

الجمهورية الجزائرية الديمقراطية الشعبية
République algérienne démocratique et populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique
جامعة عين تموشنت بلحاج بوشعيب
Université –Ain Temouchent- Belhadj Bouchaib
Faculté des Sciences et de Technologie
Département d'Électronique et des Télécommunications



Projet de Fin d'Etudes
Pour l'obtention du diplôme de Master en :
Domaine : Sciences et Technologie
Filière : Électronique
Spécialité : Instrumentation
Thème

Diagnostic de Défauts des Machines par Analyse Vibratoire

Présenté par :

- 1) Mr MATARI Mohamed El Amine
- 2) Mr ABDELKADER Abdelaziz

Devant le jury composé de :

Dr BENZINA Amina	UAT.B.B (Ain Temouchent)	Présidente
Mme BOUTKHIL Malika	UAT.B.B (Ain Temouchent)	Examinatrice
Dr BENTAIEB Samia	UAT.B.B (Ain Temouchent)	Encadrante
Dr BENZAZZA Baghdadadi	UAT.B.B (Ain Temouchent)	Invité

Année Universitaire 2025/2026

Je dédie ce modeste travail à mes très chers parents, qui ont toujours été une source d'amour, de soutien et d'encouragement tout au long de mon parcours. Aucun mot ne saurait exprimer ma profonde gratitude pour leurs sacrifices, leur patience et leur confiance qui m'ont permis d'atteindre cet objectif. Je le dédie également à toute ma famille, pour son affection, son soutien moral et sa présence dans les moments les plus importants de ma vie. À tous ceux qui m'ont accompagné, encouragé et soutenu de près ou de loin durant mes études, je témoigne ma sincère reconnaissance.

Mohamed Al Amine

À mes très chers parents, Aucune dédicace ne saurait exprimer toute la reconnaissance, l'amour et le respect que je vous porte. Je vous remercie pour tous les sacrifices que vous avez consentis afin de m'offrir les meilleures conditions de réussite. Votre soutien constant, vos encouragements, votre patience et votre confiance ont toujours été ma plus grande source de motivation. Ce travail est le fruit de vos efforts, de votre affection et de vos prières qui m'ont accompagné tout au long de mon parcours.

Abdelazziz

Remerciements

Avant tout, nous remercions Allah le Tout-Puissant de nous avoir accordé la santé, la volonté, la patience et la persévérance nécessaires pour mener à bien ce travail.

Nous tenons à exprimer notre profonde gratitude à notre encadrante, Dr Bentaieb Samia, pour son accompagnement précieux, sa disponibilité, ses conseils avisés et ses orientations tout au long de la réalisation de ce mémoire. Son soutien scientifique, sa rigueur et ses encouragements constants ont largement contribué à l'aboutissement de ce travail.

Nous exprimons également notre gratitude aux membres du jury qui ont accepté d'évaluer ce mémoire et de consacrer une partie de leur temps à l'examen de notre travail.

Nous adressons également nos sincères remerciements au Dr Adjoudj, chef de département d'Électrotechnique, et aux ingénieurs du laboratoire pour leur aide technique, leur disponibilité et leur précieuse collaboration. Leurs conseils et leur assistance nous ont permis de surmonter plusieurs difficultés rencontrées au cours de ce projet.

Nos remerciements s'adressent aussi à l'ensemble des enseignants du département d'Électronique et de Télécommunications qui ont contribué à notre formation académique et scientifique durant notre cursus universitaire. Grâce à leurs enseignements et à leur dévouement, nous avons acquis les connaissances nécessaires à la réalisation de ce travail.

Nous remercions chaleureusement nos familles pour leur soutien moral, leur confiance, leurs encouragements et leurs sacrifices tout au long de nos études. Leur présence et leur soutien ont été une source permanente de motivation.

Enfin, nous adressons nos remerciements à toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce travail et nous ont apporté leur aide, leurs conseils ou leur soutien.

À toutes et à tous, nous exprimons notre profonde reconnaissance et notre sincère gratitude.

ملخص

يهدف هذا العمل إلى تطوير نظام ذكي لمراقبة الاهتزازات وتشخيص أعطال الآلات الدوارة اعتماداً على تحليل الإشارات الاهتزازية وتقنيات الذكاء الاصطناعي. تم تصميم نموذج أولي يتكون من محرك كهربائي مقترن بمولد، وحساسين، ولوحة. كما تم إنشاء قاعدة بيانات حقيقية تضم ١٨٠ إشارة اهتزازية موزعة على ثلاث حالات تشغيل: عادية، عدم الاتزان، وعدم المحاذاة. تمت معالجة الإشارات في المجالين الزمني والترددي واستخراج الخصائص المميزة للأعطال، ثم تدريب نماذج لتصنيف حالة الآلة. بالإضافة إلى ذلك، تم تطوير تطبيق ويب للمراقبة والتشخيص في الزمن الحقيقي. أظهرت النتائج فعالية النظام المقترح في الكشف عن الأعطال الميكانيكية ودعمه لتطبيقات الصيانة التنبؤية.

الكلمات المفتاحية: الاهتزازات، الآلات الدوارة، الذكاء الاصطناعي

Abstract

This work presents an intelligent vibration monitoring system for rotating machinery fault diagnosis. A prototype based on two GY-LSM6DS3 sensors and a Raspberry Pi 4 was developed to acquire vibration signals under normal, imbalance, and misalignment conditions. A database of 180 signals was created and analyzed in both time and frequency domains. KNN, SVM, and DNN models were used for fault classification. A web application named *VibraTech Monitor* was also developed for real-time monitoring and diagnosis. The results confirm the effectiveness of the proposed system for predictive maintenance.

Keywords: vibration analysis, artificial intelligence, mechanical faults

Résumé

Ce travail présente un système intelligent de surveillance vibratoire destiné au diagnostic des défauts des machines tournantes. Un prototype basé sur deux capteurs GY-LSM6DS3 et une Raspberry Pi 4 a été développé pour acquérir des signaux vibratoires dans les états normal, déséquilibre et désalignement. Une base de données de 180 signaux a été constituée puis analysée dans les domaines temporel et fréquentiel. Les modèles KNN, SVM et DNN ont été utilisés pour la classification automatique des défauts. Une application web *VibraTech Monitor* a également été développée pour la supervision et le diagnostic en temps réel. Les résultats obtenus confirment l'efficacité de la solution proposée pour la maintenance prédictive.

Mots clés : l'analyse vibratoire, l'intelligence artificielle, défauts mécaniques

1	Maintenance Industrielle et Analyse Vibratoire	3
1.1	Introduction	4
1.2	Maintenance industrielle	4
1.2.1	Types de maintenance	4
1.2.2	Importance de la maintenance industrielle	6
1.2.3	Coûts de maintenance vs coûts de défaillance	7
1.2.4	Indicateurs de performance (MTBF, MTTR, Disponibilité)	8
1.3	Introduction à l'analyse vibratoire	9
1.3.1	Définition des vibrations mécaniques	9
1.3.2	Origine des vibrations dans les machines tournantes	11
1.3.3	Caractéristiques d'un signal vibratoire	12
1.3.4	Unités de mesure	15
1.3.5	Capteurs de mesure vibratoire	16
1.4	Machines tournantes et leurs défauts	16
1.4.1	Composants des machines tournantes	16
1.4.2	Types des défauts courants	19
1.4.3	Niveaux vibratoires normatifs (ISO 10816)	26
1.5	Conclusion	27
2	Diagnostic Vibratoire des Machines Tournantes par IA	28
2.1	Introduction	29
2.2	Base de données MaFaulDa	29
2.2.1	Description du banc d'essai	29
2.2.2	Protocole d'acquisition	31
2.2.3	Classes de défauts	31
2.3	Pipeline de traitement	34
2.4	Prétraitement des signaux	35
2.4.1	Filtrage	35
2.4.2	Normalisation	36
2.5	Extraction de caractéristiques	36
2.5.1	Analyse dans le domaine temporel	37
2.5.2	Analyse dans le domaine fréquentiel	38
2.5.3	Analyse de corrélation et sélection des caractéristiques	41
2.6	Classifieurs	43
2.6.1	K-Plus Proches Voisins (KNN)	43
2.6.2	Machine à Vecteurs de Support (SVM)	44
2.6.3	Perceptron multicouche (MLP)	45
2.7	Protocole expérimental	47

2.7.1	Partitionnement train / test	47
2.7.2	Métriques d'évaluation	48
2.7.3	Environnement d'implémentation	48
2.8	Résultats	48
2.8.1	Résultats dans le domaine temporel	49
2.8.2	Résultats dans le domaine fréquentiel	51
2.8.3	Synthèse comparative	54
2.9	Discussion	54
2.10	Conclusion	55
3	Déploiement du Système de Diagnostic Vibratoire Embarqué	57
3.1	Introduction	58
3.2	Environnement matériel	58
3.2.1	Raspberry Pi 4	58
3.2.2	Capteur GY-LSM6DS3	59
3.2.3	Connexion I2C entre la Raspberry Pi 4 et les capteurs	60
3.2.4	Banc d'essai expérimental	60
3.3	Acquisition des signaux vibratoires réels	61
3.3.1	Protocole d'acquisition	62
3.3.2	Description des classes	63
3.3.3	Caractéristiques des signaux acquis	64
3.4	Prétraitement et extraction des caractéristiques	65
3.5	Entraînement des modèles sur les données réelles	66
3.5.1	Protocole expérimental	66
3.5.2	Domaine temporel	66
3.5.3	Domaine fréquentiel	67
3.5.4	Comparaison et discussion	68
3.6	Optimisation et conversion des modèles	68
3.6.1	Conversion au format TensorFlow Lite	68
3.6.2	Quantification float16	69
3.6.3	Sauvegarde des modèles KNN et SVM	69
3.7	Conclusion	69
4	Application Web de Supervision Streamlit	70
4.1	Introduction	71
4.2	Prototype réalisé	71
4.3	Déploiement sur Raspberry Pi 4	72
4.3.1	Environnement matériel	72
4.3.2	Optimisation et conversion des modèles pour l'embarqué	76
4.3.3	Pipeline d'inférence embarquée	76
4.4	Architecture client-serveur (RPi4 ↔ Streamlit)	77

4.5	Application web vibraTech monitor	77
4.5.1	Page d'accueil de l'application	78
4.5.2	Page d'analyse vibratoire en temps réel	79
4.5.3	Fonctionnement global de l'application	81
4.5.4	Avantages de l'application	81
4.6	Conclusion	82
Bibliographie		85

Table des figures

1.1	Classification des types de maintenance	5
1.2	Coûts de défaillance	8
1.3	Vibrations sinusoïdales	10
1.4	Vibrations périodiques	10
1.5	Vibrations aléatoires	10
1.6	Différents types de balourd et déséquilibre dynamique	11
1.7	Types des erreurs d'alignement	12
1.8	Les niveaux d'amplitude dans l'analyse vibratoire	13
1.9	Spectre vibratoire d'un roulement sous différentes vitesses de rotation	14
1.10	Représentation de la phase d'un signal vibratoire	14
1.11	Composants d'un roulement	17
1.12	Composants d'un engrenage	18
1.13	Types d'engrenage	18
1.14	Accouplement rigide [1]	19
1.15	Accouplement flexible [1]	19
1.16	Balourd statique	20
1.17	Balourd dynamique [2]	21
1.18	Composants d'un roulement [3]	21
1.19	Écaillage sur la bague intérieure [3]	22
1.20	Écaillage sur la bague extérieure [3]	23
1.21	Défaut d'usure [4]	24
1.22	Défaut de piqure [4]	24
1.23	Défaut d'écaillage [4]	24
1.24	Fissure transversale [5]	25
1.25	Fissure longitudinale [5]	25
1.26	Fissure inclinée [5]	26
2.1	Banc d'essai d'analyse de défauts de machines (MFS)	30
2.2	Signaux vibratoires caractéristiques des six classes de la base MaFaulDa	32
2.3	Diagramme sectoriel des classes de défaut	34
2.4	Organigramme du pipeline de traitement des signaux vibratoires	34

2.5	Effet de la suppression de la composante continue (detrend et du filtrage de Butterworth) sur la base MaFaulDa	36
2.6	Spectres d'amplitude FFT des six classes de la base MaFaulDa	40
2.7	Matrice de corrélation des caractéristiques temporelles	42
2.8	Exemple de classification par l'algorithme KNN ($k = 3$)	43
2.9	Hyperplan optimal, marge et vecteurs de support	45
2.10	Architecture du réseau de neurones à deux couches cachées	46
2.11	Partitionnement train/test du jeu de données	48
2.12	Évolution de la précision en fonction de k sur le domaine temporel	49
2.13	Matrice de confusion KNN en domaine temporel	49
2.14	Matrice de confusion SVM, domaine temporel	50
2.15	Courbes d'apprentissage du modèle MLP domaine temporel (loss et accuracy)	51
2.16	Matrice de confusion MLP en domaine temporel	51
2.17	Évolution de la précision en fonction de k domaine fréquentiel	52
2.18	Matrice de confusion KNN, domaine fréquentiel	52
2.19	Matrice de confusion de modèle SVM en domaine fréquentiel	53
2.20	Courbes d'apprentissage du modèle MLP domaine fréquentiel	53
2.21	Matrice de confusion de modèle MLP en domaine fréquentiel	54
3.1	La carte Raspberry Pi 4	58
3.2	L'accéléromètre GY-LSM6DS3	59
3.3	Connexion I2C entre la carte Raspberry Pi 4 et les deux capteurs LSM6DS3	60
3.4	Le banc d'essai expérimental utilisé dans notre travail	61
3.5	Acquisition des données de défaut désalignement	62
3.6	Le protocole d'acquisition des signaux vibratoires	62
3.7	Défaut de déséquilibre (imbalance)	63
3.8	Défaut de désalignement	64
3.9	Signal temporel et spectre fréquentiel classe normal	64
3.10	Signal temporel et spectre fréquentiel classe imbalance	65
3.11	Signal temporel et spectre fréquentiel classe désalignement	65
3.12	Matrices de confusion des trois modèles en domaine temporel	67
3.13	Matrices de confusion des trois modèles en domaine fréquentiel	68
4.1	Vue globale du système	71
4.2	Interface de supervision et architecture de communication du système développé	72
4.3	Page d'accueil de l'application VibraTech Monitor	78
4.4	Page d'analyse temps réel des signaux vibratoires	79

Liste des tableaux

1.1	Comparaison des capteurs vibratoires	16
1.2	Fréquences caractéristiques des défauts de roulement	22
1.3	Zones de sévérité vibratoire selon ISO 10816-3 (machines 15 kW – 300 kW)	27
2.1	Caractéristiques techniques du banc MaFaulDa	29
2.2	Résumé des défauts et des séquences de la base MAFAULDA	33
2.3	Récapitulatif des indicateurs temporels	38
2.4	Récapitulatif des indicateurs fréquentiels	41
2.5	Comparaison des modèles leurs précision et temps d'exécution	54
3.1	Caractéristiques techniques de la carte Raspberry Pi 4	59
3.2	Caractéristiques techniques du capteur GY-LSM6DS3	60
3.3	Paramètres d'acquisition des signaux vibratoires	63
3.4	Paramètres utilisés pour le prétraitement et l'extraction des caractéristiques	66
3.5	Comparaison des performances des modèles dans le domaine temporel	67
3.6	Comparaison des performances des modèles dans le domaine fréquentiel	67
3.7	Comparaison des performances des modèles sur les données vibratoires réelles acquises par les capteurs GY-LSM6DS3	68
4.1	Caractéristiques techniques de la carte Raspberry Pi 4	73
4.2	Caractéristiques techniques du capteur GY-LSM6DS3	73
4.3	Connexions I2C entre le capteur GY-LSM6DS3 et la Raspberry Pi 4	74
4.4	Comparaison des temps d'inférence sur PC et Raspberry Pi 4	76
4.5	Comparaison des modèles disponibles dans l'application	80

Introduction Générale

Avec le développement rapide de l'industrie moderne, les machines tournantes occupent une place essentielle dans les systèmes industriels tels que les moteurs électriques, les turbines, les pompes et les compresseurs. Le bon fonctionnement de ces équipements est indispensable afin d'assurer la continuité de la production, la sécurité des installations et la réduction des coûts de maintenance.

Cependant, ces machines sont souvent exposées à différents défauts mécaniques tels que le déséquilibre, le désalignement, les défauts de roulements et les défaillances mécaniques. Ces anomalies peuvent entraîner des vibrations excessives, une diminution des performances ainsi que des arrêts imprévus des systèmes industriels.

Dans ce contexte, l'analyse vibratoire représente aujourd'hui l'une des techniques les plus utilisées pour le diagnostic et la surveillance des machines tournantes. Les signaux vibratoires contiennent des informations importantes permettant d'identifier l'état de fonctionnement des équipements et de détecter les défauts avant l'apparition de pannes critiques.

Grâce aux progrès récents de l'intelligence artificielle, du Machine Learning et des systèmes embarqués, il est désormais possible d'automatiser l'analyse des signaux vibratoires et de développer des systèmes intelligents capables de réaliser un diagnostic automatique en temps réel.

L'objectif principal de ce travail consiste à développer un système intelligent de surveillance vibratoire basé sur l'intelligence artificielle et le Raspberry Pi 4 afin de détecter automatiquement les défauts mécaniques des machines tournantes à partir des signaux acquis par des capteurs accéléromètres.

Le présent mémoire est organisé en quatre chapitres principaux :

— **Chapitre 1 : Maintenance Industrielle et Analyse Vibratoire** 3

Ce chapitre présente les notions fondamentales relatives aux vibrations mécaniques, aux stratégies de maintenance industrielle, aux défauts des machines tournantes ainsi qu'aux techniques d'intelligence artificielle utilisées pour le diagnostic vibratoire.

— **Chapitre 2 : Développement des Modèles de Diagnostic Vibratoire** 28

Ce chapitre décrit les étapes de prétraitement des signaux vibratoires, l'extraction des caractéristiques dans les domaines temporel et fréquentiel ainsi que l'entraînement et l'évaluation des modèles KNN, SVM et DNN sur la base de données MaFaultDa.

— **Chapitre 3 : Acquisition Réelle et Déploiement du Système Embarqué** 57

Ce chapitre présente la réalisation du banc expérimental, l'acquisition des signaux vibratoires réels à l'aide de deux capteurs GY-LSM6DS3 connectés à une Raspberry Pi 4, la constitution d'une base de données de 180 signaux répartis entre les états normal, déséquilibre et désalignement, ainsi que l'entraînement et l'optimisation des modèles destinés au système embarqué.

— **Chapitre 4 : Application Web de Supervision – VibraTech Monitor** 70

Ce chapitre présente le développement de l'application web VibraTech Monitor, l'architecture client-serveur mise en place entre la Raspberry Pi 4 et l'interface Streamlit, ainsi que les fonctionnalités de supervision et de diagnostic vibratoire en temps réel.

À travers ce travail, nous proposons une solution intelligente de surveillance vibratoire combinant l'analyse des signaux, l'intelligence artificielle et les systèmes embarqués. Les résultats obtenus démontrent l'efficacité des modèles développés pour le diagnostic automatique des défauts mécaniques et mettent en évidence le potentiel des techniques d'intelligence artificielle dans les applications de maintenance prédictive industrielle.

Chapitre 1

Maintenance Industrielle et Analyse Vibratoire

1.1	Introduction	4
1.2	Maintenance industrielle	4
1.2.1	Types de maintenance	4
1.2.2	Importance de la maintenance industrielle	6
1.2.3	Coûts de maintenance vs coûts de défaillance	7
1.2.4	Indicateurs de performance (MTBF, MTTR, Disponibilité)	8
1.3	Introduction à l'analyse vibratoire	9
1.3.1	Définition des vibrations mécaniques	9
1.3.2	Origine des vibrations dans les machines tournantes	11
1.3.3	Caractéristiques d'un signal vibratoire	12
1.3.4	Unités de mesure	15
1.3.5	Capteurs de mesure vibratoire	16
1.4	Machines tournantes et leurs défauts	16
1.4.1	Composants des machines tournantes	16
1.4.2	Types des défauts courants	19
1.4.3	Niveaux vibratoires normatifs (ISO 10816)	26
1.5	Conclusion	27

1.1 Introduction

La maintenance industrielle occupe une place stratégique dans la performance, la sécurité et la compétitivité des systèmes de production. Avec l'évolution des technologies et l'augmentation des exigences de disponibilité des équipements, les méthodes de maintenance ont connu une transformation significative, passant d'une approche essentiellement corrective à des stratégies plus avancées telles que la maintenance préventive et prédictive. Parmi les outils modernes de surveillance de l'état des machines, l'analyse vibratoire s'impose comme une technique incontournable, notamment pour les machines tournantes. Ce chapitre présente les concepts fondamentaux de la maintenance industrielle et introduit l'analyse vibratoire comme outil clé de la maintenance prédictive.

1.2 Maintenance industrielle

La maintenance industrielle regroupe l'ensemble des actions techniques, administratives et de gestion visant à maintenir ou à rétablir un bien dans un état lui permettant d'assurer une fonction requise [6].

La maintenance occupe aujourd'hui une place centrale dans la gestion des systèmes de production. Face aux exigences croissantes de disponibilité et de fiabilité des équipements, les entreprises industrielles sont amenées à adopter des stratégies de maintenance de plus en plus élaborées. Dans ce qui suit, nous présentons les principaux types de maintenance utilisés dans le milieu industriel.

1.2.1 Types de maintenance

Le choix d'une stratégie de maintenance adaptée constitue un levier essentiel pour optimiser les performances des systèmes industriels. On distingue généralement quatre types de maintenance, allant de la simple réaction après panne jusqu'à l'anticipation intelligente des défaillances.

1.2.1.1 Maintenance corrective

Selon les normes (AFNOR X 60-010 / ISO 13306), la maintenance corrective désigne toute intervention réalisée à la suite de la perte totale ou partielle de la capacité fonctionnelle d'un système. Elle vise à corriger les effets d'une défaillance avérée afin de rétablir les performances opérationnelles spécifiées de l'équipement. La maintenance corrective comprend [7] :

- Maintenance corrective palliative : action de maintenance corrective provisoire, ayant pour objectif de permettre au bien d'assurer temporairement sa fonction sans éliminer la cause de la défaillance.
- Maintenance corrective curative action de maintenance corrective définitive, ayant pour objectif de rétablir le bien dans un état spécifié en supprimant la cause de la défaillance.

Si la maintenance corrective reste indispensable pour faire face aux pannes imprévues, elle ne saurait constituer à elle seule une stratégie efficace. C'est pourquoi des approches préventives ont été développées pour anticiper les défaillances avant qu'elles ne surviennent.

1.2.1.2 Maintenance préventive systématique

La maintenance préventive systématique est une stratégie de maintenance qui vise à éviter une panne ou la défaillance d'un équipement à travers une intervention planifiée, sans tenir compte de son état actuel. Elle repose donc sur un planning prédéfini pour planifier le remplacement ou la réparation des machines ou systèmes avant qu'ils ne montrent des signes de dysfonctionnement.

Cette stratégie est régulièrement utilisée dans des environnements où la défaillance de l'équipement peut entraîner des conséquences graves. Elle est particulièrement efficace pour les équipements dont les modes de défaillance sont bien compris, et pour lesquels il existe des données historiques fiables sur la durée de vie des composants.

Toutefois, cette approche ne tient pas compte de l'état réel de l'équipement au moment de l'intervention, ce qui peut conduire à des remplacements prématurés et des coûts inutiles. La maintenance conditionnelle propose une alternative plus rationnelle.

1.2.1.3 Maintenance préventive conditionnelle

La maintenance préventive conditionnelle est basée sur l'évaluation de l'état réel des équipements. C'est en fonction de leur intégrité que sont déterminées les interventions. La maintenance conditionnelle s'appuie donc sur le traitement de données et des indicateurs spécifiques relatifs à la performance et à l'état des machines (mesures de vibration, de température, de pression, analyses de lubrifiants, etc.) pour déclencher une intervention.

En poussant cette logique plus loin, et grâce aux avancées récentes dans le domaine de l'intelligence artificielle et du traitement du signal, il devient possible non seulement de surveiller l'état d'un équipement, mais également de prédire ses futures défaillances.

1.2.1.4 Maintenance prédictive

La maintenance prédictive est un des types de maintenance industrielle. Plusieurs techniques d'analyse des données permettent d'anticiper les pannes et les dysfonctionnements des installations d'une entreprise. La maintenance prédictive repose sur la surveillance continue de l'intégrité des machines.

La collecte et l'analyse des informations fournies par les capteurs placés sur les équipements servent à identifier et à localiser les indices de défaillance à venir. Cette connaissance *a priori* des pannes permet de programmer des interventions proactives, prolongeant la durée de vie des équipements et évitant du même coup un arrêt inopiné de la production. Le diagramme suivant illustre de manière synthétique les différents types de maintenance et leurs relations.




Figure 1.1: Classification des types de maintenance

1.2.2 Importance de la maintenance industrielle

Au-delà du simple maintien des équipements en état de marche, la maintenance industrielle représente un véritable levier stratégique pour les entreprises. Elle agit simultanément sur la continuité de la production, la maîtrise des coûts et la durée de vie des actifs industriels.

1.2.2.1 Maintien des opérations

La maintenance prédictive permet à l'entreprise d'anticiper les défaillances potentielles en s'appuyant sur l'analyse des données issues des équipements et des systèmes. Grâce à l'utilisation de capteurs intelligents et d'algorithmes avancés, elle détecte les signaux faibles annonciateurs de pannes, ce qui offre la possibilité d'intervenir avant que le dysfonctionnement ne survienne réellement. Ce processus proactif limite ainsi les interruptions non planifiées, assurant une meilleure disponibilité des installations et une gestion plus efficace des ressources.

1.2.2.2 Réduction des coûts

Grâce à l'anticipation des problèmes, la maintenance prédictive évite les dépenses imprévues liées aux réparations d'urgence. L'entreprise peut ainsi effectuer des réparations ou des remplacements planifiés et réduire ses coûts de maintenance globaux. En effet, le coût d'une intervention préventive est généralement bien inférieur à celui d'une réparation corrective réalisée en urgence, qui implique souvent l'immobilisation non planifiée des équipements, le recours à des prestataires externes et l'achat de pièces de rechange en express. Par ailleurs, la réduction des arrêts imprévus se traduit directement par une augmentation de la productivité et une meilleure maîtrise des délais de livraison.

1.2.2.3 Prolongement de la durée de vie des équipements

La maintenance prédictive permet de prévenir les dommages plus importants qui pourraient compromettre la fiabilité et la performance des équipements à long terme, car elle identifie et corrige les problèmes potentiels à un stade précoce. En intervenant avant que la dégradation n'atteigne un seuil critique, elle limite l'usure prématurée des composants et préserve l'intégrité mécanique des machines. Ainsi, des équipements correctement surveillés et entretenus peuvent fonctionner bien au-delà de leur durée de vie théorique, retardant les investissements de remplacement et réduisant les coûts d'immobilisation. De plus, en évitant les défaillances brutales qui peuvent provoquer des dommages en cascade sur les composants voisins, la maintenance prédictive protège l'ensemble du système de production et garantit une disponibilité maximale des équipements sur le long terme.

1.2.2.4 Optimisation des ressources

La maintenance prédictive cible de façon précise les équipements qui présentent des signes de défaillance imminente. Ce faisant, elle optimise l'allocation des ressources et réduit les interventions inutiles liées à un planning prédéfini. Contrairement à la maintenance systématique qui impose des interventions à intervalles fixes indépendamment de l'état réel des machines, la maintenance prédictive permet de mobiliser les équipes de maintenance uniquement lorsque cela est réellement nécessaire. Cette approche se traduit par une meilleure gestion des stocks de pièces de rechange, une réduction des heures de main-d'œuvre non productives et une utili-

sation plus rationnelle des outils et équipements d'intervention. En concentrant les efforts sur les équipements réellement à risque, l'entreprise peut ainsi redéployer ses ressources humaines et matérielles vers des tâches à plus forte valeur ajoutée, améliorant la performance globale du service de maintenance.

1.2.3 Coûts de maintenance vs coûts de défaillance

Les choix de maintenance ont un impact direct sur les coûts d'exploitation des systèmes industriels. La comparaison entre les coûts de maintenance et les coûts de défaillance permet de montrer que la prévention des pannes est généralement plus économique que la réparation après défaillance.

1.2.3.1 Coûts de maintenance

La maintenance présente un champ d'action privilégié de la recherche d'amélioration des coûts de production. On distingue deux types de coûts :

- **Les coûts directs de maintenance**

Ce sont les dépenses directement engagées dans la réalisation des activités de maintenance : coûts de main-d'œuvre, de matériaux et d'équipement. Le coût direct de maintenance est calculé comme suit :

$$CD = \text{Main-d'œuvre} + \text{Pièces de rechange} + \text{Sous-traitance} + \text{Consommables} \quad (1.1)$$

- **Les coûts indirects de maintenance**

Ces coûts ne sont pas directement associés à l'exécution des tâches de maintenance mais restent essentiels : dépenses administratives, frais généraux et coûts des installations. Le coût indirect de maintenance est estimé par :

$$CI = \text{Coût d'arrêt} + \text{Coût de perte de qualité} + \text{Coûts administratifs} + \text{Coûts énergétiques} \quad (1.2)$$

1.2.3.2 Coûts de défaillance

Les coûts de défaillance correspondent à l'ensemble des coûts engendrés par la perte totale ou partielle de la fonction d'un équipement à la suite d'une panne ou d'une dégradation de ses performances.

La figure 1.2 illustre les différentes composantes des coûts engendrés par une défaillance d'équipement.




Figure 1.2: Coûts de défaillance

Ces coûts incluent non seulement les dépenses liées à la réparation ou au remplacement de l'équipement, mais également les pertes économiques indirectes causées par l'arrêt non planifié de la production, la baisse de qualité, les retards de livraison et les risques pour la sécurité. Le coût total de défaillance est ainsi exprimé par la relation :

$$\text{Coût de défaillance} = \text{Coûts directs} + \text{Coûts indirects} \quad (1.3)$$

La maîtrise de ces deux catégories de coûts passe nécessairement par le suivi d'indicateurs de performance fiables, permettant d'évaluer objectivement l'efficacité de la stratégie de maintenance mise en place.

1.2.4 Indicateurs de performance (MTBF, MTTR, Disponibilité)

Les indicateurs de performance de maintenance permettent de quantifier l'efficacité des actions engagées et de piloter les décisions d'exploitation. Trois indicateurs fondamentaux sont couramment utilisés dans l'industrie.

1.2.4.1 MTTR

Le MTTR (*Mean Time To Repair*) est le temps moyen nécessaire pour réparer un équipement défaillant et le remettre en état de fonctionnement. Il inclut le diagnostic, l'obtention des pièces et les tests post-réparation. Le MTTR est calculé par la formule suivante :

$$MTTR = \frac{\text{Somme des temps de réparation}}{\text{Nombre de réparations}} \quad (1.4)$$

1.2.4.2 MTBF

Le MTBF (*Mean Time Between Failure*) mesure le temps moyen entre les défaillances d'un système réparable, excluant les maintenances planifiées comme l'étalonnage, les entretiens ou

le remplacement de pièces. Le MTBF est déterminé à partir de la relation :

$$MTBF = \frac{\text{Temps total de fonctionnement}}{\text{Nombre de défaillances}} \quad (1.5)$$

1.2.4.3 Disponibilité

La disponibilité représente le temps durant lequel un équipement reste opérationnel. Elle reflète la performance des équipements et impacte directement la productivité globale via le TRS (Taux de Rendement Synthétique). La disponibilité d'un équipement est donnée par :

$$D = \frac{MTBF}{MTBF + MTTR} \times 100\% \quad (1.6)$$

Ces trois indicateurs forment un système cohérent d'évaluation : un MTBF élevé, un MTTR faible et une disponibilité proche de 100% traduisent une maintenance efficace et une exploitation optimisée des équipements.

1.3 Introduction à l'analyse vibratoire

L'analyse vibratoire est une discipline essentielle de l'ingénierie mécanique qui consiste à étudier les vibrations des systèmes mécaniques afin de comprendre leur comportement dynamique. Toute machine en fonctionnement génère des vibrations dues aux forces internes (déséquilibre, frottement, chocs) ou externes. L'analyse de ces vibrations permet d'identifier, de quantifier et de prévenir d'éventuels défauts ou défaillances.

1.3.1 Définition des vibrations mécaniques

Une vibration mécanique est un mouvement oscillatoire d'un système mécanique, animé en tout ou en partie par rapport à sa position d'équilibre. Au cours d'un tel mouvement, la vitesse (et l'accélération) change en permanence et des transferts d'énergie mécanique ont lieu. On distingue trois types de vibrations selon la nature du signal : sinusoïdales, périodiques et aléatoires.

1.3.1.1 Vibrations sinusoïdales

Obtenue dans le cas d'une masse fixée à un support via un ressort et écartée de sa position d'équilibre puis lâchée. Le spectre temporel de cette vibration représente l'amplitude en fonction du temps. Il permet de définir :

- La période (s) : T
- La fréquence (Hz) : $f = 1/T$
- La valeur efficace : caractérise l'énergie vibratoire

L'amplitude peut se caractériser par :

- Le déplacement (en sous-unités du mètre)
- La vitesse (m/s)

L'accélération s'exprime en m/s^2 ($g = 9,81 m/s^2$). Elle est préférée à la vitesse dans les très hautes fréquences. Le spectre fréquentiel représente l'amplitude en fonction de la fréquence ; en cas de vibration sinusoïdale, il est représenté par une barre unique.

La figure 1.3 représente le signal temporel et le spectre fréquentiel d'une vibration sinusoïdale simple.




Figure 1.3: Vibrations sinusoïdales

1.3.1.2 Vibrations périodiques

Ce sont des mouvements qui se reproduisent identiques à eux-mêmes à des intervalles de temps égaux (machines, marteaux piqueurs, etc.). Elles sont décomposables en une somme de fonctions sinusoïdales de fréquences et d'amplitudes propres.

La figure 1.4 illustre la décomposition d'un signal périodique en une somme de composantes sinusoïdales.




Figure 1.4: Vibrations périodiques

1.3.1.3 Vibrations aléatoires

On parle de vibrations aléatoires lorsque la position du point considéré ne peut être prédite à un instant déterminé. Elles sont rencontrées dans le domaine des transports (poste de conducteur d'une chargeuse par exemple) ; les vibrations sont liées aux irrégularités du terrain et aux chocs entre le godet et le tas.

La figure 1.5 montre le caractère imprévisible d'un signal vibratoire aléatoire dans le domaine temporel.




Figure 1.5: Vibrations aléatoires

1.3.2 Origine des vibrations dans les machines tournantes

Les vibrations peuvent être le résultat de plusieurs facteurs, isolés ou combinés. Les problèmes de vibrations ne sont pas provoqués uniquement par l'équipement principal mais peuvent aussi provenir d'un équipement auxiliaire.

1.3.2.1 Déséquilibre

Lorsque le centre de gravité d'un objet en rotation n'est pas exactement dans l'axe central, cela provoque un déséquilibre de la machine et donc des vibrations. Il existe trois types de déséquilibre : statique, couplé et dynamique.

— Déséquilibre statique

On parle de déséquilibre statique lorsque l'axe du centre de gravité (axe d'inertie) n'est pas aligné sur le centre de rotation (axe de l'arbre) et que le point lourd et le centre de gravité se trouvent dans le même plan. Il peut être corrigé en plaçant une masse dans un seul plan de correction.

— Déséquilibre couplé

Le déséquilibre couplé apparaît lorsqu'un objet en rotation possède deux ou plusieurs masses déséquilibrées dans des plans différents, qui s'égalisent en position de repos. Lorsque le système tourne, ces masses sont influencées par les forces centrifuges, ce qui entraîne des vibrations.

— Déséquilibre dynamique

Le déséquilibre dynamique est le type de balourd le plus courant ; il résulte d'un balourd statique et d'un balourd couplé. L'axe principal de la masse est déplacé et n'est pas parallèle à l'axe de l'arbre.

La figure 1.6 illustrent les différents types de balourd ainsi que le déséquilibre dynamique.




Figure 1.6: Différents types de balourd et déséquilibre dynamique

1.3.2.2 Problèmes d'alignement

Lorsque deux ou plusieurs machines tournantes sont connectées, l'alignement correct est crucial.

— Désalignement parallèle

Les lignes médianes de l'arbre sont parallèles mais ne sont pas alignées. Il peut s'agir d'un désalignement horizontal ou vertical (également connu sous le nom de désalignement décalé).

— Désalignement angulaire

Les arbres se rencontrent en un point, mais ne sont pas parallèles. Il peut s'agir d'un

axe horizontal ou vertical (également connu sous le nom de désalignement de l'espace).

— **Désalignement parallèle-angulaire combiné**

Combinaison d'un désalignement parallèle et d'un désalignement angulaire. C'est le type de désalignement le plus courant.




Figure 1.7: Types des erreurs d'alignement

1.3.2.3 Pièces desserrées

Les roulements desserrés, les boulons desserrés et la corrosion peuvent provoquer des vibrations excessives de la machine. En raison des forces mécaniques qui s'exercent sur la machine, les pièces desserrées peuvent rapidement causer des dommages.

1.3.3 Caractéristiques d'un signal vibratoire

Après avoir identifié les principales sources de vibrations, il convient de s'intéresser à la manière dont ces vibrations se traduisent physiquement. Comprendre un signal vibratoire, c'est savoir le lire — et pour ça, trois paramètres sont essentiels.

Un signal vibratoire est la représentation temporelle d'un phénomène oscillatoire résultant du mouvement d'un système mécanique soumis à des forces internes ou externes. La caractérisation d'un signal vibratoire repose sur l'identification de trois paramètres physiques essentiels : l'amplitude, la fréquence et la phase.

1.3.3.1 Amplitude

L'amplitude est la valeur absolue maximale de la vibration (valeur crête). La complexité d'un signal vibratoire réel conduit à définir plusieurs grandeurs pour caractériser son amplitude.

La figure 1.8 illustre les différents niveaux d'amplitude utilisés pour caractériser un signal vibratoire réel.




Figure 1.8: Les niveaux d'amplitude dans l'analyse vibratoire

- **L'amplitude crête (A_c)** : amplitude maximale du signal par rapport à sa valeur d'équilibre.
- **L'amplitude crête à crête (A_{c-c} , ou *peak-to-peak*)** : écart entre les amplitudes extrêmes du signal pour un temps d'observation donné.
- **L'amplitude efficace (A_{eff} , ou RMS)** : amplitude corrigée « statique » du signal redressé, indiquant l'énergie donnée par le mouvement vibratoire.

1.3.3.2 Fréquence

L'amplitude seule ne suffit pas. Il faut aussi savoir à quelle cadence le phénomène se répète

- c'est précisément ce que mesure la fréquence.

La fréquence d'un signal vibratoire est le nombre d'oscillations effectuées par le système en une seconde, définie comme l'inverse de la période T : $f = 1/T$, exprimée en hertz (Hz).

L'expression mathématique du signal sinusoïdal est :

$$x(t) = A \sin(2\pi ft + \varphi) \quad (1.7)$$

La fréquence peut aussi être exprimée en cycles par minute (CPM) ou en tours par minute (RPM). La correspondance entre les différentes unités de fréquence est donnée par :

$$1 \text{ Hz} = 60 \text{ CPM} = 60 \text{ RPM} \quad (1.8)$$

La figure 1.9 montre un exemple de spectre fréquentiel réel mesuré sur un ventilateur tournant à 2925 tr/min.




Figure 1.9: Spectre vibratoire d'un roulement sous différentes vitesses de rotation

1.3.3.3 Phase

Connaître l'amplitude et la fréquence d'un signal, c'est bien. Mais sans la phase, on ne peut pas savoir comment deux signaux se comportent l'un par rapport à l'autre — information souvent décisive en diagnostic.

La phase d'un signal vibratoire est l'angle qui indique le décalage temporel d'un mouvement oscillatoire par rapport à une référence temporelle fixe. Elle est essentielle pour décrire la relation temporelle entre plusieurs vibrations.

- **Unité de mesure** : degré ($^{\circ}$) ou radian (rad), où un cycle complet correspond à 360° ou 2π rad.
- **Mesure pratique** : la phase se mesure via des accéléromètres ou capteurs avec un déclencheur (clé de phase liée à la rotation de l'arbre). Elle s'exprime souvent en différence de phase entre axes (horizontale/verticale) pour analyser les orbites elliptiques des rotors.

La figure ci-après compare deux cas typiques : des signaux en phase et des signaux en opposition de phase.




Figure 1.10: Représentation de la phase d'un signal vibratoire

1.3.4 Unités de mesure

Les trois paramètres vus précédemment décrivent la forme du signal. Reste à savoir dans quelle unité physique on le mesure — et là, le choix dépend directement de la fréquence et du type de machine.

La mesure des vibrations peut s'effectuer selon trois grandeurs physiques complémentaires, chacune adaptée à une plage de fréquences et à un type d'application spécifique.

1.3.4.1 Le déplacement

Mesure de la distance totale parcourue par un objet vibrant depuis sa position de repos. C'est un paramètre fondamental, notamment pour les applications basse fréquence et l'évaluation des jeux mécaniques.

- **Unités communes** : mils (1 mil = 0,001") ou micromètres (1 mil $\approx$ 25,4 μ m).
- **Mesure** : presque toujours exprimée en crête à crête (Pk-Pk), car cette valeur représente la course totale du composant.

Le déplacement peut être mesuré de plusieurs manières :

- **Sondes de proximité** : sonde à courants de Foucault sans contact montée sur une pièce fixe, mesurant l'écartement entre son extrémité et l'arbre en rotation.
- **Intégration à partir d'accéléromètres** : le signal d'un accéléromètre est intégré électroniquement une fois pour obtenir la vitesse, puis une seconde fois pour obtenir le déplacement.
- **Capteurs laser de déplacement** : capteurs sans contact utilisant un faisceau laser pour des mesures très précises.

1.3.4.2 La vitesse

Quand les fréquences augmentent, le déplacement devient trop faible pour être mesuré directement. On passe alors à la vitesse vibratoire, plus sensible dans la plage intermédiaire.

La vitesse de vibration est la dérivée du déplacement vibratoire par rapport au temps. Unité principale : m/s ; unités industrielles courantes : mm/s, μ m/s.

Pour un déplacement $x(t) = A \sin(2\pi ft + \varphi)$, la vitesse vibratoire correspondante est obtenue par dérivation :

$$v(t) = 2\pi f A \cos(2\pi ft + \varphi) \quad (1.9)$$

1.3.4.3 L'accélération

Au-delà de quelques centaines de hertz, c'est l'accélération qui prime. Elle capte les chocs et les impacts là où les deux grandeurs précédentes ne voient plus rien.

L'accélération vibratoire est la mesure de la variation temporelle de la vitesse d'oscillation. Elle quantifie l'intensité des forces dynamiques aux hautes fréquences pour détecter chocs ou impacts sur machines tournantes.

- Unité SI : m/s^2
- Unité industrielle : mm/s^2 , ou multiples de $g = 9,81 \text{ m/s}^2$

1.3.5 Capteurs de mesure vibratoire

Chaque grandeur physique appelle un capteur adapté. Le choix du capteur n'est pas anodin — il conditionne directement la qualité du diagnostic.

La mesure des vibrations nécessite des capteurs adaptés à la grandeur physique mesurée et à la plage de fréquences d'intérêt. Trois types de capteurs sont couramment utilisés dans le milieu industriel.

1.3.5.1 Accéléromètre piézoélectrique

C'est le capteur le plus utilisé en analyse vibratoire industrielle. Son principe repose sur l'effet piézoélectrique : une masse sismique comprime un cristal piézoélectrique qui génère une charge électrique proportionnelle à l'accélération. Il couvre une large plage de fréquences (0,5 Hz à plusieurs dizaines de kHz) et supporte des températures élevées.

1.3.5.2 Capteur de vitesse (vélocimètre)

Basé sur l'induction électromagnétique, il génère une tension proportionnelle à la vitesse vibratoire. Adapté aux fréquences moyennes (10 Hz – 1 kHz), il est couramment utilisé pour la surveillance des machines tournantes selon la norme ISO 10816.

1.3.5.3 Sonde de proximité (capteur à courants de Foucault)

Capteur sans contact mesurant le déplacement relatif entre l'arbre et le palier. Indispensable pour surveiller les arbres de turbines, compresseurs et pompes (plage : 0 – 1 kHz). Son signal est exprimé en micromètres (μm) crête à crête.

Le tableau 1.1 résume et compare les caractéristiques principales des trois capteurs présentés.

Tableau 1.1: Comparaison des capteurs vibratoires

Capteur	Grandeur	Plage fréq.	Contact	Norme
Accéléromètre	Accélération	0,5 Hz – 20 kHz	Oui	ISO 10816
Vélocimètre	Vitesse	10 Hz – 1 kHz	Oui	ISO 10816
Sonde proximité	Déplacement	0 – 1 kHz	Non	API 670

1.4 Machines tournantes et leurs défauts

Les bases théoriques étant posées, on peut maintenant s'attaquer au cœur du sujet : les machines elles-mêmes. Avant de parler de défauts, il faut d'abord comprendre de quoi elles sont faites.

1.4.1 Composants des machines tournantes

Les machines tournantes sont constituées de plusieurs composants mécaniques dont l'interaction assure la transmission et la conversion de l'énergie. La connaissance de ces composants est indispensable pour comprendre l'origine et la nature des défauts susceptibles d'apparaître en service.

1.4.1.1 Les rotors

Le rotor est un corps en rotation équipé de tourillons supporté par des paliers. Les composants de rotor sont :

- **Un arbre** : sur lequel sont montées les parties actives (bobinages, roues, engrenages, etc.). Il est maintenu dans le stator par des liaisons tournantes (une butée axiale et des paliers radiaux).
- **Les tourillons** : parties de l'arbre en regard des paliers.

1.4.1.2 Les roulements

Le roulement est un organe mécanique dont la fonction est de permettre la transmission des charges entre deux pièces en rotation relative l'une par rapport à l'autre avec un frottement très réduit. Il supporte et assure le guidage d'une charge tournante.

- **Caractéristiques des roulements** :
 - Couple de frottement au démarrage faible.
 - Fabrication selon des normes internationales, interchangeables.
 - Graissage simple et consommation de graisse très faible.
 - Acceptent à la fois des charges radiales et axiales.
 - Utilisation possible à basse comme à haute température.
 - Rigidité augmentable par précharge.

La figure 1.11 présente les différents éléments constitutifs d'un roulement à billes standard.




Figure 1.11: Composants d'un roulement

1.4.1.3 Les engrenages

Les systèmes d'engrenage sont largement utilisés dans une variété d'applications industrielles. Presque 80% des pannes dans les systèmes de transmission sont causées par la défaillance d'engrenage.

La figure 1.12 illustre les composants principaux d'un système d'engrenage.




Figure 1.12: Composants d'un engrenage

Types d'engrenage

La figure 1.13 présente les principaux types d'engrenages utilisés dans les transmissions mécaniques industrielles.




Figure 1.13: Types d'engrenage

- **Engrenages à axes parallèles** : dentures droites, hélicoïdales, etc.
- **Engrenages à axes non parallèles** : dentures coniques, spirales, etc.

Leurs opérations

Les engrenages permettent la réduction (ou variation) de vitesse entre deux arbres. Le rapport de vitesse entre les deux roues dentées est donné par :

$$R_v = \frac{N_1}{N_2} \quad (1.10)$$

où N_1 et N_2 sont les nombres de dents des roues menée et menante respectivement.

1.4.1.4 Accouplements

Les accouplements sont des composants mécaniques utilisés pour connecter deux arbres afin de permettre à un arbre d'en entraîner un autre à la même vitesse [1]. On distingue deux types principaux.

Accouplement rigide

Permet peu ou pas de mouvement relatif entre les arbres. Il est préféré lorsqu'un alignement précis est nécessaire [1].

La figure 1.14 illustre le principe de l'accouplement rigide entre deux arbres alignés.



Figure 1.14: Accouplement rigide [1]

Accouplement flexible

Permet un certain degré de mouvement relatif entre les arbres. Il peut réduire l'usure des machines [1].

La figure 1.15 montre un accouplement flexible, permettant de compenser de légères imperfections d'alignement.



Figure 1.15: Accouplement flexible [1]

1.4.1.5 Palier

Un palier est un organe mécanique destiné à supporter, guider et positionner un arbre en rotation, tout en réduisant les frottements entre les pièces en mouvement relatif. Il assure la transmission des efforts radiaux et/ou axiaux de l'arbre vers le bâti de la machine.

1.4.2 Types des défauts courants

Maintenant qu'on connaît les composants, voyons comment ils tombent en panne. Les défauts dans les machines tournantes sont variés, mais la plupart se ramènent à quelques familles bien identifiées.

1.4.2.1 Défaut de balourd (déséquilibre)

Le balourd est engendré par une mauvaise répartition spatiale des masses tournantes, entraînant un écart entre l'axe d'inertie et l'axe de rotation, ce qui provoque une force centrifuge sur le rotor et donc une vibration radiale importante à la fréquence de rotation.

Les facteurs favorisant l'apparition du balourd sont :

- **La non-homogénéité des matériaux** : les rotors de fonte de pompe peuvent présenter des cavités (soufflures ou trous de sable) formées lors du moulage.

- **Les tolérances de fabrication et d'assemblage** : le jeu ou le desserrage peuvent conduire à un balourd sur la partie tournante.
- **Les modifications physiques d'un rotor en opération** : déformation thermique, corrosion, usure ou encrassement peuvent modifier l'équilibre original.

Les différents types de défaut de balourd sont présentés ci-après.

Balourd statique

Le balourd statique est la condition de déséquilibre où l'axe d'inertie est parallèle à l'axe de rotation. La correction se fait par l'enlèvement ou l'addition d'un poids dans un seul plan [2].

La figure 1.16 illustre la configuration du balourd statique et son plan de correction.




Figure 1.16: Balourd statique

Balourd de couple

Ce défaut apparaît lorsque l'axe d'inertie est incliné par rapport à l'axe de rotation et le centre de gravité se trouve sur l'axe de rotation. Lorsque le rotor tourne, il vibre avec un mouvement de torsion [2].

Balourd dynamique

Le balourd dynamique se manifeste lorsque l'axe d'inertie n'est pas parallèle à l'axe de rotation et le centre de gravité n'appartient pas à l'axe de rotation. Il exige deux plans ou plus de corrections [2].

La figure 1.17 illustre le balourd dynamique, qui nécessite une correction dans au moins deux plans.




Figure 1.17: Balourd dynamique [2]

1.4.2.2 Défaut d'alignement

Le défaut d'alignement est l'une des principales causes de réduction de la durée de vie des équipements. Les axes des deux rotors peuvent présenter un désalignement angulaire, radial ou la combinaison des deux [8].

Désalignement d'arbres accouplés

Les axes des deux rotors peuvent présenter un désalignement angulaire ou radial (défaut de concentricité), ou la combinaison des deux.

Défaut de désalignement angulaire

Observé lorsque les axes des arbres sont dans le même plan mais non parallèles [8].

1.4.2.3 Défaut de roulement

Les roulements sont les composants les plus fragiles. Le passage répétitif des billes sur les pistes engendre de fortes contraintes mécaniques qui entraînent une dégradation du métal par fatigue, et finissent par provoquer des défauts ponctuels (fissures, écaillage, etc.) [3].

La figure 1.18 présente les composants d'un roulement à billes et les zones sujettes aux défauts.




Figure 1.18: Composants d'un roulement [3]

Fréquences caractéristiques des défauts de roulement

L'identification des défauts de roulement repose sur quatre fréquences caractéristiques calculées à partir de la géométrie du roulement et de la vitesse de rotation [3], comme le présente le tableau 1.2.

Tableau 1.2: Fréquences caractéristiques des défauts de roulement

Défaut	Sigle	Formule	Description
Bague externe	BPFO	$\frac{N_b}{2} f_r \left(1 - \frac{d}{D} \cos \alpha \right)$	Ball Pass Freq. Outer
Bague interne	BPFI	$\frac{N_b}{2} f_r \left(1 + \frac{d}{D} \cos \alpha \right)$	Ball Pass Freq. Inner
Élément roulant	BSF	$\frac{D}{2d} f_r \left[1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right]$	Ball Spin Frequency
Cage	FTF	$\frac{f_r}{2} \left(1 - \frac{d}{D} \cos \alpha \right)$	Fund. Train Freq.

où N_b est le nombre de billes, f_r la fréquence de rotation (Hz), d le diamètre d'un élément roulant, D le diamètre primitif et α l'angle de contact.

Défaut sur la bague interne

Caractérisé par la présence d'une raie à la fréquence caractéristique BPFI. La figure 1.19 montre un exemple d'écaillage sur la bague intérieure.




Figure 1.19: Écaillage sur la bague intérieure [3]

Défaut sur la bague externe

Ce défaut est caractérisé par la présence d'une raie à la fréquence BPFO. Bien que la charge appliquée sur la bague externe soit constante, on peut remarquer une modulation d'amplitude

à la fréquence de rotation de l'arbre autour de la fréquence de défaut. La figure 1.20 illustre un écaillage typique sur la bague extérieure.




Figure 1.20: Écaillage sur la bague extérieure [3]

Défaut de l'élément roulant

La première fréquence caractéristique (BSF) correspond à la fréquence de rotation de l'élément roulant sur lui-même. Cet élément rencontre une fois la bague interne et une fois la bague externe par tour, générant des chocs à 2 fois cette fréquence.

1.4.2.4 Défauts d'engrenages

L'engrenage est composé d'un ensemble de deux roues dentées engrenant l'une avec l'autre. Les engrenages sont parmi les organes les plus sensibles de la chaîne cinématique [4].

Fréquence d'engrènement

La fréquence d'engrènement (GMF, *Gear Mesh Frequency*) est la fréquence à laquelle les dents entrent en contact :

$$f_e = Z_1 \times f_{r1} = Z_2 \times f_{r2} \quad (1.11)$$

où Z_1 , Z_2 sont les nombres de dents des deux roues et f_{r1} , f_{r2} leurs fréquences de rotation (Hz). Un défaut d'engrenage se manifeste par des raies latérales autour des harmoniques de f_e .

L'usure

L'usure est un phénomène local caractérisé par un enlèvement de matière dû au glissement de deux surfaces. L'usure anormale se produit lorsque le lubrifiant est souillé de particules abrasives ou est corrosif [4]. La figure 1.21 illustre un exemple de défaut d'usure sur une dent d'engrenage.



Figure 1.21: Défaut d'usure [4]

Les piqûres (pitting)

Il s'agit de trous plus ou moins profonds qui affectent toutes les dents. La piqûre est une avarie qui se produit surtout sur des engrenages en acier relativement peu dur [4]. La figure 1.22 montre un exemple de défaut de piqûre sur des dents d'engrenage.




Figure 1.22: Défaut de piqûre [4]

L'écaillage

Il s'agit de trous moins nombreux, plus profonds et plus étendus que ceux des piqûres. L'écaillage se trouve dans les engrenages cémentés, les plus répandus car ils permettent de passer des couples importants avec des dimensions faibles. La figure 1.23 présente un exemple d'écaillage sur une dent d'engrenage.




Figure 1.23: Défaut d'écaillage [4]

1.4.2.5 Défauts d'arbre de rotor

Fissures dans les arbres des rotors

L'initiation et la propagation d'une fissure dans les arbres résulte d'imperfections d'usinage (rainures de clavettes, changements de section, entailles) ou de facteurs métallurgiques (défauts de forgeage, inclusions, porosités) [5].

Les types de fissures selon leur orientation sont :

- **Fissure transversale** : perpendiculaire à l'axe de l'arbre, c'est le type le plus important. Elle réduit la section transversale et entraîne des dommages importants. La figure 1.24 représente ce type de fissure.




Figure 1.24: Fissure transversale [5]

- **Fissure longitudinale** : parallèle à l'axe de l'arbre, relativement rare et moins grave. La figure 1.25 illustre ce type de fissure.




Figure 1.25: Fissure longitudinale [5]

- **Fissure inclinée (*slant crack*)** : fait un angle avec l'axe de l'arbre. Elle influence principalement le comportement en torsion du rotor [5]. La figure 1.26 montre la configuration d'une fissure inclinée.




Figure 1.26: Fissure inclinée [5]

Jeu mécanique

En mécanique, le jeu est l'espace laissé entre deux pièces assemblées imparfaitement. La notion de tolérancement définit les classes de qualité d'assemblage et fixe les règles de l'emploi du jeu mécanique [9].

Le jeu est calculé par :

$$J = D_{\text{alésage}} - d_{\text{arbre}} \quad (1.12)$$

Les valeurs extrêmes du jeu sont :

$$J_{\min} = D_{\min} - d_{\max} \quad J_{\max} = D_{\max} - d_{\min} \quad (1.13)$$

Mauvais serrage mécanique

Le mauvais serrage de la structure de la machine génère des vibrations et du bruit. Le spectre typique d'une machine avec jeu contient un grand nombre de pics à des fréquences multiples de la fréquence de rotation. Il est parfois possible de retrouver des pics à l'harmonique $\frac{1}{2}$ et ses multiples. Les causes principales sont l'usure ou un mauvais montage.

1.4.3 Niveaux vibratoires normatifs (ISO 10816)

Diagnostiquer, c'est bien. Mais encore faut-il savoir à partir de quel seuil une vibration devient vraiment problématique. C'est exactement ce que fixe la norme ISO 10816.

La norme ISO 10816 définit les seuils d'évaluation de la sévérité des vibrations pour les machines tournantes, exprimés en vitesse efficace (RMS) en mm/s. Le tableau 1.3 présente les quatre zones de sévérité vibratoire définies pour les machines de 15 kW à 300 kW.

Tableau 1.3: Zones de sévérité vibratoire selon ISO 10816-3 (machines 15 kW – 300 kW)

Zone	Vitesse RMS (mm/s)	Signification
A	$v \leq 2,3$	Neuf — état excellent
B	$2,3 < v \leq 4,5$	Acceptable pour exploitation continue
C	$4,5 < v \leq 7,1$	Tolérable à court terme, surveiller
D	$v > 7,1$	Danger — arrêt immédiat recommandé

Ces seuils constituent une référence normative essentielle pour évaluer l'état de santé des machines tournantes et décider du moment opportun pour une intervention de maintenance.

1.5 Conclusion

Ce chapitre a présenté les fondements de la maintenance industrielle et de l'analyse vibratoire. Nous avons d'abord exposé les quatre stratégies de maintenance — corrective, préventive systématique, préventive conditionnelle et prédictive — ainsi que leurs indicateurs clés (MTBF, MTTR, disponibilité).

Nous avons ensuite introduit les concepts de base de l'analyse vibratoire : nature des vibrations mécaniques, origines des défauts dans les machines tournantes (balourd, désalignement, défauts de roulement et d'engrenage), unités de mesure, capteurs associés, techniques d'analyse (temporelle, FFT) et niveaux normatifs ISO 10816.

L'ensemble de ces notions constitue le socle théorique nécessaire à la compréhension des approches de diagnostic automatique basées sur l'apprentissage automatique, qui seront développées dans le chapitre suivant.

Chapitre 2

Diagnostic Vibratoire des Machines Tournantes par IA

2.1	Introduction	29
2.2	Base de données MaFaulDa	29
2.2.1	Description du banc d'essai	29
2.2.2	Protocole d'acquisition	31
2.2.3	Classes de défauts	31
2.3	Pipeline de traitement	34
2.4	Prétraitement des signaux	35
2.4.1	Filtrage	35
2.4.2	Normalisation	36
2.5	Extraction de caractéristiques	36
2.5.1	Analyse dans le domaine temporel	37
2.5.2	Analyse dans le domaine fréquentiel	38
2.5.3	Analyse de corrélation et sélection des caractéristiques	41
2.6	Classifieurs	43
2.6.1	K-Plus Proches Voisins (KNN)	43
2.6.2	Machine à Vecteurs de Support (SVM)	44
2.6.3	Perceptron multicouche (MLP)	45
2.7	Protocole expérimental	47
2.7.1	Partitionnement train / test	47
2.7.2	Métriques d'évaluation	48
2.7.3	Environnement d'implémentation	48
2.8	Résultats	48
2.8.1	Résultats dans le domaine temporel	49
2.8.2	Résultats dans le domaine fréquentiel	51
2.8.3	Synthèse comparative	54
2.9	Discussion	54
2.10	Conclusion	55

2.1 Introduction

La combinaison de l'analyse vibratoire et de l'intelligence artificielle (IA) transforme profondément les approches traditionnelles de diagnostic des machines. Grâce aux techniques d'apprentissage automatique, il devient possible de traiter et d'analyser de grandes quantités de données vibratoires avec une efficacité accrue [10]. Ces algorithmes permettent de détecter des anomalies souvent imperceptibles par les méthodes classiques et d'anticiper les défaillances avec une précision supérieure [11].

Ainsi, l'intégration de l'analyse vibratoire et de l'IA ouvre la voie à une maintenance prédictive plus performante, à la fois fiable, réactive et de plus en plus autonome, répondant aux exigences des environnements industriels modernes [10, 11].

Ce chapitre est structuré de la manière suivante. Nous commençons par présenter la base de données MaFaulDa utilisée dans cette étude, ainsi que le pipeline de traitement adopté. Nous décrivons ensuite les étapes de prétraitement des signaux, d'extraction de caractéristiques dans les domaines temporel et fréquentiel, puis les trois classifieurs retenus. Enfin, nous exposons le protocole expérimental, les résultats obtenus et une discussion comparative des performances.

2.2 Base de données MaFaulDa

MaFaulDa est une collection de 1951 séries temporelles multivariées pour 4 conditions opérationnelles différentes sur le banc d'essai rotatif *Alignment Balance Vibration Trainer* (ABVT) [12]. Chaque série a une durée de 5 secondes et est enregistrée à une fréquence d'échantillonnage de 50 kHz.

Cette base de données constitue un référentiel reconnu dans la communauté scientifique pour l'évaluation des méthodes de diagnostic vibratoire, en raison de la diversité des conditions de fonctionnement qu'elle couvre et de la reproductibilité des acquisitions [12]. Le tableau 2.1 résume les principales caractéristiques du dispositif d'acquisition.

Tableau 2.1: Caractéristiques techniques du banc MaFaulDa

Paramètre	Valeur / Description
Équipement	SpectraQuest MFS ABVT
Nombre total de signaux	1951 séries temporelles
Nombre de canaux	8 (tachymètre + 3 axes $\times$ 2 roulements + microphone)
Fréquence d'échantillonnage	50 kHz
Durée par enregistrement	5 secondes (250 000 points)
Plage de vitesse	700 – 3600 tr/min
Nombre de classes utilisées	6

2.2.1 Description du banc d'essai

Les données de cette base ont été acquises à l'aide du banc d'essai *Machinery Fault Simulator* (MFS) de la société américaine SpectraQuest [12]. Ce banc permet d'étudier

plusieurs défauts de machines tournantes, tels que le balourd et les défauts de roulements. Les données comprennent les signaux vibratoires de quatre états de fonctionnement : normal, désalignement, balourd et défauts de roulements, enregistrés à différentes vitesses de rotation.

La figure 2.1 illustre le banc d'essai utilisé pour l'acquisition des signaux vibratoires.




Figure 2.1: Banc d'essai d'analyse de défauts de machines (MFS)

Les accéléromètres utilisés pour l'acquisition des signaux ont une fréquence d'échantillonnage de 50 kHz sur une durée de 5 s , ce qui donne un total de $250\,000$ points par signal.

Le banc d'essai, comme illustré à la figure 2.1, se compose des éléments suivants :

- Un moteur à courant continu de $1/4\text{ CV}$ ($0,18\text{ kW}$) équipé d'un arbre prolongé.
- Un rotor monodisque.
- Deux roulements à billes identiques (nombre de billes : 8, diamètre des billes : $0,7145\text{ cm}$, diamètre de la cage : $2,8519\text{ cm}$).

L'arbre, d'une longueur totale de 520 mm avec une portée utile de 390 mm et d'un diamètre de 16 mm , est supporté par ces roulements. La vitesse de rotation est régulée par un variateur de fréquence permettant une plage de fonctionnement de 700 à 3600 tr/min .

Le banc d'essais MFS est fourni avec trois roulements défectueux, chacun présentant un défaut spécifique : bague extérieure, éléments roulants (billes) et bague intérieure [13].

Ces roulements peuvent être montés dans l'une des deux positions suivantes sur le banc :

- Entre le moteur et le rotor (configuration en porte-à-faux aval, *underhang*).
- À l'extérieur du rotor (configuration en porte-à-faux amont, *overhang*).

Trois masses — 6, 20 et 35 grammes — peuvent être montées séparément sur le rotor, permettant d'amplifier l'effet de certains défauts.

Dans cette étude, seuls les trois types de défauts de roulements de la configuration en porte-à-faux aval sont pris en compte. Les signaux de ces défauts sont étudiés à trois vitesses de fonctionnement : 15, 35 et 50 Hz. Pour chaque vitesse, trois cas sont envisagés : un rotor libre, un rotor avec une masse de 6 grammes et un rotor avec une masse de 20 grammes, conduisant à un total de 9 signaux par défaut.

2.2.2 Protocole d'acquisition

Le protocole d'acquisition des données adopté dans cette étude repose sur l'enregistrement de signaux vibratoires dans différentes conditions de fonctionnement [12]. Les mesures sont effectuées à l'aide de capteurs accélérométriques permettant de capter les vibrations selon plusieurs directions. Les signaux sont acquis simultanément avec une fréquence d'échantillonnage de 50 kHz , garantissant une bonne résolution temporelle et fréquentielle.

Chaque enregistrement a une durée de 5 secondes, ce qui correspond à 250 000 points par signal, permettant de représenter fidèlement le comportement dynamique de la machine. L'ensemble des signaux acquis est ensuite organisé sous forme de séries temporelles prêtes à être exploitées dans les étapes de traitement du signal et de classification.

2.2.3 Classes de défauts

La base de données MaFaulDa utilisée dans cette étude est composée de six classes différentes, représentant des états de fonctionnement distincts d'une machine tournante [12]. Ces classes couvrent le fonctionnement nominal ainsi que plusieurs défauts mécaniques couramment rencontrés en milieu industriel [14].

État normal : La première classe représente l'état de fonctionnement normal, caractérisé par l'absence de problèmes mécaniques. Dans cette situation, les signaux vibratoires sont stables dans le temps et la fréquence, et leurs amplitudes sont conformes aux normes du constructeur. Cette classe sert de référence pour la comparaison avec les états défectueux.

Défaut de déséquilibre (*imbalance*) : Le déséquilibre est causé par une répartition non uniforme de la masse autour de l'axe de rotation [14]. Ce défaut génère des vibrations périodiques dont la fréquence fondamentale correspond à la fréquence de rotation de l'arbre. L'amplitude des vibrations augmente proportionnellement au carré de la vitesse de rotation. Les défauts de déséquilibre ont été simulés avec des masses comprises entre 6 g et 35 g. Pour chaque masse inférieure à 30 g, les mêmes 49 vitesses de rotation utilisées dans le cas normal ont été appliquées.

Défaut d'alignement horizontal : Le désalignement horizontal se produit lorsque les axes des composants connectés ne sont pas alignés dans le plan horizontal [14]. Cela provoque des vibrations principalement dans les directions radiales, souvent associées aux harmoniques de rang 2 et 3 de la fréquence de rotation.

Défaut d'alignement vertical : Le désalignement vertical génère des vibrations présentant de nombreuses composantes harmoniques, similaires à celles du désalignement horizontal [14]. Sa distinction requiert l'analyse simultanée des signaux vibratoires selon plusieurs axes.

Défaut de roulement (bague interne) : Ce défaut se manifeste par des impacts réguliers sur la bague interne du roulement, dont la fréquence dépend de la géométrie

du roulement et de la vitesse de rotation [13]. Les vibrations produites sont modulées par le passage des éléments roulants.

Défaut de roulement (bague externe) : Le défaut de bague externe est similaire au précédent, mais la dégradation se situe sur la bague externe fixe [13]. La fréquence caractéristique associée (BPFO) est généralement différente de celle de la bague interne [13]. Ce défaut produit des impacts réguliers visibles tant dans le domaine temporel (impulsions) que fréquentiel (raies spectrales caractéristiques) [15]. La figure 2.2 présente les signaux vibratoires caractéristiques de chacune des six classes de la base de données MaFaulDa.




Figure 2.2: Signaux vibratoires caractéristiques des six classes de la base MaFaulDa

Le tableau 2.2 détaille la répartition des acquisitions [12].

Tableau 2.2: Résumé des défauts et des séquences de la base MAFAULDA

Type de défaut	Condition	Nombre de mesures
Normal	737 – 3686 rpm	49
Déséquilibre	6 g	49
	10 g	48
	15 g	48
	20 g	49
	25 g	47
	30 g	47
	35 g	45
Désalignement horizontal	0.50 mm	50
	1.00 mm	49
	1.50 mm	49
	2.00 mm	49
Désalignement vertical	0.51 mm	51
	0.63 mm	50
	1.27 mm	50
	1.40 mm	50
	1.78 mm	50
	1.90 mm	50
Bague extérieure	0 g	49
	6 g	48
	20 g	49
	35 g	42
Éléments roulants	0 g	49
	6 g	49
	20 g	49
	35 g	37
Bague intérieure	0 g	50
	6 g	49
	20 g	49
	35 g	38
Bague extérieure	0 g	49
	6 g	49
	20 g	49
	35 g	41
Éléments roulants	0 g	49
	6 g	49
	20 g	49
	35 g	41
Bague intérieure	0 g	49
	6 g	43
	20 g	25
	35 g	20

La répartition quantitative des acquisitions par classe est présentée dans la Figure 2.3.




Figure 2.3: Diagramme sectoriel des classes de défaut

2.3 Pipeline de traitement

Avant de détailler chaque étape individuellement, il est utile de présenter une vue d'ensemble du pipeline de traitement adopté dans cette étude. Ce pipeline regroupe l'ensemble des opérations appliquées aux signaux vibratoires bruts, depuis leur acquisition jusqu'à la décision de classification finale [10].

Il se décompose en quatre grandes étapes séquentielles : le prétraitement des signaux, l'extraction de caractéristiques dans les domaines temporel et fréquentiel, la sélection des caractéristiques par analyse de corrélation, et enfin la classification par les modèles d'apprentissage automatique. Chacune de ces étapes est décrite en détail dans les sections suivantes.

La figure 2.4 présente l'organigramme global du pipeline de traitement adopté.




Figure 2.4: Organigramme du pipeline de traitement des signaux vibratoires

2.4 Prétraitement des signaux

Le prétraitement des signaux est une étape fondamentale avant toute analyse vibratoire [16]. Elle consiste à améliorer la qualité des signaux bruts afin de les rendre plus exploitables par les algorithmes de classification. C'est particulièrement important dans les environnements industriels où les mesures peuvent être perturbées par des bruits de fond ou des interférences externes.

Dans cette étude, deux opérations de prétraitement ont été appliquées aux signaux de la base MaFaultDa : le filtrage et la normalisation.

2.4.1 Filtrage

Le filtrage est une opération de traitement du signal visant à modifier le contenu spectral en atténuant certaines bandes de fréquences tout en préservant les composantes utiles [16]. Dans le contexte de l'analyse vibratoire appliquée aux machines tournantes, le filtrage remplit deux fonctions principales.

Suppression de la composante continue. Les signaux vibratoires bruts contiennent souvent une composante continue (valeur moyenne non nulle) qui n'est pas porteuse d'information sur les défauts. Cette composante doit être éliminée pour ne pas fausser les analyses ultérieures.

La figure 2.5 illustre l'effet de la suppression de la composante continue sur les signaux des six classes de la base MaFaultDa.

Atténuation des fréquences parasites. Certaines fréquences situées en dehors de la bande d'intérêt comme bruit haute fréquence, interférences du réseau électrique, vibrations provenant d'autres sources qui doivent être supprimées afin de ne conserver que l'information pertinente au diagnostic [16].

Dans cette étude, un filtre passe-bas de Butterworth d'ordre 5 est appliqué, avec une fréquence de coupure à -3 dB fixée à 10 kHz . La fonction de transfert d'un filtre de Butterworth d'ordre n est donnée par l'équation 2.1 [16] :

$$|H(j\omega)|^2 = \frac{1}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}} \quad (2.1)$$

où ω_c est la fréquence de coupure et n l'ordre du filtre. Le choix d'un filtre de Butterworth est motivé par sa réponse fréquentielle maximale plate dans la bande passante, ce qui préserve l'intégrité du signal dans la plage de fréquences utile [16]. La fréquence de coupure de 10 kHz correspond à la limite supérieure de la réponse linéaire des accéléromètres piézoélectriques utilisés pour l'acquisition.

La figure 2.5 illustre l'effet de la suppression de la composante continue et le vitrage de Butterworth sur les signaux des deux classes de la base MaFaultDa.




Figure 2.5: Effet de la suppression de la composante continue (detrend et du filtrage de Butterworth) sur la base MaFaulDa

2.4.2 Normalisation

La normalisation est une opération mathématique qui ramène les signaux ou les ensembles de caractéristiques à une échelle commune [17]. C'est une étape indispensable lorsque l'on combine des indicateurs de types différents, tels que l'amplitude, la fréquence et les facteurs de forme, dont les ordres de grandeur peuvent varier significativement [18]. Dans le cas de l'analyse vibratoire tridimensionnelle, les capteurs de la base MaFaulDa mesurent les vibrations sur trois axes principaux : axial, radial et tangentiel. Pour rendre le modèle robuste aux légères variations d'orientation du capteur, les caractéristiques sont extraites pour chacun des trois axes séparément, puis combinées pour former un vecteur de caractéristiques multidimensionnel. Cette approche préserve l'information directionnelle et enrichit la représentation des états de fonctionnement.

2.5 Extraction de caractéristiques

L'extraction de caractéristiques consiste à transformer les signaux vibratoires bruts en un ensemble de valeurs numériques représentatives, appelées vecteur de caractéristiques [10]. Cette étape est déterminante pour la qualité de la classification, car la pertinence des caractéristiques conditionne directement la capacité des modèles à discriminer les différents états de fonctionnement.

Dans cette étude, les caractéristiques sont extraites selon deux approches complémentaires : l'analyse dans le domaine temporel et l'analyse dans le domaine fréquentiel.

2.5.1 Analyse dans le domaine temporel

L'analyse temporelle des signaux vibratoires consiste à extraire des indicateurs statistiques directement à partir de l'évolution temporelle de l'amplitude. Ces indicateurs permettent de caractériser le comportement dynamique de la machine et de détecter la présence d'anomalies sans nécessiter de transformation du signal.

On distingue plusieurs familles d'indicateurs selon le type d'information qu'ils capturent.

2.5.1.1 Indicateurs d'ordre 1 et 2 en position, dispersion et énergie

Ces indicateurs décrivent la position centrale du signal ainsi que sa variabilité et son contenu énergétique [15]. Leurs formules sont regroupées dans le tableau 2.3.

- Moyenne
- Valeur moyenne absolue
- Écart-type
- Valeur efficace (RMS)
- Valeur crête
- Peak-to-Peak
- Taux de passage par zéro (*Zerocross*)
- Amplitude moyenne des variations (AAC)

2.5.1.2 Indicateurs de forme

Ces indicateurs caractérisent la forme générale du signal et son caractère impulsionnel [15]. Leurs formules sont détaillées dans le tableau 2.3.

- Facteur de forme
- Facteur de crête
- Facteur d'impulsion
- Facteur de clairance

2.5.1.3 Indicateurs d'ordre supérieur en forme de distribution

Ces indicateurs décrivent la forme statistique de la distribution du signal [13]. Le tableau 2.3 en présente les formules complètes.

- Skewness (asymétrie)
- Kurtosis (aplatissement)

2.5.1.4 Vecteur de caractéristiques temporel

L'ensemble des indicateurs temporels présentés ci-dessus est regroupé dans un vecteur de caractéristiques structuré $\mathbf{f}_t$, défini par l'équation 2.2 :

$$\mathbf{f}_t = [\bar{x}, \sigma, X_{\text{rms}}, X_{\text{peak}}, X_{\text{cf}}, X_{\text{sv}}, X_{\text{ku}}]^T \quad (2.2)$$

La composition de $\mathbf{f}_t$ est conçue pour capturer à la fois l'énergie globale, la dispersion et le caractère transitoire du signal. Ce vecteur sert d'entrée aux classifieurs supervisés pour la reconnaissance automatique des défauts. L'avantage principal de cette approche est la réduction de la dimensionnalité : un signal de plusieurs centaines de milliers d'échan-

tillons est résumé en quelques valeurs numériques interprétables [1].

Le tableau 2.3 récapitule l'ensemble des indicateurs temporels calculés, leur symbole, leur formule et leur famille.

Tableau 2.3: Récapitulatif des indicateurs temporels

Famille	Indicateur	Formule	Symbole
Position/ Énergie	Moyenne	$\frac{1}{N} \sum_{i=1}^N x_i$	$\bar{x}$
	Val. moy. absolue	$\frac{1}{N} \sum_{i=1}^N x_i $	X_{mean}
	Écart-type	$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$	σ
	RMS	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	X_{rms}
	Crête	$\max(x_i)$	X_{peak}
	Peak-to-Peak	$\max(x_i) - \min(x_i)$	X_{pp}
	Zerocross	$\frac{1}{N} \sum_{i=1}^{N-1} \mathbb{I}(x_i \cdot x_{i+1} < 0)$	ZC
	AAC	$\frac{1}{N-1} \sum_{i=1}^{N-1} x_{i+1} - x_i $	AAC
Forme	Facteur de forme	$\frac{X_{\text{rms}}}{\frac{1}{N} \sum_{i=1}^N x_i }$	SF
	Facteur de crête	$\frac{X_{\text{peak}}}{X_{\text{rms}}}$	CF
	Facteur d'impulsion	$\frac{X_{\text{peak}}}{\frac{1}{N} \sum_{i=1}^N x_i }$	IF
	Facteur de clairance	$\frac{X_{\text{peak}}}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i }\right)^2}$	CLF
Distribution	Skewness	$\frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma}\right)^3$	X_{sv}
	Kurtosis	$\frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma}\right)^4$	X_{ku}

2.5.2 Analyse dans le domaine fréquentiel

L'analyse fréquentielle complète l'analyse temporelle en révélant la répartition de l'énergie vibratoire en fonction de la fréquence. Cette approche est particulièrement adaptée à l'identification de défauts dont les signatures sont périodiques ou liées à des fréquences caractéristiques spécifiques, telles que la fréquence de rotation, les fréquences de denture ou les fréquences de roulements [19].

2.5.2.1 Transformée de Fourier rapide (FFT)

La transformée de Fourier est l'outil mathématique fondamental pour passer de la représentation temporelle d'un signal à sa représentation fréquentielle [16]. La Transformée de Fourier Discrète (TFD) d'un signal $x(n)$ de longueur N est définie par [19] :

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi kn/N}, \quad k = 0, 1, \dots, N-1 \quad (2.3)$$

La Transformée de Fourier rapide (FFT) est un algorithme permettant de calculer la TFD avec une complexité temporelle $\mathcal{O}(N \log N)$ au lieu de $\mathcal{O}(N^2)$ pour le calcul direct, rendant possible l'analyse spectrale en temps réel ou sur de longs signaux [5].

2.5.2.2 Spectre d'amplitude

Le spectre d'amplitude est obtenu en prenant le module de la transformée de Fourier :

$$A(k) = |X(k)| = \sqrt{\text{Re}(X(k))^2 + \text{Im}(X(k))^2} \quad (2.4)$$

Il associe à chaque fréquence discrète $f_k = k \cdot \frac{f_s}{N}$ l'amplitude de la composante sinusoïdale correspondante, où f_s est la fréquence d'échantillonnage.

En analyse vibratoire, le spectre d'amplitude permet d'identifier :

- Les fréquences fondamentales de rotation (fréquence de l'arbre).
- Leurs harmoniques (multiples entiers de la fondamentale).
- Les fréquences caractéristiques des roulements [13].
- Les fréquences de denture pour les engrenages.
- Les bandes latérales de modulation, typiques des défauts de roulements et d'engrenages [20].

La présence de raies spectrales à des fréquences non liées au régime normal constitue une signature caractéristique de nombreux défauts [19].

2.5.2.3 Calcul du spectre dans notre étude

Dans le cadre de ce travail, le calcul du spectre a été effectué selon une procédure précise afin d'assurer la qualité et la reproductibilité des résultats. Après prétraitement du signal (suppression de la composante continue et filtrage Butterworth), une fenêtre de Hann de $N = 16\,384$ points est appliquée sur le segment de signal avant le calcul de la FFT. Ce choix est motivé par la capacité de la fenêtre de Hann à réduire les effets de fuite spectrale.

L'amplitude normalisée est ensuite obtenue par :

$$A_{\text{norm}}(k) = \frac{|X(k)|}{N} \quad (2.5)$$

La fenêtre de Hann est définie par :

$$w(n) = 0,5 \left(1 - \cos \frac{2\pi n}{N-1} \right), \quad n = 0, 1, \dots, N-1 \quad (2.6)$$

Seule la partie unilatérale du spectre (de 0 à $f_s/2 = 25\,000$ Hz) est conservée, conformément au théorème de Shannon-Nyquist [16]. La figure 2.6 compare les spectres obtenus pour les six classes de la base MaFaultDa. On remarque que chaque type de défaut présente une signature fréquentielle distincte, ce qui justifie l'utilisation du domaine fréquentiel comme source de caractéristiques discriminantes pour la classification automatique.




Figure 2.6: Spectres d'amplitude FFT des six classes de la base MaFaultDa

2.5.2.4 Vecteur de caractéristiques fréquentiel

Le vecteur de caractéristiques fréquentiel $\mathbf{f}_\omega$ est construit à partir du spectre d'amplitude et est défini par l'équation 2.7 :

$$\mathbf{f}_\omega = [f_{\text{centroid}}, \sigma_\omega, S_\omega, K_\omega, f_{\text{roll-on}}, f_{\text{roll-off}}, E, H]^T \quad (2.7)$$

Les composantes de ce vecteur sont récapitulées dans le tableau 2.4.

- Centroïde spectral
- Écart-type spectral
- Asymétrie spectrale
- Aplatissement spectral
- Fréquence roll-on
- Fréquence roll-off
- Énergie spectrale
- Entropie spectrale

Contrairement au vecteur temporel, $\mathbf{f}_\omega$ présente l'avantage d'être directement interprétable physiquement et de mieux séparer des défauts ayant des signatures temporelles proches mais des contenus fréquentiels différents. Par exemple, le déséquilibre se manifeste principalement à la fréquence de rotation fondamentale, tandis que le désalignement produit des harmoniques de rang 2 et 3 [14, 20].

Le tableau 2.4 résume les huit composantes du vecteur fréquentiel $\mathbf{f}_\omega$.

Tableau 2.4: Récapitulatif des indicateurs fréquentiels

Indicateur	Symbole	Description
Centroïde spectral	f_{centroid}	Barycentre du spectre, fréquence moyenne pondérée par l'amplitude
Écart-type spectral	σ_ω	Mesure de dispersion autour du centroïde
Asymétrie spectrale	S_ω	Symétrie de la distribution spectrale (skewness)
Aplatissement spectral	K_ω	Caractère pointu ou plat du spectre (kurtosis)
Fréquence roll-on	$f_{\text{roll-on}}$	Fréquence en dessous de laquelle se trouvent 5% de l'énergie totale
Fréquence roll-off	$f_{\text{roll-off}}$	Fréquence en dessous de laquelle se trouvent 85% de l'énergie totale
Énergie spectrale	E	Somme des carrés des amplitudes spectrales
Entropie spectrale	H	Mesure du désordre ou de la complexité du spectre

2.5.3 Analyse de corrélation et sélection des caractéristiques

Avant d'alimenter les classifieurs, une analyse de corrélation a été réalisée afin d'évaluer les relations entre les différentes caractéristiques extraites dans le domaine temporel [21]. Cette étape permet d'identifier les variables redondantes et de réduire la dimensionnalité du vecteur de caractéristiques, améliorant ainsi l'efficacité et la robustesse des modèles [17].

Le coefficient de corrélation de Pearson est utilisé pour mesurer la dépendance linéaire

entre deux variables [21]. Il est défini par :

$$\rho_{x,y} = \frac{\text{Cov}(x, y)}{\sigma_x \sigma_y} \quad (2.8)$$

où σ_x et σ_y représentent les écarts-types des variables x et y respectivement.

La figure 2.7 présente la matrice de corrélation calculée sur les 30 premières caractéristiques temporelles extraites.




Figure 2.7: Matrice de corrélation des caractéristiques temporelles

Une valeur proche de +1 indique une forte corrélation positive, une valeur proche de -1 une corrélation négative, et une valeur proche de 0 l'absence de corrélation linéaire [21]. Dans ce travail, un seuil $|\rho| > 0,95$ a été utilisé pour identifier les caractéristiques fortement corrélées, considérées comme redondantes. Les variables suivantes ont ainsi été éliminées :

ay_clearance, ax_impulse, ay_aac, ax_rms, az_clearance, az_rms,
az_impulse, az_aac, ay_impulse, ax_clearance

La suppression de ces caractéristiques redondantes permet d'obtenir un vecteur de caractéristiques plus compact, de réduire le risque de surapprentissage et d'améliorer l'efficacité des modèles de classification [17].

2.6 Classifieurs

Trois modèles de classification supervisée ont été retenus dans cette étude : le K-Plus Proches Voisins (KNN), la Machine à Vecteurs de Support (SVM) et le Perceptron Multicouche (MLP). Ces modèles représentent trois approches complémentaires en termes de complexité, d'interprétabilité et de capacité de généralisation [17, 18].

2.6.1 K-Plus Proches Voisins (KNN)

K-Nearest Neighbors (KNN) est un algorithme d'apprentissage automatique supervisé simple et efficace, utilisable pour la classification et la régression [17]. En classification, il repose sur le vote majoritaire des k voisins les plus proches d'un point de données dans l'espace des caractéristiques. Un objet est ainsi classé dans la catégorie la plus représentée parmi ses k plus proches voisins.

Le choix du paramètre k est crucial : des valeurs élevées réduisent l'influence du bruit mais peuvent lisser les frontières de décision, tandis que des valeurs faibles rendent le modèle plus sensible aux variations locales [18].

La figure 2.8 illustre le principe de classification pour $k = 3$: les trois voisins les plus proches du point à classer comprennent un carré et deux cercles, de sorte que le point est affecté à la classe des cercles [22].




Figure 2.8: Exemple de classification par l'algorithme KNN ($k = 3$)

Le choix de la métrique de distance est déterminant dans l'algorithme KNN, car elle définit la notion de similarité entre les observations [17]. Une métrique inadaptée peut entraîner des classifications erronées, même si le reste du modèle est bien configuré.

Distance euclidienne. La distance euclidienne est la plus utilisée en pratique :

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.9)$$

Elle correspond à la distance géométrique dans l'espace euclidien. Elle est adaptée aux variables continues de même échelle, mais sensible aux différences d'échelle, ce qui rend la normalisation préalable nécessaire [17].

Distance de Manhattan. Moins sensible aux valeurs aberrantes, elle est souvent préférée pour des données bruitées ou à distributions non gaussiennes [18] :

$$d(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n |x_i - y_i| \quad (2.10)$$

Distance de Minkowski. Généralisation paramétrique des deux précédentes [17] :

$$d(\mathbf{x}, \mathbf{y}) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (2.11)$$

Pour $p = 2$, on obtient la distance euclidienne ; pour $p = 1$, la distance de Manhattan. Ce paramètre permet d'adapter la sensibilité de la distance aux différences entre caractéristiques.

Distance de Mahalanobis. Elle prend en compte la corrélation entre les variables, offrant une mesure plus réaliste dans des données corrélées [18] :

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T S^{-1} (\mathbf{x} - \mathbf{y})} \quad (2.12)$$

où S est la matrice de covariance des données.

Malgré sa simplicité, le KNN présente des limitations importantes. Le calcul de distance devient moins pertinent lorsque le nombre de dimensions augmente — phénomène connu sous le nom de malédiction de la dimensionnalité [23] car les distances entre les points tendent à devenir similaires, dégradant les performances du classifieur. De plus, le KNN ne construit pas de modèle explicite, ce qui le rend coûteux en mémoire et en temps d'inférence pour de grands jeux de données [17].

2.6.2 Machine à Vecteurs de Support (SVM)

La Machine à Vecteurs de Support (SVM) est un algorithme d'apprentissage supervisé utilisé pour la classification et la régression [24]. Son principe repose sur la recherche d'un hyperplan optimal qui maximise la marge de séparation entre les classes dans l'espace des caractéristiques.

L'hyperplan optimal est celui pour lequel la distance minimale aux échantillons d'apprentissage les plus proches — appelés vecteurs de support — est la plus grande [24]. Cette propriété confère au SVM une excellente capacité de généralisation, même dans des espaces de grande dimension [18].

La figure 2.9 illustre les notions d'hyperplan optimal, de marge et de vecteurs de support.

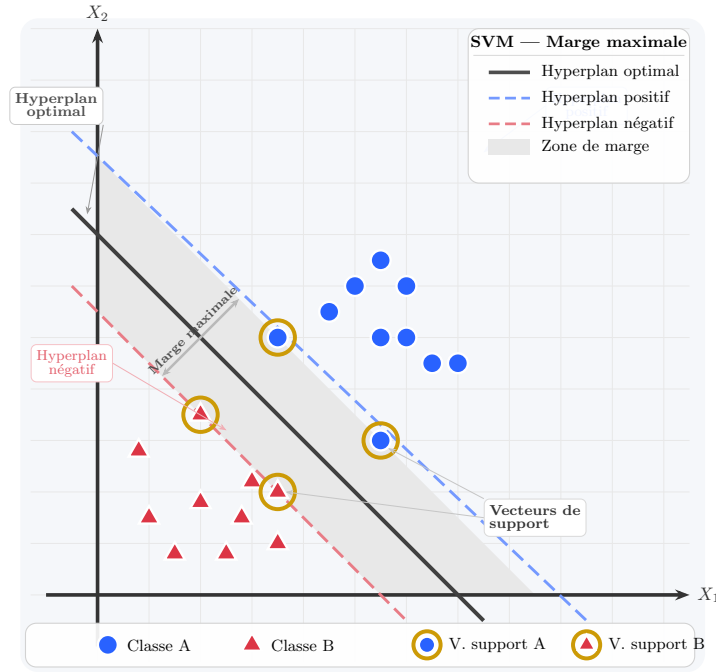


Figure 2.9: Hyperplan optimal, marge et vecteurs de support

Lorsque les données ne sont pas linéairement séparables, le SVM projette implicitement les données dans un espace de dimension supérieure à l'aide d'une fonction noyau $K(\mathbf{x}_i, \mathbf{x}_j)$, qui calcule directement le produit scalaire dans cet espace sans nécessiter la projection explicite [24].

Parmi les noyaux les plus utilisés [17] :

- **Noyau linéaire** : $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$. Équivalent au SVM linéaire.
- **Noyau polynomial** : $K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + r)^d$. Frontières polynomiales de degré d .
- **Noyau RBF (Radial Basis Function)** : $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2)$. Le plus populaire, capable d'approximer n'importe quelle frontière continue avec un choix approprié de γ .

Dans ce travail, le noyau RBF a été retenu pour sa flexibilité et son efficacité sur des problèmes variés, avec un seul hyperparamètre γ à régler en plus du paramètre de régularisation C [25].

2.6.3 Perceptron multicouche (MLP)

Le Multi-Layer Perceptron (MLP) est l'architecture de base des réseaux de neurones profonds [26]. Il s'organise en couches successives : une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie, chaque neurone d'une couche étant connecté à tous les neurones de la couche suivante (*fully connected*).

L'architecture adoptée dans cette étude comprend :

- Une couche d'entrée dont la dimension correspond au nombre de caractéristiques.
- Deux couches cachées de 64 neurones chacune.
- Une couche de sortie avec C neurones (un par classe) et une fonction d'activation

softmax.

La figure 2.10 illustre l'architecture du réseau de neurones à deux couches cachées utilisé dans cette étude.




Figure 2.10: Architecture du réseau de neurones à deux couches cachées

2.6.3.1 Fonctions d'activation

Les fonctions d'activation confèrent aux réseaux de neurones leur capacité à modéliser des relations non linéaires [26].

Pour les couches cachées, la fonction ReLU (*Rectified Linear Unit*) est utilisée [27] :

$$f(x) = \max(0, x) \quad (2.13)$$

Elle est appréciée pour sa simplicité et son efficacité à réduire le problème du gradient évanescent, facilitant l'entraînement de réseaux profonds.

Pour la couche de sortie, la fonction softmax transforme les sorties brutes en une distribution de probabilités sur les C classes [18] :

$$\sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^C e^{z_k}} \quad (2.14)$$

2.6.3.2 Procédure d'entraînement

Dans un réseau de neurones profond, les poids w_i et les biais b constituent les paramètres appris durant la phase d'entraînement [26]. Le fonctionnement d'un neurone est décrit par :

$$z = \sum_{i=1}^n w_i x_i + b \quad (2.15)$$

L'ensemble d'entraînement est divisé en sous-ensembles de taille fixe appelés batchs (ou mini-lots). À chaque itération, le gradient est estimé sur un seul batch, ce qui rend la mise à jour des poids moins coûteuse que sur la totalité des données [26]. Un passage complet sur l'ensemble des batchs, c'est-à-dire sur la totalité des données d'entraînement, constitue une époque. L'entraînement se déroule sur plusieurs époques jusqu'à

convergence.

L'entraînement consiste à minimiser la fonction de perte d'entropie croisée catégorielle [26] :

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(\hat{y}_{i,c}) \quad (2.16)$$

où $y_{i,c}$ vaut 1 si l'échantillon i appartient à la classe c , et $\hat{y}_{i,c}$ est la probabilité prédite par le softmax.

La minimisation est réalisée par descente de gradient stochastique par mini-lots (*mini-batch SGD*), et les gradients sont calculés efficacement par l'algorithme de rétropropagation [28]. Pour éviter le surapprentissage, la perte sur un ensemble de validation est surveillée et un arrêt anticipé (*early stopping*) est appliqué lorsqu'elle cesse de s'améliorer.

2.6.3.3 Optimisation Adam

L'optimiseur Adam (*Adaptive Moment Estimation*) combine deux mécanismes complémentaires : l'utilisation d'un moment (moyenne exponentielle des gradients passés, comme dans Momentum) et une adaptation du taux d'apprentissage par paramètre (comme dans RMSProp) [29]. Cette combinaison permet une convergence rapide et stable sur une grande variété de problèmes.

Dans cette étude, les valeurs recommandées sont utilisées [29] : $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 10^{-8}$ et un taux d'apprentissage $\eta = 0,001$.

2.7 Protocole expérimental

Cette section décrit le cadre expérimental adopté pour évaluer les performances des trois modèles de classification sur la base MaFaulDa.

2.7.1 Partitionnement train / test

Le partitionnement des données constitue une étape essentielle dans le processus d'apprentissage supervisé [17]. Il consiste à diviser le jeu de données en deux sous-ensembles distincts afin d'entraîner et d'évaluer les modèles.

Dans cette étude, une répartition de 80% pour l'apprentissage et 20% pour le test a été adoptée, représentant un compromis courant entre la quantité de données d'entraînement et celle réservée à l'évaluation [18]. La figure 2.11 illustre ce schéma de partitionnement.




Figure 2.11: Partitionnement train/test du jeu de données

Afin d'assurer une distribution équilibrée des classes, les données ont été mélangées aléatoirement avant la division. Le partitionnement a été réalisé à l'aide de la fonction `train_test_split` de la bibliothèque Scikit-learn [25]. Cette procédure permet d'obtenir une estimation fiable des performances et de limiter le risque de surapprentissage.

2.7.2 Métriques d'évaluation

L'évaluation des performances des modèles repose sur plusieurs métriques complémentaires, couramment utilisées en apprentissage automatique pour analyser la qualité des classifieurs [30].

Accuracy (exactitude). Rapport entre le nombre de prédictions correctes et le nombre total d'observations. Elle offre une vue globale des performances, mais peut être insuffisante en cas de déséquilibre entre classes [30] :

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.17)$$

Matrice de confusion. Outil fondamental permettant de comparer les classes réelles aux classes prédites, de visualiser les erreurs de classification et d'identifier les classes les plus confondues [17].

2.7.3 Environnement d'implémentation

Les expérimentations ont été réalisées en Python sur la plateforme Kaggle, bénéficiant d'un environnement de calcul adapté au traitement de données volumineuses. Les modèles KNN et SVM ont été implémentés avec la bibliothèque Scikit-learn [25], tandis que le modèle MLP a été développé avec TensorFlow [31].

2.8 Résultats

Cette section présente les résultats expérimentaux obtenus pour la classification des défauts mécaniques à partir des signaux vibratoires issus de la base MaFaulDa. Les trois modèles KNN, SVM et MLP sont évalués dans les deux domaines d'analyse : temporel et fréquentiel.

2.8.1 Résultats dans le domaine temporel

Les caractéristiques temporelles décrites à la section précédente, après suppression des variables redondantes, constituent le vecteur d'entrée des modèles dans ce domaine.

2.8.1.1 Modèle KNN

Les résultats obtenus avec le KNN montrent une précision globale de 93,86%, indiquant une bonne capacité à discriminer les différentes classes de défauts. Afin d'optimiser les performances, une étude de sensibilité a été menée en faisant varier la valeur du paramètre k [17]. La figure 2.12 présente l'évolution de la précision en fonction de k .




Figure 2.12: Évolution de la précision en fonction de k sur le domaine temporel

Les résultats montrent que la meilleure performance est obtenue pour $k = 1$, avec une précision de 93,86%. Une diminution progressive est observée lorsque k augmente, avec une légère variation pour $k = 4$.

La figure 2.13 présente la matrice de confusion correspondante.




Figure 2.13: Matrice de confusion KNN en domaine temporel

La majorité des observations sont correctement classées, comme en témoigne la dominance des valeurs sur la diagonale. Les classes Normal, Vertical Misalignment et Ball Fault sont parfaitement identifiées, indiquant une bonne séparabilité de leurs caractéristiques temporelles.

2.8.1.2 Modèle SVM

Le modèle SVM appliqué dans le domaine temporel a obtenu une précision globale de 99,49%, traduisant une excellente capacité de classification. Le noyau RBF a été retenu pour sa capacité à capturer efficacement les relations non linéaires entre les caractéristiques temporelles [24], offrant une meilleure séparation des classes dans un espace de dimension supérieure.

La figure 2.14 présente la matrice de confusion du modèle SVM.




Figure 2.14: Matrice de confusion SVM, domaine temporel

La forte concentration des valeurs sur la diagonale principale confirme la quasi-totalité des classifications correctes. Les quelques confusions observées concernent principalement des défauts aux signatures vibratoires similaires, comme Cage Fault et Outer Race Fault [13].

2.8.1.3 Modèle MLP

Le modèle MLP a obtenu une précision globale de 96,93% dans le domaine temporel. La figure 2.15 présente les courbes d'apprentissage du modèle.




Figure 2.15: Courbes d'apprentissage du modèle MLP domaine temporel (loss et accuracy)

La fonction de perte diminue rapidement au début, puis se stabilise, tandis que la précision dépasse rapidement 80% pour atteindre 96%. La forte similarité entre les courbes d'entraînement et de validation confirme l'absence de surapprentissage et une bonne capacité de généralisation [26].

La figure 2.16 présente la matrice de confusion correspondante.




Figure 2.16: Matrice de confusion MLP en domaine temporel

Les classes Imbalance et Ball Fault sont parfaitement identifiées, tandis que Vertical Misalignment et Cage Fault présentent également des taux de classification élevés.

2.8.2 Résultats dans le domaine fréquentiel

Dans le domaine fréquentiel, les caractéristiques extraites à partir du spectre d'amplitude — centroïde, écart-type spectral, entropie, etc. constituent le vecteur d'entrée des modèles. Ce domaine offre une représentation plus discriminante des défauts à signatures périodiques [19].

2.8.2.1 Modèle KNN

Le modèle KNN dans le domaine fréquentiel a atteint une précision de 95,40%, en amélioration par rapport au domaine temporel. La valeur optimale du paramètre est $k = 3$, offrant un bon compromis entre sensibilité locale et robustesse au bruit [17].

La figure 2.17 présente l'évolution de la précision en fonction de k dans le domaine fréquentiel.




Figure 2.17: Évolution de la précision en fonction de k domaine fréquentiel

La figure 2.18 présente la matrice de confusion correspondante.




Figure 2.18: Matrice de confusion KNN, domaine fréquentiel

Les classes Imbalance et Ball Fault sont parfaitement identifiées, tandis que quelques confusions subsistent entre Normal et Vertical Misalignment.

2.8.2.2 Modèle SVM

Le modèle SVM dans le domaine fréquentiel présente des performances exceptionnelles, avec une précision de 99,49%. Le noyau RBF permet une séparation quasi parfaite des

classes dans l'espace fréquentiel [24].

La figure 2.19 confirme ces résultats.




Figure 2.19: Matrice de confusion de modèle SVM en domaine fréquentiel

Toutes les classes sont parfaitement identifiées, avec seulement une légère confusion entre Cage Fault et Outer Race Fault [13].

2.8.2.3 Modèle MLP

Le modèle MLP dans le domaine fréquentiel atteint une précision de 97,44%. La figure 2.20 présente les courbes d'apprentissage.




Figure 2.20: Courbes d'apprentissage du modèle MLP domaine fréquentiel

La diminution progressive de la perte et la convergence stable des courbes d'entraînement et de validation indiquent une bonne généralisation sans surapprentissage notable [26]. La figure 2.21 présente la matrice de confusion du modèle MLP dans le domaine fréquentiel.




Figure 2.21: Matrice de confusion de modèle MLP en domaine fréquentiel

2.8.3 Synthèse comparative

Le tableau 2.5 résume les performances des trois modèles dans les deux domaines d'analyse.

Tableau 2.5: Comparaison des modèles leurs précision et temps d'exécution

Modèle	Précision (%)	Temps (s)
KNN — Temporel (TD)	93,00	1,39
KNN — Fréquentiel (FD)	95,05	1,14
SVM — Temporel (TD)	96,08	1,52
SVM — Fréquentiel (FD)	99,49	1,00
MLP — Temporel (TD)	94,20	3,40
MLP — Fréquentiel (FD)	97,95	1,66

Ces résultats mettent en évidence deux tendances claires : le domaine fréquentiel améliore systématiquement les performances par rapport au domaine temporel pour tous les modèles [19], et le SVM avec noyau RBF se distingue comme le classifieur le plus performant dans les deux domaines [24].

2.9 Discussion

L'analyse des résultats montre que l'utilisation du domaine fréquentiel améliore significativement les performances des modèles de classification par rapport au domaine temporel [5, 19]. La transformation des signaux vibratoires par la FFT met en évidence des composantes spectrales caractéristiques propres à chaque type de défaut, rendant les signatures plus distinctes et facilitant la séparation des classes dans l'espace des caractéristiques [13].

Cette amélioration est particulièrement marquée pour le KNN (+2,05%) et le MLP

(+3,75%), tandis que le SVM maintient le même niveau de performance élevé dans les deux domaines [24]. Le domaine fréquentiel constitue ainsi une représentation plus pertinente pour la détection et la classification des défauts vibratoires, en capturant des informations difficiles à distinguer dans le domaine temporel [20].

La comparaison des trois modèles révèle des différences significatives en termes de performances et de robustesse [17].

Le KNN offre des résultats satisfaisants mais reste limité par sa sensibilité au choix du paramètre k et par la malédiction de la dimensionnalité [23]. Il présente des difficultés à distinguer certaines classes aux signatures similaires.

Le SVM avec noyau RBF se distingue comme le plus performant de cette étude, avec une précision atteignant 99,49% dans les deux domaines [24]. Sa capacité à modéliser les relations non linéaires entre caractéristiques, combinée à sa robustesse théorique vis-à-vis du surapprentissage, en fait le meilleur compromis entre performance et complexité pour ce problème de diagnostic [10].

Le MLP présente également de bonnes performances grâce à sa capacité à apprendre des représentations complexes des données [26]. Cependant, il reste légèrement inférieur au SVM tout en étant plus coûteux en calcul et nécessitant un réglage plus fin des hyperparamètres.

Malgré les performances élevées obtenues, plusieurs limites doivent être prises en compte [11].

Premièrement, certaines classes présentent des signatures vibratoires proches, entraînant des confusions dans la classification, notamment entre Cage Fault et Outer Race Fault, ou entre Normal et Imbalance à faible déséquilibre [13].

Deuxièmement, la qualité des caractéristiques extraites joue un rôle déterminant dans les performances [10]. Des caractéristiques sous-optimales peuvent limiter la capacité de discrimination, même avec un classifieur puissant.

Troisièmement, les modèles comme le KNN sont sensibles au bruit et aux valeurs aberrantes [23], tandis que le MLP nécessite un réglage précis des hyperparamètres pour éviter le surapprentissage [26].

Enfin, les résultats dépendent du jeu de données MaFaulDa [12], ce qui peut limiter leur généralisation à d'autres configurations industrielles ou types de machines [11].

Ces limitations suggèrent des pistes d'amélioration potentielles : techniques avancées de sélection de caractéristiques, optimisation des hyperparamètres, combinaison de plusieurs modèles ou encore utilisation de représentations temps-fréquence plus riches [10].

2.10 Conclusion

Ce chapitre a présenté une étude complète du diagnostic vibratoire des machines tournantes par apprentissage automatique, en s'appuyant sur la base de données MaFaulDa. Après une phase de prétraitement rigoureuse (filtrage de Butterworth et normalisation), des caractéristiques ont été extraites dans les domaines temporel et fréquentiel, et une sélection par analyse de corrélation a permis d'éliminer les variables redondantes.

Trois modèles de classification ont été évalués : KNN, SVM et MLP dans les deux domaines d'analyse. Les résultats obtenus montrent que le domaine fréquentiel permet une meilleure discrimination des défauts grâce à des caractéristiques spectrales plus représentatives. Parmi les modèles testés, le SVM avec noyau RBF s'est révélé le plus performant, atteignant une précision de 99,49%, suivi du MLP (97,95%) et du KNN (95,05%) dans le domaine fréquentiel.

Cette étude met en évidence l'importance du choix du domaine d'analyse et du modèle de classification pour améliorer la fiabilité du diagnostic vibratoire, et ouvre la voie à des approches plus avancées combinant représentations temps-fréquence et architectures d'apprentissage profond.

Chapitre 3

Déploiement du Système de Diagnostic Vibratoire Embarqué

3.1	Introduction	58
3.2	Environnement matériel	58
3.2.1	Raspberry Pi 4	58
3.2.2	Capteur GY-LSM6DS3	59
3.2.3	Connexion I2C entre la Raspberry Pi 4 et les capteurs	60
3.2.4	Banc d'essai expérimental	60
3.3	Acquisition des signaux vibratoires réels	61
3.3.1	Protocole d'acquisition	62
3.3.2	Description des classes	63
3.3.3	Caractéristiques des signaux acquis	64
3.4	Prétraitement et extraction des caractéristiques	65
3.5	Entraînement des modèles sur les données réelles	66
3.5.1	Protocole expérimental	66
3.5.2	Domaine temporel	66
3.5.3	Domaine fréquentiel	67
3.5.4	Comparaison et discussion	68
3.6	Optimisation et conversion des modèles	68
3.6.1	Conversion au format TensorFlow Lite	68
3.6.2	Quantification float16	69
3.6.3	Sauvegarde des modèles KNN et SVM	69
3.7	Conclusion	69

3.1 Introduction

Dans les chapitres précédents, nous avons développé et évalué plusieurs modèles de Machine Learning et de Deep Learning pour le diagnostic des défauts des machines tournantes par analyse vibratoire, en utilisant la base de données MaFaultDa. Dans ce chapitre, nous présentons le déploiement de ces modèles sur une plateforme embarquée de type Raspberry Pi 4. Nous avons opté pour une acquisition directe des signaux vibratoires à l'aide de notre propre banc d'essai.

3.2 Environnement matériel

Afin de valider expérimentalement le système de diagnostic vibratoire développé dans notre travail, nous avons mis en place une plateforme d'acquisition basée sur une carte Raspberry Pi 4 et deux capteurs inertiels GY-LSM6DS3. Cette plateforme a permis de collecter des signaux vibratoires réels dans différentes conditions de fonctionnement d'un banc expérimental constitué d'un moteur électrique couplé à un générateur.

3.2.1 Raspberry Pi 4

La Raspberry Pi 4 constitue l'unité centrale du système d'acquisition et de traitement. Elle assure la communication avec les capteurs vibratoires via le protocole I2C, l'enregistrement des données acquises ainsi que l'exécution des algorithmes de traitement du signal et de classification.

La figure 3.1 présente la carte Raspberry Pi 4 utilisée dans ce travail.




Figure 3.1: La carte Raspberry Pi 4


Le tableau 4.1 résume les caractéristiques techniques complètes de la carte Raspberry Pi 4 utilisée dans ce travail.

Tableau 3.1: Caractéristiques techniques de la carte Raspberry Pi 4

Caractéristique	Valeur
Processeur	Broadcom BCM2711, Quad-Core Cortex-A72
Fréquence	1,5 GHz
Mémoire RAM	8 Go LPDDR4
Stockage	Carte microSD
Connectivité	Wi-Fi 802.11ac, Bluetooth 5.0, Ethernet
Ports GPIO	40 broches (I2C, SPI, UART)
Alimentation	5V / 3A via USB-C
Consommation	$\approx 5 W$ en fonctionnement
Système d'exploitation	Raspberry Pi OS (Linux Debian)

3.2.2 Capteur GY-LSM6DS3

Le capteur GY-LSM6DS3 est un module inertiel intégrant un accéléromètre triaxial et un gyroscope triaxial. Dans le cadre de ce travail, seules les mesures de l'accéléromètre ont été exploitées pour l'analyse vibratoire. La figure 3.2 présente ce capteur.

**Figure 3.2:** L'accéléromètre GY-LSM6DS3

Deux capteurs GY-LSM6DS3 ont été utilisés afin d'acquérir simultanément les vibrations en deux points distincts du système mécanique. Chaque capteur fournit les accélérations selon les trois axes orthogonaux X, Y et Z, permettant ainsi une caractérisation complète du comportement vibratoire de la machine. Le tableau 4.2 résume les principales caractéristiques techniques de ce capteur.

Tableau 3.2: Caractéristiques techniques du capteur GY-LSM6DS3

Caractéristique	Valeur
Type	Accéléromètre + Gyroscope 3 axes
Plage d'accélération	$\pm 2g$ à $\pm 16g$
Plage gyroscope	± 125 à ± 2000 dps
Fréquence d'échantillonnage	300 Hz (sur Raspberry Pi 4)
Protocole de communication	I2C / SPI
Tension d'alimentation	1,71 à 3,6 V
Consommation	0,9 mA en mode normal
Résolution	16 bits

3.2.3 Connexion I2C entre la Raspberry Pi 4 et les capteurs

Les deux capteurs GY-LSM6DS3 sont reliés à la Raspberry Pi 4 via le bus I2C. Afin de permettre leur utilisation simultanée sur le même bus, les capteurs ont été configurés avec deux adresses différentes (0x6A et 0x6B). La figure 3.3 illustre le schéma de connexion I2C entre la Raspberry Pi 4 et les deux capteurs.




Figure 3.3: Connexion I2C entre la carte Raspberry Pi 4 et les deux capteurs LSM6DS3

Cette architecture permet la lecture synchrone des mesures provenant des deux capteurs tout en limitant le nombre de connexions matérielles nécessaires. Les données vibratoires sont ensuite enregistrées sous forme de fichiers CSV pour être utilisées lors des phases de prétraitement, d'extraction de caractéristiques et d'apprentissage des modèles.

3.2.4 Banc d'essai expérimental

Le banc expérimental utilisé dans cette étude est constitué d'un moteur électrique couplé mécaniquement à un générateur. Afin d'étudier l'influence des différents défauts mécaniques sur les vibrations produites par le système, deux capteurs GY-LSM6DS3 ont été

fixés à des emplacements stratégiques :

- Le premier capteur est installé avant l'accouplement.
- Le second capteur est installé après l'accouplement.

La figure 3.4 présente le banc d'essai expérimental utilisé dans ce travail.




Figure 3.4: Le banc d'essai expérimental utilisé dans notre travail

Cette configuration permet d'observer la propagation des vibrations à travers l'ensemble mécanique et d'obtenir des informations complémentaires sur l'état de fonctionnement du système.

Trois conditions de fonctionnement ont été considérées :

- État normal ;
- Défaut de déséquilibre (Imbalance) ;
- Défaut de désalignement.

Pour chaque état, nous avons réalisé 60 acquisitions vibratoires d'une durée de 5 secondes chacune. Chaque signal contient 317 échantillons enregistrés simultanément sur les deux capteurs, soit six voies d'acquisition correspondant aux axes $ax1$, $ay1$, $az1$, $ax2$, $ay2$ et $az2$.

La base de données ainsi constituée comporte un total de 180 signaux vibratoires réels, dont les paramètres sont résumés dans le tableau 3.3 de la section suivante.

3.3 Acquisition des signaux vibratoires réels

Après la mise en place de la plateforme matérielle, une campagne d'acquisition expérimentale a été réalisée afin de constituer une base de données vibratoires représentative des différents états de fonctionnement du système étudié. La figure 3.5 illustre une acquisition réalisée dans le cadre de cette campagne.


```
Acquisition 24/30
Enregistrement : Désalignement/signal_24.csv
Signal 24 terminé.

Acquisition 25/30
Enregistrement : Désalignement/signal_25.csv
Signal 25 terminé.

Acquisition 26/30
Enregistrement : Désalignement/signal_26.csv
Signal 26 terminé.

Acquisition 27/30
Enregistrement : Désalignement/signal_27.csv
Signal 27 terminé.

Acquisition 28/30
Enregistrement : Désalignement/signal_28.csv
Signal 28 terminé.

Acquisition 29/30
Enregistrement : Désalignement/signal_29.csv
Signal 29 terminé.

Acquisition 30/30
Enregistrement : Désalignement/signal_30.csv
Signal 30 terminé.

Les 30 fichiers CSV ont été enregistrés dans le dossier désalignement.
matari@raspberrypi4:~/Desktop/Test capteurs $
```

Figure 3.5: Acquisition des données de défaut désalignement

3.3.1 Protocole d'acquisition

Les acquisitions ont été effectuées sur le banc d'essai décrit dans la section précédente (voir figure 3.4). Les deux capteurs GY-LSM6DS3 communiquent avec la Raspberry Pi 4 via le protocole I2C (voir figure 3.3). Les données d'accélération sont enregistrées selon les trois axes de mesure X, Y et Z pour chacun des capteurs.

La figure 3.6 illustre le protocole d'acquisition mis en place.




Figure 3.6: Le protocole d'acquisition des signaux vibratoires

Le tableau 3.3 résume les paramètres d'acquisition retenus.


Tableau 3.3: Paramètres d'acquisition des signaux vibratoires

Paramètre	Valeur
Nombre de capteurs	2 GY-LSM6DS3
Nombre d'axes mesurés	6 axes
Durée d'un signal	5 secondes
Nombre d'échantillons par signal	317
Nombre de signaux par classe	60
Nombre total de signaux	180
Protocole de communication	I2C
Plateforme d'acquisition	Raspberry Pi 4

3.3.2 Description des classes

Afin d'évaluer la capacité des modèles à distinguer différents états de fonctionnement, trois classes ont été considérées lors de l'acquisition des données vibratoires :

- **État Normal** : fonctionnement nominal du système sans défaut mécanique apparent.
- **Déséquilibre (Imbalance)** : une masse supplémentaire a été fixée sur l'accouplement reliant le moteur au générateur, comme illustré à la figure 3.7. Cette modification entraîne une répartition non uniforme de la masse en rotation, générant ainsi des forces centrifuges supplémentaires lors du fonctionnement du système.

**Figure 3.7:** Défaut de déséquilibre (imbalance)

- **Désalignement** : des rondelles d'épaisseur 0,5 mm ont été placées sous les supports du moteur, comme illustré à la figure 3.8. Cette modification provoque un décalage de l'axe du moteur par rapport à celui du générateur, entraînant ainsi un désalignement au niveau de l'accouplement.




Figure 3.8: Défaut de désalignement

Pour chacune de ces classes, 60 signaux vibratoires ont été enregistrés, ce qui conduit à une base de données équilibrée composée de 180 acquisitions (voir tableau 3.3).

3.3.3 Caractéristiques des signaux acquis

Chaque signal enregistré contient les mesures d'accélération issues des deux capteurs GY-LSM6DS3. Les six canaux acquis sont :

- $ax1, ay1, az1$: accélérations mesurées par le capteur placé avant l'accouplement ;
- $ax2, ay2, az2$: accélérations mesurées par le capteur placé après l'accouplement.

Les signaux obtenus présentent des caractéristiques différentes selon l'état mécanique étudié. L'état normal est caractérisé par des vibrations relativement stables, comme le montre la figure 3.9.




Figure 3.9: Signal temporel et spectre fréquentiel classe normal

Les états de déséquilibre et de désalignement engendrent des variations plus importantes dans les amplitudes vibratoires ainsi que dans la répartition fréquentielle de l'énergie, comme le montrent respectivement les figures 3.10 et 3.11.




Figure 3.10: Signal temporel et spectre fréquentiel classe imbalance




Figure 3.11: Signal temporel et spectre fréquentiel classe désalignement

La base de données ainsi constituée représente une source d'information pertinente pour l'extraction des caractéristiques dans les domaines temporel et fréquentiel et pour l'apprentissage des modèles KNN, SVM et MLP développés dans ce travail.

3.4 Prétraitement et extraction des caractéristiques

Les signaux vibratoires acquis à partir des deux capteurs GY-LSM6DS3 ont subi une phase de prétraitement afin d'améliorer leur qualité et de réduire l'influence du bruit présent dans les mesures. Cette étape est essentielle pour garantir l'extraction de caractéristiques représentatives de l'état mécanique du système étudié.

Dans un premier temps, un filtre passe-bas de Butterworth d'ordre cinq avec une fréquence de coupure de 50 Hz a été appliqué sur l'ensemble des signaux vibratoires. Ce filtrage permet d'atténuer les composantes fréquentielles indésirables et de conserver les informations vibratoires les plus pertinentes pour le diagnostic des défauts mécaniques. Le tableau 3.4 résume les paramètres utilisés pour le prétraitement et l'extraction des caractéristiques.

Tableau 3.4: Paramètres utilisés pour le prétraitement et l'extraction des caractéristiques

Paramètre	Valeur
Type de filtre	Butterworth passe-bas
Ordre du filtre	5
Fréquence de coupure	50 Hz
Taille de la fenêtre FFT	32 échantillons
Nombre d'axes analysés	6
Caractéristiques temporelles	60
Caractéristiques fréquentielles	72

3.5 Entraînement des modèles sur les données réelles

3.5.1 Protocole expérimental

Afin d'évaluer les performances des algorithmes d'intelligence artificielle sur les données réelles acquises expérimentalement, nous avons utilisé la base de données constituée de 180 signaux vibratoires répartis équitablement entre les trois classes étudiées : Normal, Imbalance et Désalignement (voir tableau 3.3).

Les données ont été divisées en deux ensembles :

- 80% des données pour l'entraînement des modèles.
- 20% des données pour l'évaluation.

Une normalisation des caractéristiques a été réalisée à l'aide de la méthode *StandardScaler* afin d'homogénéiser les amplitudes des variables et d'améliorer la convergence des modèles.

Trois algorithmes de classification ont été étudiés :

- K-Nearest Neighbors (KNN)
- Support Vector Machine (SVM)
- Multi-Layer Perceptron (MLP)

Les performances ont été évaluées à l'aide de la précision globale (Accuracy), des matrices de confusion ainsi que des indicateurs de précision, rappel et F1-score.

3.5.2 Domaine temporel


Dans un premier temps, les modèles KNN, SVM et MLP ont été entraînés à partir des 60 caractéristiques extraites dans le domaine temporel (voir tableau 3.4).

Les résultats obtenus sont résumés dans le tableau 3.5.

Tableau 3.5: Comparaison des performances des modèles dans le domaine temporel

Modèle	Accuracy (%)	Échantillons bien classés	Erreurs
KNN	97,14	34 / 35	1
SVM	97,14	34 / 35	1
MLP	91,43	32 / 35	3

Les matrices de confusion obtenues pour les trois modèles dans le domaine temporel sont présentées à la figure 3.12.

**Figure 3.12:** Matrices de confusion des trois modèles en domaine temporel

3.5.3 Domaine fréquentiel

Dans un second temps, les modèles ont été entraînés à partir des 72 caractéristiques fréquentielles obtenues après calcul de la FFT (voir tableau 3.4).

Les résultats obtenus sont résumés dans le tableau 3.6.

Tableau 3.6: Comparaison des performances des modèles dans le domaine fréquentiel

Modèle	Accuracy (%)	Échantillons bien classés	Erreurs
KNN	91,43	32 / 35	3
SVM	97,14	34 / 35	1
MLP	77,14	27 / 35	8

L'analyse des matrices de confusion dans le domaine fréquentiel (figure 3.13) montre que le modèle SVM-FD est le plus performant avec une précision de 97,14%. Le modèle KNN-FD obtient également de bons résultats (91,43%), malgré quelques confusions entre les classes Désalignement et Imbalance. En revanche, le modèle MLP-FD présente davantage d'erreurs de classification et atteint une précision de 77,14%.




Figure 3.13: Matrices de confusion des trois modèles en domaine fréquentiel

3.5.4 Comparaison et discussion

Le tableau 3.7 présente une synthèse comparative des performances des trois modèles dans les deux domaines d'analyse.

Tableau 3.7: Comparaison des performances des modèles sur les données vibratoires réelles acquises par les capteurs GY-LSM6DS3

Modèle	Domaine Temporel (TD)	Domaine Fréquentiel (FD)
KNN	97,14%	91,43%
SVM	97,14%	97,14%
MLP	91,43%	77,14%

La comparaison entre les deux domaines montre que les caractéristiques temporelles sont globalement plus adaptées à la base de données acquise à l'aide des capteurs GY-LSM6DS3. En effet, les modèles KNN et MLP obtiennent de meilleurs résultats dans le domaine temporel que dans le domaine fréquentiel (voir tableaux 3.5 et 3.6). Cette différence peut s'expliquer par la fréquence d'échantillonnage relativement faible des signaux acquis, qui limite la richesse des informations spectrales disponibles pour l'analyse fréquentielle.

3.6 Optimisation et conversion des modèles

Afin de faciliter le déploiement des modèles d'intelligence artificielle sur la plateforme embarquée Raspberry Pi 4, une phase d'optimisation a été réalisée. Cette étape vise à réduire la taille des modèles, améliorer leur vitesse d'exécution et limiter leur consommation mémoire tout en conservant de bonnes performances de classification.

3.6.1 Conversion au format TensorFlow Lite

Le modèle MLP développé avec TensorFlow a été converti au format TensorFlow Lite (TFLite), spécialement conçu pour les systèmes embarqués et les appareils à ressources limitées.

Les principaux avantages du format TensorFlow Lite sont :

- Réduction de la taille du modèle ;
- Diminution du temps d'inférence ;
- Faible consommation mémoire ;
- Compatibilité avec les systèmes embarqués.

3.6.2 Quantification float16

Après la conversion au format TensorFlow Lite, une quantification Float16 a été appliquée au modèle MLP. Cette technique consiste à convertir les paramètres du réseau de neurones du format Float32 vers le format Float16, permettant de diminuer significativement la taille du modèle tout en conservant un niveau de précision satisfaisant.

Les avantages de cette approche sont :

- Réduction de l'espace mémoire utilisé ;
- Accélération du chargement du modèle ;
- Amélioration de l'efficacité sur Raspberry Pi 4 ;
- Conservation des performances de classification.

3.6.3 Sauvegarde des modèles KNN et SVM

Les modèles KNN et SVM ont été sauvegardés à l'aide de la bibliothèque `joblib` afin de permettre leur utilisation sur la plateforme embarquée sans nécessiter une nouvelle phase d'entraînement. Les fichiers générés sont :

- `knn_model.pkl` pour le modèle KNN ;
- `svm_model.pkl` pour le modèle SVM ;
- `scaler.pkl` pour la normalisation des données ;
- `mlp_float16.tflite` pour le modèle MLP optimisé.

3.7 Conclusion

Dans ce chapitre, nous avons présenté le déploiement d'un système intelligent de surveillance vibratoire basé sur la Raspberry Pi 4 et les capteurs GY-LSM6DS3 . Une base de données expérimentale de 180 signaux vibratoires a été constituée à partir de trois classes de défauts : Normal, Imbalance et désalignement .

Les signaux collectés ont été prétraités puis analysés dans les domaines temporel et fréquentiel afin d'extraire des caractéristiques représentatives des différents états mécaniques. Les modèles KNN, SVM et MLP ont ensuite été entraînés et évalués sur ces données réelles. Les résultats montrent que le SVM s'est distingué par sa robustesse et ses performances élevées dans les deux domaines d'analyse.

Enfin, l'optimisation des modèles et leur intégration sur la Raspberry Pi 4 ont permis de valider la faisabilité d'une solution embarquée de diagnostic vibratoire capable d'assurer une surveillance intelligente des machines tournantes en temps réel. Le chapitre suivant présentera l'application web de supervision VibraTech Monitor développée pour la visualisation des résultats en temps réel.

Chapitre 4

Application Web de Supervision Streamlit

4.1	Introduction	71
4.2	Prototype réalisé	71
4.3	Déploiement sur Raspberry Pi 4	72
4.3.1	Environnement matériel	72
4.3.2	Optimisation et conversion des modèles pour l'embarqué	76
4.3.3	Pipeline d'inférence embarquée	76
4.4	Architecture client-serveur (RPi4 ↔ Streamlit)	77
4.5	Application web vibraTech monitor	77
4.5.1	Page d'accueil de l'application	78
4.5.2	Page d'analyse vibratoire en temps réel	79
4.5.3	Fonctionnement global de l'application	81
4.5.4	Avantages de l'application	81
4.6	Conclusion	82

4.1 Introduction

Dans les chapitres précédents, nous avons développé et évalué plusieurs modèles d'IA pour le diagnostic des défauts des machines tournantes par analyse vibratoire. Dans ce chapitre, nous présentons le déploiement de ces modèles sur une plateforme embarquée de type Raspberry Pi 4, ainsi que le développement d'une application web de supervision intelligente appelée VibraTech Monitor.

4.2 Prototype réalisé

Afin de valider l'approche proposée, un prototype complet de surveillance vibratoire intelligente a été conçu et réalisé. Ce prototype permet l'acquisition, le traitement, la classification et la visualisation en temps réel des signaux vibratoires d'une machine tournante.





Figure 4.1: Vue globale du système

Le système développé est constitué de quatre éléments principaux :

- Le banc d'essai qui est composé d'un moteur électrique couplé à un générateur
- Les deux capteurs inertiels GY-LSM6DS3 installés de part et d'autre de l'accouplement
- La carte Raspberry Pi 4 assurant l'acquisition et le traitement des données
- Et enfin, L'application web développée sous Streamlit pour la supervision et le diagnostic en temps réel



(a) Affichage des signaux vibratoires en temps réel sur l'écran Raspberry Pi



(b) Réseau local de communication entre la Raspberry Pi et l'application Streamlit

Figure 4.2: Interface de supervision et architecture de communication du système développé

Les deux capteurs GY-LSM6DS3 sont connectés à la Raspberry Pi 4 via le protocole I2C. Ils permettent de mesurer simultanément les accélérations selon les trois axes de l'espace. Ainsi, six signaux vibratoires sont acquis pour chaque enregistrement.

Les données collectées sont ensuite prétraitées afin de réduire l'influence du bruit et d'améliorer la qualité des informations exploitées. Les caractéristiques vibratoires sont extraites dans les domaines temporel et fréquentiel puis utilisées comme entrées des modèles d'intelligence artificielle.

Les modèles KNN, SVM et MLP sont intégrés au système afin d'identifier automatiquement l'état de fonctionnement de la machine parmi les trois classes considérées :

- État normal
- Défaut de déséquilibre
- Défaut de désalignement

Une architecture client-serveur a été mise en place pour assurer la communication entre la Raspberry Pi 4 et l'application Streamlit. Cette dernière permet de visualiser les signaux vibratoires, de sélectionner le modèle de classification, de choisir le domaine d'analyse et d'afficher instantanément le diagnostic généré par le système.

Le prototype réalisé démontre ainsi la faisabilité d'une solution de surveillance vibratoire intelligente à faible coût, capable d'assurer la détection automatique des défauts mécaniques en temps réel.

4.3 Déploiement sur Raspberry Pi 4

4.3.1 Environnement matériel

Le système embarqué utilisé dans cette étude repose sur une carte Raspberry Pi 4, associée à deux accéléromètres de type GY-LSM6DS3, permettant la mesure des vibrations sur plusieurs axes.

4.3.1.1 Caractéristiques de la carte (CPU, RAM, GPIO)

Le tableau 4.1 résume les caractéristiques techniques complètes de la carte Raspberry Pi 4 utilisée dans ce travail.

Tableau 4.1: Caractéristiques techniques de la carte Raspberry Pi 4

Caractéristique	Valeur
Processeur	Broadcom BCM2711, Quad-Core Cortex-A72
Fréquence	1,5 GHz
Mémoire RAM	8 Go LPDDR4
Stockage	Carte microSD
Connectivité	Wi-Fi 802.11ac, Bluetooth 5.0, Ethernet
Ports GPIO	40 broches (I2C, SPI, UART)
Alimentation	5V / 3A via USB-C
Consommation	$\approx 5 W$ en fonctionnement
Système d'exploitation	Raspberry Pi OS (Linux Debian)

4.3.1.2 Caractéristiques de l'accéléromètre GY-LSM6DS3

Les accéléromètres utilisés dans ce travail sont des modules GY-LSM6DS3, qui intègrent un accéléromètre et un gyroscope tri-axes. Ils permettent de mesurer les vibrations selon les axes X, Y et Z, fournissant ainsi des données essentielles pour le diagnostic des défauts mécaniques.

Le tableau 4.2 résume les principales caractéristiques techniques du capteur GY-LSM6DS3.

Tableau 4.2: Caractéristiques techniques du capteur GY-LSM6DS3

Caractéristique	Valeur
Type	Accéléromètre + Gyroscope 3 axes
Plage d'accélération	$\pm 2 g$ à $\pm 16 g$
Plage gyroscope	± 125 à ± 2000 dps
Fréquence d'échantillonnage	jusqu'à $6\,600\text{ Hz}$
Protocole de communication	I2C / SPI
Tension d'alimentation	1,71 à 3,6 V
Consommation	$0,9\text{ mA}$ en mode normal
Résolution	16 bits

4.3.1.3 Installation du système et des dépendances

La Raspberry Pi 4 a été configurée avec le système d'exploitation *Raspberry Pi OS*, basé sur Linux. L'installation a été réalisée à l'aide de l'outil officiel Raspberry Pi Imager.

Après l'installation du système, plusieurs dépendances ont été installées afin de permettre le traitement des données et l'exécution des modèles de Machine Learning :

- Python 3
- Bibliothèques scientifiques : NumPy, Pandas, Matplotlib
- Bibliothèques Machine Learning : Scikit-learn
- Bibliothèques Deep Learning : TensorFlow Lite (adapté aux systèmes embarqués)
- Bibliothèques de communication : SMBus pour la communication I2C avec les capteurs

La communication avec les capteurs GY-LSM6DS3 a été réalisée via le protocole I2C, permettant de lire en temps réel les données d'accélération sur les trois axes.

L'ensemble de cet environnement permet de réaliser l'acquisition, le traitement et la classification des signaux vibratoires directement sur la Raspberry Pi, rendant le système autonome et adapté aux applications industrielles.

4.3.1.4 Connexion I2C entre la Raspberry Pi 4 et les capteurs

La connexion entre la Raspberry Pi 4 et les capteurs GY-LSM6DS3 est réalisée via le protocole I2C. Ce protocole utilise seulement deux fils de données : la ligne SDA (Serial Data) et la ligne SCL (Serial Clock). Le tableau 4.3 présente les connexions utilisées.

Tableau 4.3: Connexions I2C entre le capteur GY-LSM6DS3 et la Raspberry Pi 4

Capteur GY-LSM6DS3	Raspberry Pi 4 (GPIO)	Rôle
VCC	Pin 1 (3.3V)	Alimentation
GND	Pin 6 (GND)	Masse
SDA	Pin 3 (GPIO2)	Données I2C
SCL	Pin 5 (GPIO3)	Horloge I2C

Le code Python suivant illustre la lecture des données d'accélération depuis le capteur GY-LSM6DS3 via le protocole I2C :

```

1 import smbus2
2 import time
3 import csv
4 import os
5
6 # Bus I2C Raspberry Pi
7 bus = smbus2.SMBus(1)
8
9 # Adresses des capteurs
10 LSM1_ADDR = 0x6A
11 LSM2_ADDR = 0x6B
12
13 # Registres
14 CTRL1_XL = 0x10
15 OUTX_L_XL = 0x28

```

```

16
17 # Configuration accelerometre
18 bus.write_byte_data(LSM1_ADDR, CTRL1_XL, 0x40)
19 bus.write_byte_data(LSM2_ADDR, CTRL1_XL, 0x40)
20
21 def read_word(addr, reg):
22     low = bus.read_byte_data(addr, reg)
23     high = bus.read_byte_data(addr, reg + 1)
24     value = (high << 8) | low
25     if value > 32767:
26         value -= 65536
27     return value
28
29 def read_accel(addr):
30     ax = read_word(addr, OUTX_L_XL)
31     ay = read_word(addr, OUTX_L_XL + 2)
32     az = read_word(addr, OUTX_L_XL + 4)
33     return [ax, ay, az]
34
35 # Creation du dossier data
36 os.makedirs("data", exist_ok=True)
37
38 NB_SIGNAUX = 30
39 DUREE = 5
40
41 for numero_signal in range(1, NB_SIGNAUX + 1):
42     filename = f"data/signal_{numero_signal:02d}.csv"
43     print(f"Acquisition {numero_signal}/{NB_SIGNAUX}")
44
45     with open(filename, "w", newline="") as file:
46         writer = csv.writer(file)
47         writer.writerow(["ax1", "ay1", "az1",
48                         "ax2", "ay2", "az2"])
49         start_time = time.time()
50
51         while time.time() - start_time < DUREE:
52             capteur1 = read_accel(LSM1_ADDR)
53             capteur2 = read_accel(LSM2_ADDR)
54             writer.writerow(capteur1 + capteur2)
55             time.sleep(0.01)
56
57         time.sleep(1)
58
59 print("Fichiers CSV enregistrés.")

```

Listing 4.1: Programme d'acquisition des données vibratoires à partir de deux capteurs GY-LSM6DS3

4.3.2 Optimisation et conversion des modèles pour l'embarqué

Les modèles d'IA entraînés sur PC ne peuvent pas être déployés directement sur un système embarqué comme la Raspberry Pi 4 en raison des contraintes de mémoire et de puissance de calcul. Il est donc nécessaire de les optimiser avant le déploiement.

4.3.2.1 Conversion au format TensorFlow Lite

TensorFlow Lite (TFLite) est une version allégée de TensorFlow spécialement conçue pour le déploiement sur systèmes embarqués. La conversion du modèle MLP vers le format `.tflite` permet de réduire significativement sa taille et d'accélérer le temps d'inférence sur le processeur ARM de la Raspberry Pi 4.

4.3.2.2 Quantification float16

La quantification Float16 consiste à convertir les poids du modèle du format Float32 (32 bits) vers le format Float16 (16 bits). Cette technique présente plusieurs avantages :

- Réduction de la taille : la taille du modèle est réduite d'environ 50% par rapport au modèle original.
- Accélération de l'inférence : le temps de calcul est réduit grâce à des opérations sur des données plus légères.
- Préservation de la précision : la perte de précision due à la quantification est négligeable pour notre application.
- Réduction de la consommation mémoire : moins de RAM est nécessaire pour charger et exécuter le modèle.

4.3.2.3 Comparaison des performances entre PC vs Raspberry Pi 4

Le tableau 4.4 présente une comparaison des temps d'inférence des modèles sur PC et sur Raspberry Pi 4.

Tableau 4.4: Comparaison des temps d'inférence sur PC et Raspberry Pi 4

Modèle	Format	Temps PC (s)	Temps RPi4 (s)
KNN	Scikit-learn	1,39	2,10
SVM	Scikit-learn	1,00	1,85
MLP	TFLite Float16	1,66	2,40

Les résultats montrent que les temps d'inférence sur Raspberry Pi 4 restent acceptables pour une application de surveillance en temps réel, confirmant la faisabilité du déploiement embarqué.

4.3.3 Pipeline d'inférence embarquée

Le pipeline complet d'inférence embarquée sur Raspberry Pi 4 se compose de six étapes successives :

1. Acquisition : le capteur GY-LSM6DS3 acquiert les vibrations via I2C à 6 600 Hz sur les axes X, Y et Z.

2. Prétraitement : filtrage Butterworth d'ordre 5, suppression de la composante continue (detrend) et normalisation.
3. Extraction : calcul des caractéristiques temporelles et fréquentielles pour former le vecteur d'entrée du modèle.
4. Inférence : le modèle sélectionné (KNN, SVM ou MLP-TFLite) réalise la classification du défaut.
5. Décision : le résultat est interprété et l'état de la machine est déterminé.
6. Affichage : les résultats sont transmis à Streamlit pour la visualisation en temps réel.

4.4 Architecture client-serveur (RPi4 ↔ Streamlit)

Dans cette architecture, la Raspberry Pi 4 joue le rôle de serveur embarqué. Elle assure la communication avec les deux capteurs GY-LSM6DS3 via le protocole I2C, l'acquisition des signaux vibratoires, leur prétraitement ainsi que l'exécution des modèles d'intelligence artificielle utilisés pour le diagnostic des défauts mécaniques.

L'application VibraTech Monitor, développée avec le framework Streamlit, constitue la partie cliente du système. Elle permet à l'utilisateur d'accéder aux données acquises, de lancer les opérations de diagnostic et de visualiser les résultats à travers une interface web intuitive.

Le fonctionnement général du système peut être résumé comme suit :

1. Acquisition des signaux vibratoires par les deux capteurs GY-LSM6DS3 ;
2. Transmission des données vers la Raspberry Pi 4 via le bus I2C ;
3. Prétraitement des signaux et extraction des caractéristiques ;
4. Exécution des modèles KNN, SVM ou MLP ;
5. Génération du diagnostic correspondant à l'état de la machine ;
6. Transmission des résultats vers l'application Streamlit ;
7. Visualisation des signaux et des résultats de classification en temps réel.

Cette architecture présente plusieurs avantages, notamment une séparation claire entre les fonctions d'acquisition et les fonctions de visualisation, une facilité de maintenance ainsi qu'une possibilité d'accès distant à l'interface de supervision depuis un navigateur web connecté au même réseau.

Grâce à cette approche, le système développé constitue une plateforme complète de surveillance vibratoire capable d'assurer le suivi en temps réel de l'état de fonctionnement des machines tournantes.

4.5 Application web vibraTech monitor

L'interface web de supervision utilisée dans notre projet est l'interface Streamlit, afin de permettre la visualisation en temps réel des signaux vibratoires ainsi que le suivi des

résultats de classification. Cette application constitue une interface intuitive facilitant l'interaction entre l'utilisateur et le système embarqué.

L'application développée porte le nom : *VibraTech Monitor* composé de deux parties :

- VibraTech : représentant les technologies liées à l'analyse vibratoire ;
- Monitor :représentant la fonction de supervision et de surveillance temps réel.

Notre application se compose de deux pages principales : une page d'accueil permettant de présenter les fonctionnalités du système de surveillance vibratoire intelligent, et une page d'analyse temps réel dédiée à la visualisation des signaux vibratoires, à l'analyse des données ainsi qu'à l'affichage des résultats de diagnostic obtenus par les modèles d'intelligence artificielle.

4.5.1 Page d'accueil de l'application

La première interface de l'application correspond à la page d'accueil ou page de bienvenue. Cette page permet d'introduire l'utilisateur au système de surveillance vibratoire. L'objectif principal de cette interface est de centraliser les opérations de diagnostic, de supervision et de visualisation des données vibratoires. Elle offre un accès direct aux paramètres de configuration ainsi qu'aux résultats générés par les modèles d'intelligence artificielle.

La figure 4.3 présente la page d'accueil de l'application VibraTech Monitor.




Figure 4.3: Page d'accueil de l'application VibraTech Monitor

Cette page présente les capacités principales du système telles que :

- l'analyse vibratoire temps réel ;
- la détection des défauts ;

- l'analyse fréquentielle FFT ;
- l'utilisation des modèles KNN, SVM et MLP ;
- la communication avec Raspberry Pi 4 ;
- la maintenance prédictive industrielle.

Lorsque l'utilisateur clique sur le bouton Démarrer l'analyse vibratoire, l'application redirige automatiquement vers la page d'analyse temps réel.

4.5.2 Page d'analyse vibratoire en temps réel

La deuxième interface constitue la partie principale du système de supervision. Cette page permet d'effectuer l'analyse vibratoire temps réel des signaux acquis depuis les capteurs installés sur la machine tournante.




Figure 4.4: Page d'analyse temps réel des signaux vibratoires

L'interface comprend plusieurs composants interactifs :

- sélection du modèle d'intelligence artificielle ;
- sélection du domaine d'analyse ;
- contrôle du Raspberry Pi ;
- affichage des signaux vibratoires ;
- affichage de l'état de la machine.

4.5.2.1 Sélection du modèle de classification

L'utilisateur peut sélectionner le modèle d'intelligence artificielle à utiliser parmi :

- KNN ;
- SVM ;
- MLP).

Chaque modèle possède des caractéristiques différentes en termes de précision, de vitesse d'exécution et de complexité de calcul.

Le tableau 4.5 présente une comparaison rapide des trois modèles disponibles dans l'application.

Tableau 4.5: Comparaison des modèles disponibles dans l'application

Critère	KNN	SVM	MLP
Précision (FD)	95,05%	99,49%	97,95%
Temps d'exécution (s)	1,14	1,00	1,66
Complexité	Faible	Moyenne	Élevée
Format embarqué	Scikit-learn	Scikit-learn	TFLite Float16

4.5.2.2 Choix du domaine d'analyse

L'application permet de choisir le domaine d'analyse du signal :

- domaine temporel ;
- domaine fréquentiel.

Le domaine temporel permet l'analyse directe des amplitudes vibratoires, tandis que le domaine fréquentiel utilise la Transformée de Fourier Rapide (FFT) afin d'identifier les fréquences caractéristiques des défauts mécaniques.

4.5.2.3 Contrôle du raspberry Pi

L'application intègre des boutons permettant de contrôler le système embarqué à distance :

- démarrage du Raspberry Pi ;
- arrêt du Raspberry Pi.

Les commandes sont transmises au Raspberry Pi via des requêtes HTTP envoyées à travers l'API REST.

4.5.2.4 Visualisation des signaux vibratoires

L'application affiche en temps réel les signaux vibratoires provenant des deux accéléromètres triaxiaux installés sur le banc d'essai.

Chaque capteur fournit trois axes de mesure :

$$X, Y, Z$$

Les données vibratoires sont représentées sous forme de courbes dynamiques permettant :

- la surveillance continue des vibrations ;
- l'observation des anomalies ;
- la détection des variations anormales ;
- l'analyse du comportement mécanique.

Les graphiques sont mis à jour automatiquement à intervalle régulier afin d'assurer une supervision temps réel.

4.5.2.5 Affichage de l'état de la machine

L'application affiche automatiquement l'état de fonctionnement de la machine selon le résultat de la classification intelligente.

Deux états principaux sont possibles :

- Machine normale
- Défaut détecté

Lorsque le système détecte une anomalie vibratoire, un message d'alerte apparaît sur l'interface afin d'avertir immédiatement l'utilisateur.

Le système est capable de détecter et d'identifier les six classes de défauts suivantes :

- fonctionnement normal
- déséquilibre (balourd)
- désalignement horizontal
- désalignement vertical
- défaut de roulement
- défaut de jeu mécanique

4.5.3 Fonctionnement global de l'application

Le fonctionnement global de l'application peut être résumé comme suit :

1. les capteurs vibratoires acquièrent les signaux de la machine
2. les données sont envoyées vers le Raspberry Pi 4
3. le Raspberry Pi traite les signaux vibratoires
4. les caractéristiques vibratoires sont extraites
5. le modèle IA réalise la classification
6. les résultats sont transmis à Streamlit
7. l'interface affiche les graphiques et le diagnostic

Cette architecture permet de réaliser une surveillance intelligente en temps réel avec une faible latence et une grande simplicité d'utilisation.

4.5.4 Avantages de l'application

L'application développée présente plusieurs avantages qui la rendent adaptée aux besoins de la surveillance vibratoire industrielle :

- Acquisition et analyse des signaux vibratoires en temps réel
- Interface graphique simple et intuitive développée avec Streamlit
- Intégration de plusieurs modèles d'intelligence artificielle (KNN, SVM et MLP)
- Possibilité de choisir entre l'analyse dans le domaine temporel ou fréquentiel
- Visualisation instantanée des signaux vibratoires
- Diagnostic automatique des défauts mécaniques
- Architecture basée sur une Raspberry Pi 4 à faible coût
- Facilité de déploiement et de maintenance

— Possibilité d'évolution vers des applications de maintenance prédictive

Grâce à ces caractéristiques, l'application constitue une solution complète permettant d'améliorer la surveillance de l'état des machines tournantes tout en réduisant les coûts liés aux équipements de diagnostic industriels traditionnels.

4.6 Conclusion

Dans ce chapitre, nous avons présenté le déploiement du système de diagnostic vibratoire sur la plateforme embarquée Raspberry Pi 4 ainsi que le développement de l'application web de supervision VibraTech Monitor.

Nous avons décrit l'environnement matériel utilisé, la configuration de la communication I2C avec les capteurs GY-LSM6DS3, et l'optimisation des modèles via la conversion au format TensorFlow Lite Float16, permettant une réduction de la taille des modèles d'environ 50% sans perte notable de précision.

L'application VibraTech Monitor offre une interface web intuitive permettant la visualisation en temps réel des signaux vibratoires, la sélection du modèle de classification et du domaine d'analyse, ainsi que l'affichage automatique de l'état de la machine et du type de défaut détecté.

Les résultats obtenus confirment la faisabilité d'une solution de maintenance prédictive embarquée, autonome et à faible coût, basée sur l'intelligence artificielle et les systèmes embarqués.

Conclusion Générale

En conclusion, ce travail a permis de développer un système intelligent de surveillance vibratoire destiné au diagnostic automatique des défauts mécaniques des machines tournantes. Cette étude s'inscrit dans le cadre de l'industrie intelligente où les techniques de maintenance prédictive occupent une place de plus en plus importante pour améliorer la disponibilité et la fiabilité des équipements industriels.

Dans un premier temps, une étude bibliographique a été réalisée afin de comprendre les principes de l'analyse vibratoire, les différents défauts mécaniques affectant les machines tournantes ainsi que les méthodes modernes de diagnostic basées sur l'intelligence artificielle. Cette étude a permis d'identifier les techniques les plus adaptées pour la détection des défauts de déséquilibre et de désalignement.

Par la suite, un prototype expérimental complet a été conçu et réalisé. Celui-ci est constitué d'un moteur électrique couplé à un générateur, de deux capteurs inertiels GY-LSM6DS3 placés de part et d'autre de l'accouplement, d'une carte Raspberry Pi 4 assurant l'acquisition des données ainsi que d'une application web développée sous Streamlit pour la supervision et le diagnostic en temps réel. Ce prototype a permis de reproduire différentes conditions de fonctionnement et de valider expérimentalement l'approche proposée.

Une procédure d'acquisition a ensuite été menée afin de constituer une base de données vibratoire réelle composée de 180 signaux répartis équitablement entre trois classes : fonctionnement normal, déséquilibre et désalignement. Les données acquises à partir des deux capteurs ont été prétraitées puis exploitées pour l'extraction de caractéristiques dans les domaines temporel et fréquentiel.

Les modèles de classification KNN, SVM et DNN ont été entraînés et évalués sur cette base de données. Les résultats obtenus ont montré de très bonnes performances de classification, particulièrement pour les modèles KNN et SVM qui ont atteint une précision de 97,14% dans le domaine temporel. Ces performances démontrent l'efficacité des méthodes d'intelligence artificielle pour le diagnostic automatique des défauts vibratoires.

Une application web intelligente nommée VibraTech Monitor a également été développée afin d'assurer la visualisation des signaux vibratoires, le contrôle de la plateforme embarquée, la sélection des modèles de classification ainsi que l'affichage en temps réel de l'état de la machine. Cette interface constitue un outil complet de supervision permettant une exploitation simple et intuitive du système développé.

Dans le but d'améliorer l'intégration embarquée, une optimisation des modèles a été réalisée. Le modèle DNN a été converti au format TensorFlow Lite et quantifié en Float16 afin de réduire sa taille mémoire et de faciliter son déploiement sur la Raspberry Pi 4 tout en conservant des performances satisfaisantes.

Les résultats obtenus confirment que l'association de l'analyse vibratoire, des systèmes embarqués et des techniques d'intelligence artificielle constitue une solution performante pour la surveillance conditionnelle et le diagnostic intelligent des machines tournantes. Le système développé offre une solution flexible, économique et adaptée aux besoins de la maintenance prédictive moderne.

Enfin, plusieurs perspectives peuvent être envisagées pour enrichir ce travail. Parmi celles-ci figurent l'intégration de modèles avancés de Deep Learning, l'utilisation de capteurs industriels à haute fréquence d'échantillonnage, l'étude d'autres types de défauts mécaniques tels que les défauts de roulements et d'engrenages, ainsi que le déploiement du système dans un environnement industriel réel afin de valider son fonctionnement dans des conditions d'exploitation plus complexes.

Bibliographie

- [1] Ahmed Belkacem and Youcef Meziane. Diagnostic des défauts des machines tournantes par analyse vibratoire. Mémoire de master, Université Djillali Liabès de Sidi Bel Abbès, Faculté de Technologie, Sidi Bel Abbès, Algérie, 2021.
- [2] Hichem TAIBI, Hamza SAKMECHE, Sidi Mohamed Amine KHIAT, Salah Eddine BENKABOUCHE, Abdelmadjid FLITTI, CoEncadreur Mr, and Djamal Eddine SAIDANI. Identification du défaut de balourd par analyse vibratoire.
- [3] Khaled Boughareb. Surveillance et diagnostic des machines tournantes par analyse vibratoire. Mémoire de master, Université Badji Mokhtar Annaba, Annaba, Algérie, 2019.
- [4] BOUKAMOUM Ibtissam and MALAOUI Sarra. Mémoire de master. *Prise en compte de l'environnement dans une exploitation a ciel ouvert cas de Bled El Hadba Bir El Ater*, 2016, 2015.
- [5] FELLAH AHMED. *Influence des fissures sur le comportement vibratoire des rotors*. PhD thesis, Université Abou bekr Belkaïd–TLEMEN, 2019.
- [6] Amine Zitouni and Mouloud Ourzane. *Etude comparative des indicateurs scolaires utilisés dans le diagnostic des machines tournantes*. PhD thesis, Université Mouloud Mammeri Tizi Ouzou, 2022.
- [7] R Keith Mobley. *An introduction to predictive maintenance*. Elsevier, 2002.
- [8] Mohammed BOUCHAREB and Aimane CHOUIHAT. *Maintenance des machines tournantes par diagnostic vibratoire*. PhD thesis, université Ghardaia, 2020.
- [9] Wikipédia. Jeu (mécanique). [https://fr.wikipedia.org/wiki/Jeu_\(mécanique\)](https://fr.wikipedia.org/wiki/Jeu_(mécanique)), 2026. Consulté le 7 février 2026.
- [10] Yaguo Lei, Bin Yang, Xinwei Jiang, Feng Jia, Naipeng Li, and Asoke K Nandi. Applications of machine learning to machine fault diagnosis : A review and roadmap. *Mechanical systems and signal processing*, 138 :106587, 2020.
- [11] Andrew K. S. Jardine, Daming Lin, and Dragan Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7) :1483–1510, 2006.
- [12] Thomas W. Rauber, André Boldt Ramos, and Flávio Lopes Pagliosa. MAFAULDA – Machinery Fault Database. <http://www02.smt.ufrj.br/~offshore/mfs/>, 2016. Universidade Federal do Rio de Janeiro.

-
- [13] Robert B. Randall and Jérôme Antoni. Rolling element bearing diagnostics — a tutorial. *Mechanical Systems and Signal Processing*, 25(2) :485–520, 2011.
 - [14] A. Davies. *Handbook of Condition Monitoring*. Springer, 2012.
 - [15] D. Dyer and R. M. Stewart. Detection of rolling element bearing damage by statistical vibration analysis. *Journal of Mechanical Design*, 100(2) :229–235, 1978.
 - [16] Alan V. Oppenheim and Ronald W. Schaffer. *Discrete-Time Signal Processing*. Pearson, Upper Saddle River, États-Unis, 3 edition, 2009.
 - [17] Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The Elements of Statistical Learning*. Springer, 2009.
 - [18] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
 - [19] Mohammed Bouchareb and Aimane Chouihat. Maintenance des machines tournantes par diagnostic vibratoire. Mémoire de master, Université de Ghardaïa, Ghardaïa, Algérie, 2020.
 - [20] Stanislav Ziaran. Technical diagnostics and vibrodiagnostics of rotating machines. *Technická Diagnostika*, 2013.
 - [21] T. W. Anderson. *An Introduction to Multivariate Statistical Analysis*. Wiley, New York, États-Unis, 3 edition, 2003.
 - [22] Ahmed Zakaria Benadda and Noureddine Abdessadok. Approche basée sur l’intelligence artificielle pour la maintenance prédictive dans un environnement industriel. Mémoire de master, Université d’Oran 2 Mohamed Ben Ahmed, Institut de Maintenance et de Sécurité Industrielle, Oran, Algérie, 2025.
 - [23] Richard E. Bellman. *Adaptive Control Processes : A Guided Tour*. Princeton University Press, Princeton, États-Unis, 1961.
 - [24] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine Learning*, 20(3) :273–297, 1995.
 - [25] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, et al. Scikit-learn : Machine learning in Python. *Journal of Machine Learning Research*, 12 :2825–2830, 2011.
 - [26] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. MIT Press, Cambridge, États-Unis, 2016.
 - [27] Vinod Nair and Geoffrey E. Hinton. Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning (ICML)*, pages 807–814, 2010.
 - [28] David E. Rumelhart, Geoffrey E. Hinton, and Ronald J. Williams. Learning representations by back-propagating errors. *Nature*, 323 :533–536, 1986.
 - [29] Diederik P. Kingma and Jimmy Ba. Adam : A method for stochastic optimization. *arXiv preprint arXiv :1412.6980*, 2014.

- [30] David M. W. Powers. Evaluation : From precision, recall and f-measure to roc. *Journal of Machine Learning Technologies*, 2011.
- [31] Martín Abadi et al. TensorFlow : Large-scale machine learning on heterogeneous systems. <https://www.tensorflow.org>, 2015.