des signaux acoustiques bruités par du bruit blanc gaussien. Ce travail est conduit dans un cadre simulant des conditions industrielles réalistes aboutissant à plusieurs constats majeurs.

Les résultats montrent clairement que la classe « normale » reste identifiable, même en présence de bruit, ce qui démontre une certaine résistance du modèle. En revanche, la capacité de détection des classes défectueuses (inner, roller, outer) diminue fortement, mettant en lumière leur vulnérabilité face aux perturbations acoustiques. La performance globale reste néanmoins satisfaisante après l'ajout de bruit (~92 %), grâce notamment à la bonne

Chapitre IV: Testes de robustesses

reconnaissance des signaux sains, tandis que les classes moins représentées ne bénéficient d'aucun gain significatif.

Les spectrogrammes et les matrices de confusion mettent en évidence que certaines signatures fréquentielles subsistent malgré le bruit, laissant entrevoir des pistes d'amélioration possibles. Toutefois, cette robustesse partielle a un coût : l'arbre de décision devient plus complexe, plus profond, ce qui nuit à sa lisibilité et augmente le risque de surajustement.

Par ailleurs, allonger la durée des signaux à 1 seconde provoque une chute importante des performances (autour de 42 %). L'ensemble des classes est affecté, y compris la catégorie « normale », auparavant bien différenciée. Ce recul suggère que les éléments caractéristiques du signal se diluent sur une période plus longue, compliquant ainsi leur identification par le modèle.

Pour conclure, les résultats obtenus mettent en évidence les insuffisances du modèle en environnement bruité, qui nécessiterait des solutions plus robustes comme les forêts aléatoires et les réseaux de neurones ou encore des techniques de prétraitement et d'augmentation des données pour espérer une performance acceptable en condition d'utilisation réelle, caractérisée par la variabilité et l'imprévisibilité du bruit.

Conclusion générale

Conclusion générale

Conclusion générale

Face à la nécessité de maintenir des équipements complexes en bon état de fonctionnement sans interruption, les industriels se tournent de plus en plus vers des approches de maintenance fondées sur des données fiables et des analyses avancées. Parmi celles-ci, l'analyse acoustique appliquée aux moteurs se distingue par sa capacité à anticiper les défaillances critiques, notamment celles liées aux roulements. En combinant les spectrogrammes issus de l'analyse temps-fréquence avec des algorithmes d'arbre de décision, il devient possible d'identifier avec précision les premiers signes de dysfonctionnement.

Cependant, malgré les promesses de ces outils intelligents, leur intégration dans les processus industriels ne va pas sans poser certains défis. Sur le plan technique, il est essentiel de garantir la qualité des capteurs, la robustesse des algorithmes face au bruit ambiant, et l'adaptabilité du système à différents types de moteurs et de contextes d'exploitation. Sur le plan organisationnel, il faut repenser les compétences internes, adapter les méthodes de travail, et parfois surmonter une certaine résistance au changement.

En définitive, la maintenance intelligente par émission acoustique n'est pas seulement une innovation technologique : c'est une évolution culturelle. Elle demande de la vision, de la rigueur, mais aussi une volonté claire d'investir dans la fiabilité à long terme. Répondre aux défis qu'elle soulève, c'est construire dès aujourd'hui l'industrie résiliente, agile et durable de demain.

Références

Référence

[1] : « Operations & Maintenance Best Practices: A Guide to Achieving Operational Efficiency (Release 3.0) »,

https://www.energy.gov/sites/default/files/2013/10/f3/omguide_complete.pdf, publié en août 2010, consulté le 10/04/2025.

[2] : « Analysis finds decrease in U.S. manufacturing energy consumption », <https://www.energy.gov/eere/amo/articles/analysis-finds-decrease-us-manufacturing-energy-consumption>, publié le 20/05/2022, consulté le 10/04/2025.

[3] : « Electric motors », <https://www.skf.com/group/industries/general-machinery/electric-motors>, publié en 2023, consulté le 10/04/2025.

[4] : « Predictive Maintenance – Potentials for Reducing Environmental Impact », <https://www.ipa.fraunhofer.de/en/publications/studies-and-whitepapers/whitepaper-predictive-maintenance.html>, publié en 2023, consulté le 10/04/2025.

[5] : « Planifier la continuité des activités dans le secteur industriel », Everbridge, <https://www.everbridge.com/fr/blog/planifier-la-continuite-des-activites-dans-le-secteur-industriel/>, consulté le 08/05/2025.

[6] : « Qu'est-ce que la maintenance réactive ? Voici 3 exemples pratiques », BibLus - ACCA software, <https://biblus.accasoftware.com/fr/quest-ce-que-la-maintenance-reactive-voici-3-exemples-pratiques/>, consulté le 08/05/2025.

[7] : « GMAO - Gestion de maintenance assistée par ordinateur », Marche-public.fr, <https://www.marche-public.fr/Marches-publics/Definitions/Entrees/GMAO-gestion-maintenance-assistee-ordinateur.htm>, consulté le 08/05/2025.

[8] : « Indicateurs clés en gestion des incidents : MTTR, MTBF et autres métriques courantes », Atlassian, <https://www.atlassian.com/fr/incident-management/kpis/common-metrics>, consulté le 08/05/2025.

[9] : Dr. Djamel FRIHI , « Maintenance industrielle »,polycopie de cours, Université du 8 mai 1945– Guelma, Juin 2015.consulter le 12/04/2025.

- [10] « Guide sur la Maintenance Préventive : Tout Ce Que Vous Devez », <https://technomnt.com/guide-sur-la-maintenance-preventive/>, publié le 15 /09/2024, consulter le 10/04/2025.
- [11] : « Histoire et évolutions de la maintenance industrielle » , [https://mobility-work.com/fr/blog/histoire-maintenance-dans-industrie ?](https://mobility-work.com/fr/blog/histoire-maintenance-dans-industrie-?), publié 17/07/2019, dernière mise à jour 21/10/2021. consulter le 10/04/2025.
- [12] : « Evolution of maintenance | Download Scientific Diagram », https://www.researchgate.net/figure/Evolution-of- maintenance_fig2_373874317,,, consulter le 12/04/2025.
- [13] : « Emploi-construction » [https://www.emploi-construction.fr/quel-est-le-but-de-lamaintenance/#:~:text=La%20maintenance%20regroupe%20toutes%20les%20actions%20techniques%2C%20management,tout%20risque%20de%20panne%20ou%20d%C3%A9gradation%20du%20bien](https://www.emploi-construction.fr/quel-est-le-but-de-lamaintenance/#:~:text=La%20maintenance%20regroupe%20toutes%20les%20actions%20techniques%2C%20management,tout%20risque%20de%20panne%20ou%20d%C3%A9gradation%20du%20bien.). consulter le 26/04/2025.
- [14] « Software Maintenance Overview » , https://www.tutorialspoint.com/software_engineering/software_maintenance_overview.htm, consulter le 1/05/2025.
- [15] : « Les niveaux de maintenance - DURELEC TRANSFO ».
<https://durelectransfo.fr/niveaux-de-maintenance/>. consulter le 16/04/2025.
- [16] : « Overview of maintenance strategies (Source), https://www.researchgate.net/figure/Overview-of-maintenance-strategies-Source-Own-illustration-based-on-Schenk-2013_fig4_330217371, consulter le 3/05/2025.
- [17] « Organisation de la maintenance. Définitions – Risques », <https://www.inrs.fr/risques/maintenance/definitions.html>, publié le 24/10/2023, consulter le 30/04/2025.
- [18] « Tout savoir sur la maintenance préventive », <https://mobility-work.com/fr/blog/maintenance-preventive/>, Publié le 29 novembre 2021, mis à jour le 4 mars 2022, consulter le 13/04/2025.
- [19] « Qu'est-ce que la maintenance préventive – IBM », <https://www.ibm.com/fr-fr/topics/what-is-preventive-maintenance#:~:text=%C3%89tapes%20suivantes->

,Qu'est%2Dce%20que%20la%20maintenance%20pr%C3%A9ventive%20%3F,elles%20ne%20tombent%20en%20panne. consulter le 26/04/2025.

[20] : « La maintenance préventive pour anticiper les défaillances », <https://www.divalto.com/field-service-management/gestion-maintenance/types-de-maintenance/maintenance-preventive/>, 2022,consulter le 19/04/2025.

[21]« Les différents types de maintenance », <https://www.tribofilm.fr/les-differents-types-de-maintenance/> 6/10/ 2021, consulter le 26/04/2025.

[22] : « Définitions, méthodes et opérations de la maintenance », polycopie de cours, <http://dspace.univtiaret.dz/bitstream/123456789/11990/8/g%29chapitre1aintenance.pdf>,consulter le 10/04/2025.

[23] : « What Is the Major Difference Between Preventive and ... », <https://medium.com/@assetinfinity21/what-is-the-major-difference-between-preventive-and-corrective-maintenance-b9a788527ad4>,consulter le 3/05/2025.

[24] : « Qu'est-ce que la maintenance industrielle ? », <https://www.gmao.com/maintenance-industrielle/enjeux-maintenance-industrielle/>, Publié 3/042024,consulter le13/04/2025 .

[25]« Guide sur la Maintenance Préventive : Tout Ce Que Vous Devez », <https://technomnt.com/guide-sur-la-maintenance-preventive/>,publié le 15 /09/2024,consulter le 13/04/2025.

[26] : « Risques liés à une absence de maintenance préventive », <https://www.service-industrie.net/maintenance-preventive/risques-lies-a-une-absence-de-maintenance-preventive/>,publié en 2025,consulter le 18/04/2025.

[27]« Accidents du travail et expositions professionnelles », <https://www.inrs.fr/risques/maintenance/accidents-travail-expositions-professionnelles.html>, Publié 24/102023,consulter le18/04/2025 .

[28] : « Le Contrôle Non Destructif ou CND – Définition », <https://www.plastiform.info/fr/blog/assurance-qualite/le-controle-non-destructif-ou-cnd/?srsltid=AfmBOopw4lmD4m8-cY6MAgWFTDO6XqTKs7-AozvLP08BstPk4W5TnSYw>, publié en 2024,consulter le 28/04/2025.

[29] : « Applications des contrôles non destructifs»,

<https://safetyculture.com/fr/themes/controle-non-destructif/>, publié en 2025, consulter le 18/04/2025.

[30] : « STRATEGIE de MAINTENANCE », polycopie de cours, université frères mentouri, https://fac.umc.edu.dz/ista/pdf/cours/Maintenance_des_Equipements.pdf, consulter le 18/04/2025.

[31] : « Les contrôles non destructifs (CND) », <https://ealico.com/fr-fr/blog/lecontr%C3%B4les-non-destructifs-cnd/>, publié le 17/05/2024, consulter le 18/04/2025.

[32] : « STRATEGIE de MAINTENANCE », polycopie de cours, université frères mentouri, https://fac.umc.edu.dz/ista/pdf/cours/Maintenance_des_Equipements.pdf, consulter le 18/04/2025.

[33] « Le CND : Contrôle non destructif », https://rescoll.fr/le-cnd-controle-non-destructif__trashed/, publié le 28 /09/2011, consulter le 18/04/2025.

[34]: « Les contrôles non destructifs (CND) », <https://ealico.com/fr-fr/blog/les-contr%C3%B4les-non-destructifs-cnd/> publié le 17/05/ 2024, consulter le 18/04/2025.

[35] : « Les contrôles non destructifs des ouvrages en béton », <https://technobeton.wordpress.com/2016/11/28/les-controles-non-destructifs-des-ouvrages-en-beton/>, publié le 28/11/2016 , consulter le 18/04/2025.

[36] : « Moteur — Wikipédia », <https://fr.wikipedia.org/wiki/Moteur>, Cet article ne cite pas suffisamment ses sources (novembre 2013), La dernière modification de cette page a été faite le 10 /04/2025 à 12:20. consulter le 17/04/2025.

[37] : Souhayb Kass, « Diagnostic vibratoire autonome des roulements », these, <http://theses.insa-lyon.fr/publication/2019LYSEI103/these.pdf>, [2019], consulter le 17/04/2025 .

[38] : Souhayb Kass, « Diagnostic vibratoire autonome des roulements », these, <http://theses.insa-lyon.fr/publication/2019LYSEI103/these.pdf>, [2019], consulter le 17/04/2025 .

[39] : M. Chorfi Sofiane, « Partie I: ROULEMENTS », polycopie de cours, université frères mentouri Constantine 1,

<https://fac.umc.edu.dz/ista/pdf/cours/Partie%20I%28%20conception%20m%C3%A9canique%29.pdf>, consulter le 13 /04/2025.

[40] : « Rolling element bearing components and failing frequencies », <https://power-mi.com/content/rolling-element-bearing-components-and-failing-frequencies>, 2025, consulter le 24/04/2025.

[41] « 17-Défauts d'écaillage réels | Download Scientific Diagram », https://www.researchgate.net/figure/Defauts-decaillage-reels_fig50_283488469, consulter le 30/04/2025.

[42] : MESAUDI Khaled ,SLIMANI Sofiane , « Outils d'analyse et du diagnostic des défauts de roulements et d'engrenages », Outils%20d'analyse%20et%20du%20diagnostic%20des%20défauts%20de%20roulements%20et%20d'engrenages, Université de Béjaïa A-MIRA 14/06/2015, consulter le 18/04/2025.

[43] : « Tout ce que vous devez savoir sur les causes de ... », <https://www.aubearing.com/fr/everything-you-should-know-about-bearing-failure-causes-and-preventive-measures/>, consulter le 18/04/2025.

[44] : « Apprentissage automatique », https://fr.wikipedia.org/wiki/Apprentissage_automatique, La dernière modification de cette page a été faite le 19 février 2025 à 11:19, consulter le 25/04/2025.

[45] : « Tout savoir sur les arbres de décision », <https://www.lucidchart.com/pages/fr/tutoriel/arbre-de-decision>, publié en 2025, consulter le 25/04/2025.

[46] : « Tout savoir sur les arbres de décision », <https://www.lucidchart.com/pages/fr/tutoriel/arbre-de-decision> ,publié en 2025, consulter le 25/04/2025.

[47] : Larbaoui Racha, Naceri Siham , « Une Approche Sémantique Pour Le Data Mining Et Le Machine Learning », Memoire de Master en Informatique, Université AMO de Bouira ,2020/2021, consulter le 27/04/2025.

- [48] : « Apprentissage — Wikipédia », <https://fr.wikipedia.org/wiki/Apprentissage>, La dernière modification de cette page a été faite le 15 décembre 2024 à 14:55, consulter le 23/04/2025.
- [49] « APPRENTISSAGE AVEC ARBRE DE DÉCISION », https://staff.univ-batna2.dz/sites/default/files/titouna_faiza/files/arbre_decision.pdf?m=1670780742, Cours Master1 IAM, publié en 2022, consulter le 25/04/2025.
- [50] : « F1 Score in Machine Learning Explained », <https://encord.com/blog/f1-score-in-machine-learning/>, publié le 18/07/ 2023, consulter le 3/05/2025.
- [51] : « Accuracy and precision », <https://www.basicknowledge101.com/pdf/literacy/Accuracy%20and%20precision.pdf> consulter le 24/04/2025.
- [52] : « Classification: justesse, rappel, précision et métriques ... » , <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=fr>, publié le 23/01/2025, consulter le 24/04/2025.
- [53] : « Classification: justesse, rappel, précision et métriques ... » , <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=fr>, publié le 23/01/2025, consulter le 24/04/2025.
- [54] : « F1-Score : Définition, formule et applications », <https://www.ultralytics.com/fr/glossary/f1-score>, consulter le 24/04/2025 .
- [55] : « Understanding Micro, Macro, and Weighted Averages for ... » <https://iamirmasoud.com/2022/06/19/understanding-micro-macro-and-weighted-averages-for-scikit-learn-metrics-in-multi-class-classification-with-example>, © 2015-2025 Amir Masoud Sefidian, consulter le 25/04/2025.
- [56] : « Les différents types de bruits », https://www.pytaudio.com/les-differents-types-de-bruits/?srsId=AfmBOopoBu6-98pzu9fPTP3C_Q5Dbi9Zst2_iLs6SXA6waBx8h-PcHy, consulter le 5/5/2025.
- [57] « Comment gérer le bruit dans l'apprentissage automatique », <https://fr.linkedin.com/advice/0/how-do-you-handle-noise-machine-learning-skills-machine-learning?lang=fr>, publié le Aug 4, 2023, consulter le 4/5/2025.

[58]:« Bruits types - lexique acoustique », <https://www.aclaf.fr/lexique-acoustique-et-definitions/lexique-des-bruits-types/>, consulter le 5/5/2025.

