REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE Dr YAHIA FARES DE MEDEA



Faculté de **T**echnologie
Département du **G**énie **E**lectrique

Mémoire de fin d'études de Master

Filière : Electronique

Spécialité : Instrumentation

Développement d'un Système Embarqué Intelligent pour la Détection des Défauts dans les Pompes Centrifuges

Présenté par :

SAIDI Madani Amine

LEBOUKH Aboubakr

Proposé et encadré par :

Dr. BENGHERBIA Billel

TOBBAL Abdelhafid

Promotion 2025

Remerciements

Avant tout, nous exprimons notre louange et notre gratitude à ALLAH le Tout-Puissant pour nous avoir accordé la volonté, la santé, la force et la patience nécessaires à la réalisation de ce travail.

Nous adressons nos remerciements les plus sincères à nos chers parents pour leur soutien constant, leur encouragement et leur présence indéfectible tout au long de ce parcours.

Nos remerciements vont également à nos encadreurs, Dr. BENGHERBIA Billel et M. TOBBAL Abdelhafid, pour la qualité de leur accompagnement, leur disponibilité, leur bienveillance ainsi que pour la richesse de leurs conseils, qui ont grandement contribué à la réussite de ce mémoire.

Nous tenons enfin à remercier chaleureusement les membres du jury pour l'honneur qu'ils nous font en acceptant d'évaluer notre travail.

Dédicaces

À mes parents,

Pour leur amour, leur patience et leur soutien indéfectible tout au long de mon parcours.

À ma fratrie,

Avec toute la reconnaissance pour ce que nous partageons.

À mes amis et collègues,

Pour leur encouragement, leur solidarité et leur soutien constant

À mes professeurs,

Pour leur dévouement, la qualité de leur enseignement et leur accompagnement bienveillant tout au long de ma formation.

Ce mémoire est le reflet de tous vos apports. Je vous le dédie avec toute ma reconnaissance.

SAIDI Madani Amine 

Dédicaces

À ma mère,

Pour son soutien constant, sa tendresse et ses encouragements tout au long de ce parcours.

À mes frères et ma sœur,

Pour les liens qui nous unissent et leur présence, même discrète, dans ma vie.

À mon épouse et à mes enfants,

Pour leur amour, leur patience et la joie qu'ils apportent, qui m'ont donné la force d'avancer chaque jour.

À mes amis et collègues,

Pour leur solidarité, leurs conseils et leur accompagnement tout au long de cette aventure.

À mes professeurs,

Pour leur engagement, la qualité de leur enseignement et leur accompagnement bienveillant durant cette formation.

Ce mémoire est le fruit de tous vos apports. Je vous le dédie avec toute ma gratitude.

LEBOUKH Aboubakr 

ملخص

في هذا العمل، نقدم طريقة للتشخيص الذكي لأعطال المضخات الطردية تعتمد على تحليل الاهتزازات. يتم تحليل الإشارات المُكتسبة باستخدام التحويل المويجي المتقطع(DWT) ، ثم استخراج الخصائص من الاشارات الفرعية الناتجة. تم تطوير عدة نماذج من الذكاء الاصطناعي ومقارنتها لتصنيف الأعطال، وقد تم اختيار الشبكة العصبية الاصطناعية (ANN) لما تقدمه من توازن بين الدقة والتعقيد. تم تنفيذ هدا النظام بالكامل، بما في ذلك المعالجة المسبقة والتصنيف المحلي ونقل النتائج، على لوحة .ESP32 كما تم تطوير واجهة المستخدم HMI باستخدام Node-RED لعرض النتائج. وقد أكدت الاختبارات التي أُجريت موثوقية النظام المُدمج، حيث أظهر أداءً مماثلاً للتنفيذ على الحاسوب.

الكلمات المفتاحية : التشخيص الذكي، المضخات الطردية، تحليل الاهتزازات، DWT, ANN ، تصنيف الأعطال، واجهة المستخدم

Résumé

Dans ce travail, nous présentons une méthode de diagnostic intelligent des défauts des pompes centrifuges basée sur l'analyse des vibrations. Les signaux acquis sont décomposés par transformée en ondelettes discrète (DWT), puis des caractéristiques sont extraites à partir des sous-bandes obtenues. Plusieurs modèles d'intelligence artificielle ont été développés et comparés pour la classification des défauts, parmi lesquels un réseau de neurones artificiel (ANN) a été retenu pour son bon compromis entre précision et complexité. Le système complet, incluant le prétraitement, la classification locale et la transmission des résultats, a été implémenté sur une carte ESP32. Une interface HMI a été développée sous Node-RED pour la visualisation. Les tests réalisés ont confirmé la fiabilité du système embarqué, avec des performances comparables à une implémentation sur PC.

Mots clés : Diagnostic intelligent, Pompes centrifuges, Analyse des vibrations, DWT, ANN, Classification des défauts, Interface HMI

Abstract

In this work, we present an intelligent fault diagnosis method for centrifugal pumps based on vibration analysis. Acquired signals are decomposed using Discrete Wavelet Transform (DWT), and statistical features are extracted from the resulting sub-bands. Several artificial intelligence models were developed and compared for fault classification, with an Artificial Neural Network (ANN) selected for its balance between accuracy and computational efficiency. The complete system, including preprocessing, local classification, and result transmission, was implemented on an ESP32 board. An HMI interface was developed using Node-RED for visualization. Experimental tests confirmed the reliability of the embedded system, achieving performance comparable to a PC-based implementation.

Keys words : Intelligent fault diagnosis, Centrifugal pumps, Vibration analysis, DWT, ANN, Fault classification, HMI interface

Table des matières

Résumé iv
Table des matières v
Liste des figures ix
Liste des tableaux xi
Liste des nomenclatures xii
Introduction générale 1
Chapitre I : Pompes centrifuges, défauts et analyses vibratoires 1
1 Introduction 2
2 Les pompes centrifuges 2
2.1 Définition 2
2.2 Composants d'une pompe centrifuge 2
2.3 Principe de fonctionnement 3
2.4 Types et applications industrielles 4
3 Défaillances courantes des pompes centrifuges 6
3.1 Cavitation 6
3.2 Usure des roulements 7
3.3 Usure et endommagement de l'impulseur 7
3.4 Désalignement 7
3.5 Défaut de balourd 8
3.6 Autres défauts 8
4 Politiques de maintenance 9
4.1 Maintenance corrective 9
4.2 Maintenance préventive systématique 9
4.3 Maintenance préventive conditionnelle 9
4.4 Maintenance prédictive 9
4.5 Maintenance améliorative 10
5 Surveillance et diagnostic par analyse des vibrations 10
5.1 Définition d'une vibration 10
5.1.1 Fréquence 10
5.1.2 Amplitude 11
5.1.3 Nature des vibrations 11
5.2 Capteurs de vibration 12
5.2.1 Les proximètres 13
5.2.2 Les vélocimètres 14
5.2.3 Les accéléromètres 14
5.3 Techniques de surveillance 16
5.3.1 Indicateurs scalaires en bande large (niveau global) 16
5.3.2 Indicateurs scalaires en bande étroite 17
5.3.3 Analyse spectrale par comparaison à un gabarit 17

5.3.4 Indicateurs de défauts impulsionnels (roulements) 18
5.4 Signatures vibratoires des différentes défaillances 18
5.4.1 Signature vibratoire liée à la cavitation 19
5.4.2 Signatures vibratoires des défauts de roulements 19
5.4.3 Signature vibratoire d'un impulseur endommagé 21
5.4.4 Signature vibratoire d'un déséquilibre dynamique 23
5.4.5 Signatures vibratoires d'autres anomalies 23
6 Conclusion 24
Chapitre II : Méthodes de traitement vibratoire appliquées au diagnostic intelligent 25
1 Introduction 26
2 Acquisition et prétraitement des signaux vibratoires 26
2.1 Chaine d'acquisition 26
2.1.1 Capteur 27
2.1.2 Conditionneur de signal 27
2.1.3 Amplificateur 28
2.1.4 Filtre 28
2.1.5 Multiplexeur 29
2.1.6 Convertisseur analogique numérique 29
2.1.7 Calculateur et control 30
2.2 Système d'acquisition (DAQ) 30
2.3 Ordinateur et logiciel de traitement 31
2.3.1 Traitement et analyse des données 31
2.3.2 Environnement logiciel 31
2.4 Stockage et base de données 31
2.5 Interface utilisateur et exploitation 32
3 Traitement du signal 32
3.1 Analyse de Fourier 32
3.1.1 Série de Fourier 32
3.1.2 Transformé de Fourier 32
3.1.3 Transformé de Fourier Discrète 33
3.2 Analyse temps-fréquence 33
3.2.1 Transformée de Fourier à court terme (STFT) 33
3.2.2 Transformée de Fourier à court terme Discrète (STFTD) 33
3.3 Transformé en ondelettes 34
3.3.1 Définition d'une ondelette 35
3.3.2 Transformée en ondelettes continue (CWT) 36
3.3.3 Transformée en ondelettes discrète 36
4 Intelligence artificielle 38
4.1 Définition de l'IA 39
4.2 Machine Learning 40
4.2.1 Apprentissage supervisé 40
4.2.2 Apprentissage non supervisé 41
4.2.3 Apprentissage par renforcement (Reinforcement Learning) 42

4.2.4 Apprentissage Semi-Supervisé (Semi-Supervised Learning) 42
4.3 Théorie des algorithmes d'IA 42
4.3.1 Perceptron 42
4.3.2 Réseau de neurones artificiels 43
4.3.3 Fonctions d'activation 44
4.3.4 Étapes d'apprentissage des réseaux de neurones 45
4.3.5 Surapprentissage et sous-apprentissage 46
4.3.6 Répartition des données 46
4.3.7 Arbres de décision et forêts aléatoires (Decision Trees & Random Forest) 47
4.3.8 XGBoost 48
4.3.9 Machines à Vecteurs de Support (SVM) (SVC) 48
4.3.10 Autres modèles d'intelligence artificielle 49
4.4 Préparation des Données 49
4.4.1 Normalisation des données 49
4.4.2 Encodage des étiquettes (LabelEncoder) 50
4.5 Évaluation des Modèles développés 50
4.5.1 Courbe d'apprentissage (Learning curve) 50
4.5.2 Matrice de confusion 51
4.5.3 Exactitude (Accuracy) 52
4.5.4 Précision 52
4.5.5 Rappel (recall) 52
4.5.6 Score F1 52
4.5.7 Moyenne macro 52
4.5.8 Moyenne pondérée 52
5 Conclusion 53
Chapitre III : Expérimentation, analyse des résultats et implémentation 54
1 Introduction 55
2 Présentation de la base de données 55
2.1 Origine et source de la base de données 55
2.2 Dispositif expérimental 55
2.2.1 Banc d'essai 56
2.2.2 Méthodes de mesure 57
2.2.3 Procédure de mesure 58
2.3 Types de défauts simulés 59
3 Environnement Logiciel 60
4 Prétraitement des données 61
4.1 Préparation et extraction des caractéristiques 61
4.2 Normalisation, encodage et séparation des données 63
5 Test expérimentaux et validations des modèles 63
5.1 Choix des modèles 63
5.2 Description de l'architecture des modèles 64
5.3 Entraînement des modèles 65
5.4 Validation des modèles 67

6 Analyses des résultats 67
6.1 Résultats de la pompe 2 68
6.2 Résultats de la pompe 4 70
6.3 Comparaison entre modèles 71
6.4 Résultats de validation des modèles 72
7 Implémentation sur un système embarqué 72
7.1 Présentation du microcontrôleur ESP32 73
7.1.1 Caractéristiques techniques 73
7.1.2 Capacités de connectivité 74
7.2 Environnement de développement 74
7.3 Déploiement du modèle ANN sur ESP32 75
7.4 Communication des données avec MQTT 76
7.5 Création de l'interface HMI 76
7.5.1 Présentation de Node-RED et son rôle dans l'HMI 76
7.5.2 Création de l'HMI 77
7.6 Schéma global du système 78
7.6.1 Fonctionnement du système embarqué 78
7.6.2 Fonctionnement du code Node-Red 79
7.7 Tests et validation 80
7.8 Prototype 81
8 Conclusion 82
Conclusion Générale 83
Références 84
Annexes 87
Annexe A 88
Annexe B 89
Annexe C 90
Annexe D 91
Annexe E 92
Annexe F 93
Annexe G 94
Annexe H 95
Annexe I 96
Annexe J 97
Annexe K 98
Annexe L 99

Liste des figures

Figure I-1 : Pompe centrifuge monocellulaire ---------- 3
Figure I-2 : Principe de fonctionnement d'une pompe centrifuge ---------- 4
Figure I-3 : Exemple d'usure des différents composants d'un roulement ---------- 7
Figure I-4 : Endommagement d'un impulseur causé par la cavitation ---------- 7
Figure I-5 : Principaux défauts d'alignement ---------- 8
Figure I-6 : Amplitudes d'un signal vibratoire ---------- 11
Figure I-7 : Nature d'une vibration ---------- 12
Figure I-8 : Exemples de proximètres ---------- 13
Figure I-9 : Schéma de principe d'un vélocimètre [6] ---------- 14
Figure I-10 : Exemples d'accéléromètres ---------- 15
Figure I-11 : Principe de fonctionnement d'un accéléromètre piézoélectrique [6] ---------- 15
Figure I-12 : Equivalences électriques d'un accéléromètre [6] ---------- 16
Figure I-13 : Surveillance spectrale avec alarme sur dépassement de gabarit ---------- 17
Figure I-14 : Spectre des différents défauts de roulements ---------- 20
Figure I-15 : Spectre d'un signal vibratoire avec un défaut BPFI ---------- 21
Figure I-16 : Spectre vibratoire d'un impulseur endommagé ---------- 22
Figure II-1: Emplacement de la chaîne d'acquisition dans le processus de mesure et de régulation ---------- 26
Figure II-2 : Schéma d'une chaîne d'acquisition type18 ---------- 27
Figure II-3 : Diagramme de Bode d'un filtre butterworth de 5ème ordre ---------- 28
Figure II-4 : Schéma de principe d'un échantillonneur bloqueur ---------- 29
Figure II-5 : Exemple de quantification ---------- 29
Figure II-6: Carte d'acquisition de données multi-voies NI USB-4432 ---------- 30
Figure II-7 :Spectrogramme (STFT) ---------- 34
Figure II-8 : Translation et dilatation des ondelettes ---------- 35
Figure II-9 : Transformée en ondelettes (CWT) ---------- 36
Figure II-10 : Décomposition par bancs de filtres ---------- 37
Figure II-11 : Décomposition par algorithme de Mallat ---------- 37
Figure II-12: Signal Chirp décomposé par ondelette discrète ---------- 38
Figure II- 13 : IA, ML, DL ---------- 39
Figure II-14 : Types d'algorithmes d'apprentissage automatique ---------- 40
Figure II-15 : Apprentissage supervisé : entraînement sur des entrées/étiquettes pour prédire des entrées inconnue ---------- 41
Figure II-16 : Apprentissage non-supervisé : regroupement automatique des entrées sans étiquettes ---------- 41
Figure II-17 : Neurone Biologique ---------- 42
Figure II-18 : Perceptron (neurone artificiel) ---------- 43

Figure II-19 : Architecture d'un réseau de neurones artificiels ---- *43*
Figure II-20 : Fonctions d'activation ---- *45*
Figure II-21 : Arbre de décision (decision tree) ---- *47*
Figure II-22 : Random Forest vs XGBoost ---- *48*
Figure II-23 : SVM ---- *48*
Figure II-24 : Courbe d'apprentissage d'un réseau ANN ---- *50*
Figure II-25 : Exemple de matrice de confusion ---- *51*
Figure III-1 : Banc d'essai ((1) Moteur électrique, (2) Pompe, (3) Entrée d'eau principale, (4) Sortie d'eau principale, (5) Vanne de décharge, (6) Variateur de fréquence (VFD)) ---- *56*
Figure III-2 : Pompe NK 80-250/270 ---- *57*
Figure III-3 : Accéléromètre et carte d'acquisition utilisés ---- *57*
Figure III-4 : Emplacements de mesure des vibrations : les flèches indiquent la position et la direction, tandis que les points représentent une direction perpendiculaire au schéma ---- *58*
Figure III-5 : Diagramme d'acquisition des données ---- *58*
Figure III-6 : Structure des fichiers de la base de données ---- *59*
Figure III-7 : L'exécution du code d'extraction des caractéristiques avec MATLAB ---- *60*
Figure III-8 : L'exécution du code d'apprentissage automatique sur Jupyter Lab ---- *61*
Figure III-9 : Diagramme de prétraitement des données ---- *62*
Figure III-10 : Architecture ANN ---- *64*
Figure III-11 : Architecture DNN ---- *65*
Figure III-12 : Exemple de structure des fichiers à la fin d'apprentissage ---- *66*
Figure III-13: Diagramme fonctionnel de l'ESP32-S3 ---- *73*
Figure III-14 : Interface Arduino IDE ---- *74*
Figure III-15 : Etapes de conversion du modèle ANN en fichier C ---- *75*
Figure III-16 : Architecture de communication MQTT ---- *76*
Figure III-17: Programme Node-Red ---- *77*
Figure III-18 : Interface Homme Machine développée ---- *77*
Figure III-19 : diagramme de fonctionnement du code implémenté ESP32 ---- *78*
Figure III-20 : diagramme de fonctionnement du code Node-Red ---- *79*
Figure III-21: Validation du modèle ANN embarqué ---- *80*
Figure III-22 : Vérification des données transmises avec MQTT explorer ---- *81*
Figure III-23 : Premier prototype réalisé sur platine d'expérimentation ---- *82*

Liste des tableaux

Tableau I-1 : Classification des pompes centrifuges ---------- *4*
Tableau I-2 : Plages de fréquences générées par la cavitation et leurs sources physiques ------- *19*
Tableau I-3 : Signatures vibratoire d'autres anomalies ---------- *23*
Tableau III-1 : Détails des moteurs électriques utilisés ---------- *56*
Tableau III-2 : Caractéristiques des pompes utilisées ---------- *56*
Tableau III-3 : Défauts induits6 ---------- *59*
Tableau III-4 : Architecture des modèles ANN et DNN ---------- *64*
Tableau III-5 : Architecture des modèles Decision Tree et Random Forest ---------- *65*
Tableau III-6 : Architecture du modèle XGBoost ---------- *65*
Tableau III-7 : Architecture du modèle SVM ---------- *65*
Tableau III-8: Les quatre meilleurs résultats obtenus avec l'énergie uniquement ---------- *68*
Tableau III-9 : Les quatre meilleurs résultats obtenus en combinant l'énergie avec le facteur de crête ---------- *68*
Tableau III-10: Les quatre meilleurs résultats obtenus en combinant l'énergie avec le kurtosis - *69*
Tableau III-11 : Les quatre meilleurs résultats obtenus en combinant l'énergie avec la valeur efficace (RMS) ---------- *69*
Tableau III-12 : Les quatre meilleurs résultats obtenus avec la valeur efficace uniquement ---- *69*
Tableau III-13 : Les quatre meilleurs résultats obtenus en combinant la valeur efficace avec le kurtosis ---------- *69*
Tableau III-14: Les 10 meilleurs résultats obtenus avec l'énergie uniquement ---------- *70*
Tableau III-15: Les 10 meilleurs résultats obtenus avec la valeur efficace uniquement ---------- *70*
Tableau III-16: Meilleurs modèles de chaque type ---------- *71*

Liste des nomenclatures

ADC : Analog to Digital Converter (Convertisseur Analogique-Numérique)

AI : Intelligence Artificielle

ANN : Artificial Neural Network (Réseau de Neurones Artificiels)

BPF : Blade Pass Frequency (Fréquence de Passage des Pales)

BPFI : Ball Pass Frequency Inner race (Fréquence de Passage des Billes sur la Bague Intérieure)

BPFO : Ball Pass Frequency Outer race (Fréquence de Passage des Billes sur la Bague Extérieure)

BSF : Ball Spin Frequency (Fréquence de Rotation des Billes)

CAN : Convertisseur Analogique-Numérique

CC0 : Creative Commons Zero

CNN : Convolutional Neural Network (Réseau de Neurones à Convolutions)

CPM : Cycles Par Minute

CWT : Continuous Wavelet Transform (Transformée en Ondelettes Continue)

DAC : Digital to Analog Converter (Convertisseur Numérique-Analogique)

DAQ : Data Acquisition (Acquisition de Données)

DFT : Discrete Fourier Transform (Transformée de Fourier Discrète)

DNN : Deep Neural Network (Réseau de Neurones Profond)

DWT : Discrete Wavelet Transform (Transformée en Ondelettes Discrète)

FTF : Fundamental Train Frequency (Fréquence Fondamentale de la Cage)

GAN : Generative Adversarial Network (Réseau Antagoniste Génératif)

GPIO : General Purpose Input/Output (Entrée/Sortie à Usage Général)

HMI : Human-Machine Interface (Interface Homme-Machine)

I2C : Inter-Integrated Circuit (Circuit Inter-Intégré)

IA : Intelligence Artificielle

IDE : Integrated Development Environment

JSON : JavaScript Object Notation (Notation d'Objet JavaScript)

LCD : Liquid Crystal Display (Affichage à Cristaux Liquides)

MATLAB : MATrix LABoratory

MCU : Microcontroller Unit

ML : Machine Learning (Apprentissage Automatique)

MQTT : Message Queuing Telemetry Transport.

NPSH : Net Positive Suction Head (Hauteur Nette d'Aspiration Positive)

PSRAM : Pseudo Static Random Access Memory (Mémoire Vive Pseudo-Statique)

PWM : Pulse Width Modulation (Modulation de Largeur d'Impulsion)

RAM : Random Access Memory.

ReLU : Rectified Linear Unit (Unité Linéaire Rectifiée)

RMS : Root Mean Square (Valeur Efficace)

RNN : Recurrent Neural Network (Réseau de Neurones Récurrents)

RPM : Revolutions Per Minute (Tours Par Minute)

SoC : System on a Chip.

SPI : Serial Peripheral Interface (Interface Périphérique Série)

SRAM : Static Random Access Memory (Mémoire Vive Statique)

SVG : Scalable Vector Graphics (Graphiques Vectoriels Redimensionnables)

SVM : Support Vector Machine (Machine à Vecteurs de Support)

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

UART : Universal Asynchronous Receiver-Transmitter (Récepteur-Transmetteur Asynchrone Universel)

VFD : Variable Frequency Drive (Variateur de Fréquence)

XGBoost : eXtreme Gradient Boosting (Algorithme d'Optimisation par Gradient)

Introduction générale

Les pompes centrifuges constituent des dispositifs essentiels dans de nombreux domaines industriels, où elles jouent un rôle central dans le transport des fluides au sein d'infrastructures. Toutefois, ces systèmes sont soumis à diverses défaillances susceptibles d'entraîner des arrêts de production, des pertes financières considérables et des risques accrus pour la sécurité des installations.

Les approches traditionnelles de maintenance, principalement fondées sur des inspections périodiques et des interventions correctives, présentent des limites notables en termes d'efficacité et de coût, notamment en raison des arrêts fréquents de production. Face à ces contraintes, l'émergence de stratégies plus avancées, notamment la maintenance préventive conditionnelle et la maintenance prédictive, constituent des alternatives prometteuses. Dans ce cadre, l'analyse vibratoire s'impose comme un outil performant pour la surveillance des pompes centrifuges, permettant l'identification précoce des anomalies avant qu'elles n'évoluent en défaillances critiques. L'intégration des avancées récentes en intelligence artificielle à cette approche améliore considérablement la précision et la rapidité du diagnostic.

Dans ce contexte, le présent mémoire vise à élaborer une approche fondée sur l'analyse des signaux vibratoires afin de détecter et classifier les défauts affectant les pompes centrifuges. En s'appuyant sur des techniques de l'intelligence artificielle, l'objectif est de concevoir un modèle performant capable d'identifier automatiquement les anomalies en exploitant les données vibratoires collectées. Pour ce faire, une méthodologie rigoureuse sera mise en œuvre, intégrant l'acquisition des données, le traitement du signal, la sélection des caractéristiques pertinentes et le développement d'algorithmes d'apprentissage.

Afin d'apporter une réponse à cette problématique, le premier chapitre de ce mémoire sera consacré à une revue de la littérature portant sur le fonctionnement des pompes centrifuges et sur les méthodes de diagnostic des défauts, avec une attention particulière portée à l'analyse vibratoire. Ce chapitre établira les bases nécessaires à la compréhension des phénomènes mécaniques liés aux pompes ainsi qu'aux indicateurs vibratoires pertinents pour la détection des anomalies.

Le deuxième chapitre traitera des techniques de traitement des signaux vibratoires et introduira les concepts fondamentaux de l'intelligence artificielle appliquée à ce domaine. Il abordera les méthodes mathématiques d'extraction de caractéristiques ainsi que le développement des algorithmes d'IA, en vue d'identifier les défauts à partir des signaux collectés.

Enfin, le troisième chapitre sera dédié à la phase expérimentale, incluant la mise en œuvre, l'évaluation des performances des modèles développés, et la réalisation d'un prototype fonctionnel. Cette dernière étape permettra de valider l'efficacité de l'approche proposée dans un cadre pratique de détection et de classification des défauts.

Chapitre I

Pompes centrifuges, défauts et analyses vibratoires

1 Introduction

Les pompes centrifuges, comme toute machine tournante, voient leur intégrité mécanique menacée par des défaillances aux conséquences souvent critiques, allant de simples baisses de performance à des arrêts imprévus, voire des dommages importants sur l'ensemble du système. Parmi les signes précurseurs des anomalies, les vibrations jouent un rôle clé, elles permettent d'identifier des défauts tels que l'usure des roulements, l'endommagement de l'impulseur, le désalignement ou encore la cavitation, qui sont parmi les principales causes de défaillance des pompes centrifuges.

Dans ce contexte, l'analyse vibratoire émerge comme un outil privilégié pour diagnostiquer ces anomalies avant qu'elles ne dégénèrent en pannes majeures.

Ce chapitre se penchera d'abord sur les pompes centrifuges, en présentant leurs composants, leur principe de fonctionnement et les différents types existants. Il abordera ensuite les défauts les plus courants, les politiques de maintenance associées, puis la surveillance et le diagnostic de ces anomalies par analyse vibratoire.

2 Les pompes centrifuges

2.1 Définition

Les pompes centrifuges sont des turbomachines conçues pour transporter des liquides en leur conférant une certaine pression et un débit défini. Elles reposent sur un principe hydrodynamique où l'énergie transmise au fluide dépend directement de la vitesse de rotation de l'impulseur [1].

2.2 Composants d'une pompe centrifuge

Le fonctionnement d'une pompe centrifuge repose sur plusieurs composants clés : un carter en volute, un arbre, un système de palier et un impulseur monté en porte-à-faux sur l'arbre et entraîné par un moteur via un accouplement [1]. Comme le montre la figure I-1, une pompe centrifuge est composée de plusieurs éléments essentiels :

- **Buse d'aspiration** : Point d'entrée du fluide dans la pompe.
- **Impulseur (roue)** : Élément tournant qui transmet de l'énergie au fluide en augmentant sa vitesse.
- **Aube ou pale** : Parties de l'impulseur qui guident et accélèrent le fluide.
- **Œil de l'impulseur** : Zone centrale de l'impulseur où le fluide est aspiré avant d'être accéléré.

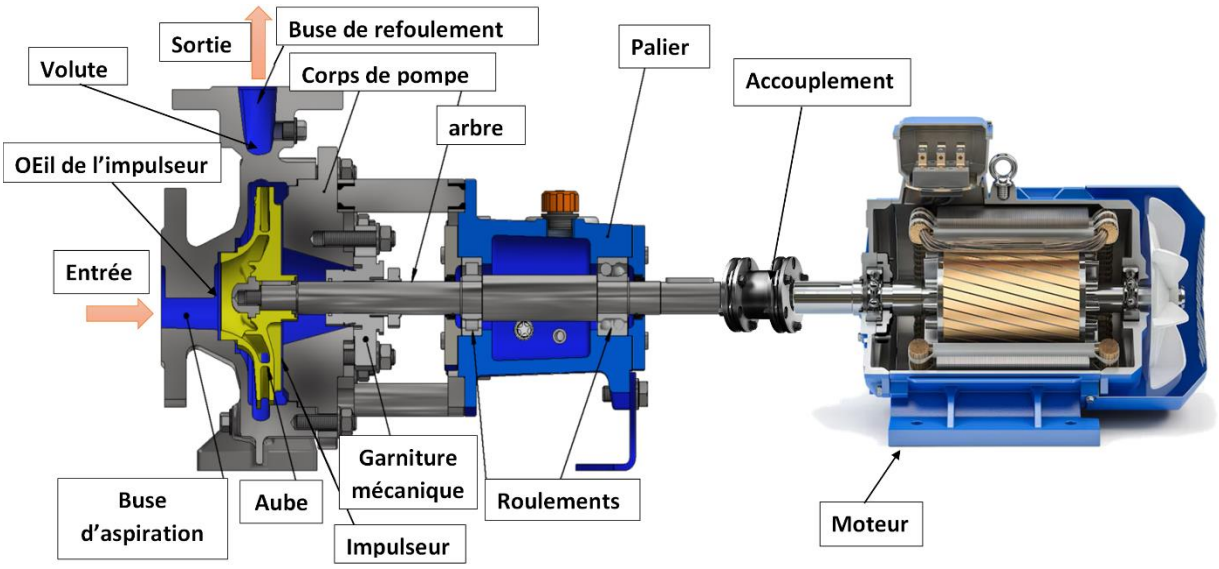


Figure I-1 : Pompe centrifuge monocellulaire

- **Volute (ou diffuseur)** : Chambre en spirale qui convertit l'énergie cinétique du fluide en pression en augmentant progressivement la section d'écoulement.
- **Arbre** : Axe mécanique qui supporte et entraîne l'impulseur en rotation.
- **Palier** : Supporte l'arbre et réduit les frottements pour assurer un bon fonctionnement mécanique.
- **Garniture mécanique ou presse-étoupe** : Assure l'étanchéité entre l'arbre et le corps de pompe pour éviter les fuites.
- **Corps de pompe** : Enveloppe extérieure qui contient et protège l'ensemble des composants internes de la pompe.
- **Moteur** : Fournit l'énergie nécessaire pour entraîner l'impulseur et assurer l'aspiration et le refoulement du fluide.
- **Buse de refoulement** : Point de sortie du fluide après son passage dans la pompe, où il est expulsé sous pression.

2.3 Principe de fonctionnement

Le fluide entre dans la pompe par la buse d'aspiration lors de la phase d'aspiration et atteint l'œil de l'impulseur. Pendant la phase d'accélération, l'impulseur tournant à grande vitesse piège le fluide entre ses pales et lui transmet de l'énergie, augmentant ainsi sa vitesse et transformant une partie de cette énergie en énergie cinétique. Sous l'effet de la force centrifuge, le fluide est projeté vers l'extérieur, où il entre dans la phase de pressurisation. En pénétrant dans la volute, la section d'écoulement s'élargit progressivement, ce qui permet de ralentir le fluide et de convertir

son énergie cinétique en pression. Enfin, lors de la phase de refoulement, le fluide est expulsé sous pression par la buse de refoulement [2] [3].

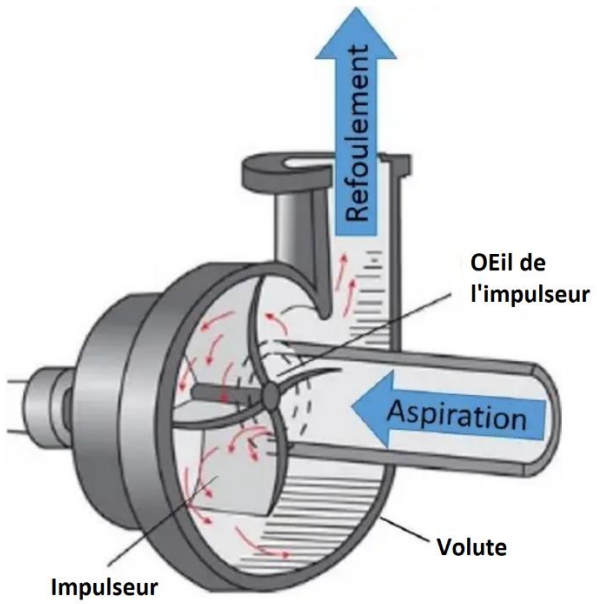


Figure I-2 : Principe de fonctionnement d'une pompe centrifuge

2.4 Types et applications industrielles

Les pompes centrifuges se classent en plusieurs types en fonction de leur conception, de leur usage et de leurs caractéristiques spécifiques [1]. Le tableau I-1 résume les principaux types:

Tableau I-1 : Classification des pompes centrifuges

Critère de classification	**Types de pompes centrifuges**	**Description et applications**
Principe de fonctionnement	Pompes centrifuges	Utilisent une roue pour accélérer le fluide et convertir l'énergie cinétique en pression.
	Pompes à canal latéral	Idéales pour les mélanges liquide/gaz, elles possèdent des caractéristiques d'auto-amorçage.
	Pompes volumétriques	Bien que différentes, elles sont utilisées dans certaines applications nécessitant un débit contrôlé.
Propriétés spécifiques	Pompes auto-amorçantes	Capables d'évacuer l'air des conduites et de fonctionner sans assistance externe.
Direction du flux à la sortie de la roue	Pompes radiales	Le fluide est projeté perpendiculairement à l'axe de rotation, permettant des pressions élevées.
	Pompes semi-axiales	Le fluide est projeté sous un angle intermédiaire, combinant débit et pression.
	Pompes axiales	Le fluide s'écoule parallèlement à l'axe, adapté aux grands débits avec faible pression.

Type de collecteur	Pompes à volute	Une chambre en spirale guide le fluide et optimise la conversion d'énergie.
	Pompes à diffuseur	Utilisent des ailettes fixes pour améliorer le rendement et réduire les turbulences.
Conception (Nombre de roues)	Pompes à un seul étage	Possèdent une seule roue, adaptées aux applications de faible pression.
	Pompes multicellulaires	Possèdent plusieurs roues en série pour atteindre des pressions plus élevées.
Conception (Aspiration)	Pompes à simple aspiration	L'eau entre par une seule ouverture, adaptées aux applications standard.
	Pompes à double aspiration	L'eau entre des deux côtés de la roue, équilibrant les forces hydrauliques et augmentant l'efficacité.
Conception (Disposition de l'arbre)	Pompes horizontales	Utilisées dans l'industrie pour leur facilité d'entretien et leur installation stable.
	Pompes verticales	Adaptées aux espaces restreints et aux puits profonds, avec un arbre vertical.
	Pompes submersibles	Complètement immergées, idéales pour les eaux usées et l'assèchement des puits.
Conception (Sans garniture mécanique)	Pompes à entraînement magnétique	Transmission du couple par champ magnétique, évitant les fuites et adaptées aux fluides dangereux.
	Pompes à moteur encapsulé (canned motor pumps)	Moteur et pompe hermétiquement scellés, évitant toute fuite et réduisant l'entretien.
Fluide transporté	Pompes pour eau potable	Conformes aux normes sanitaires pour le transport d'eau propre.
	Pompes pour alimentation de chaudières	Supportent des températures et pressions élevées, essentielles dans les centrales énergétiques.
	Pompes pour condensat	Utilisées pour récupérer la vapeur d'eau et éviter la cavitation dans les circuits de chauffage.
	Pompes pour eaux usées	Conçues pour transporter des fluides chargés en matières solides et liquides contaminés.
	Pompes pour pulpe et boues	Employées dans l'industrie minière et papetière pour transporter des fluides abrasifs.
	Pompes pour fluides corrosifs	Fabriquées en matériaux résistants aux acides, bases et solvants chimiques.
	Pompes pour huiles et hydrocarbures	Utilisées dans les raffineries et l'industrie pétrolière pour le transport de liquides inflammables.
	Pompes pour mélanges gaz/liquide	Conçues pour manipuler des mélanges multiphasiques dans l'industrie chimique et pharmaceutique.

3 Défaillances courantes des pompes centrifuges

Selon la norme NE-13306, une défaillance se définit comme la perte de capacité d'un bien à remplir sa fonction requise. Elle entraîne une panne, qu'elle soit totale ou partielle [4].

Comme tout équipement mécanique, les pompes centrifuges peuvent subir des défaillances dues à divers facteurs, notamment des conditions de fonctionnement inadaptées, une mauvaise maintenance ou encore des défauts de conception. Il est donc essentiel de comprendre les principales causes de dysfonctionnement afin de mieux les prévenir et les corriger.

3.1 Cavitation

La cavitation est un phénomène destructeur qui se produit dans les pompes centrifuges lorsque la pression du liquide chute en dessous de sa pression de vapeur saturante, entraînant la formation de bulles de vapeur [3]. Ces bulles implosent violemment lorsqu'elles atteignent des zones de haute pression, causant des dommages mécaniques : une érosion des aubes de l'impulseur et des fissures dans le carter (dégâts matériels) ; des vibrations anormales accompagnées d'un bruit caractéristique de "cailloux" ; et une baisse significative des performances se traduisant par la réduction du débit, de la pression et du rendement énergétique de la pompe [5].

La cavitation peut être à bulles, avec des implosions destructrices, ou à poches, formant des zones de vapeur stables qui réduisent l'efficacité. Elle peut aussi apparaître sous forme de tourbillons marginaux, liés à la portance des aubes, ou de tourbillons d'ogive/coque, augmentant les risques vibratoires [6].

La cavitation résulte principalement de :

- **Baisse de pression à l'aspiration** : Due à une hauteur d'aspiration excessive, une restriction dans la conduite, ou une vitesse de rotation trop élevée.
- **Température élevée du liquide** : Réduit la pression de vapeur saturante, favorisant la cavitation.
- **Débit excessif** : Un débit supérieur à la conception de la pompe peut créer des zones de basse pression.

La détection de cavitation repose sur deux approches complémentaires : les méthodes traditionnelles et les méthodes innovantes. Les premières incluent la surveillance du NPSH pour prévenir la cavitation (lorsque le NPSH disponible est inférieur au NPSH requis) ainsi que l'analyse des vibrations via des accéléromètres et l'étude des signatures acoustiques. Les secondes, plus avancées, font appel à des algorithmes d'intelligence artificielle, tels que les réseaux de neurones, capables d'analyser en temps réel des paramètres comme la pression, la vitesse et les vibrations.

3.2 Usure des roulements

Les dégradations des roulements se manifestent sous plusieurs formes, telles que l'usure généralisée, la détérioration des cages, la corrosion de contact, l'écaillage, les fissures, et les grippages. Ces défauts peuvent être causés par des particules abrasives, des charges excessives, ou une mauvaise lubrification.

L'écaillage, en particulier, est souvent un signe de fissuration sur les surfaces de contact, générant des vibrations et des signatures de défauts caractéristiques dans les spectres de fréquence [7].

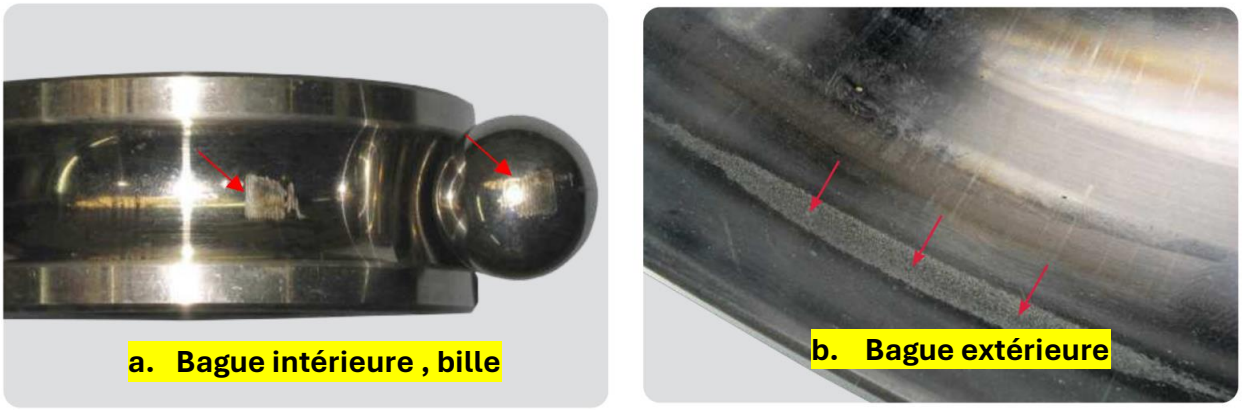


Figure I-3 : Exemple d'usure des différents composants d'un roulement

3.3 Usure et endommagement de l'impulseur

L'usure ou les dommages de l'impulseur sont des causes majeures de défaillance des pompes centrifuges. Étant l'élément rotatif qui génère la force centrifuge, l'impulseur subit des phénomènes comme la cavitation, la corrosion chimique et l'érosion due aux particules abrasives. Ces phénomènes affectent directement le rendement de l'impulseur et, par conséquent, la performance globale de la pompe.



Figure I-4 : Endommagement d'un impulseur causé par la cavitation

3.4 Désalignement

Le désalignement est une défaillance mécanique courante qui se produit lorsque l'axe de l'arbre de la pompe et celui du moteur d'entraînement présentent un défaut d'alignement. Cette

condition génère des contraintes supplémentaires sur les composants de la pompe, ce qui compromet sa durée de vie et augmente la probabilité de défaillance.

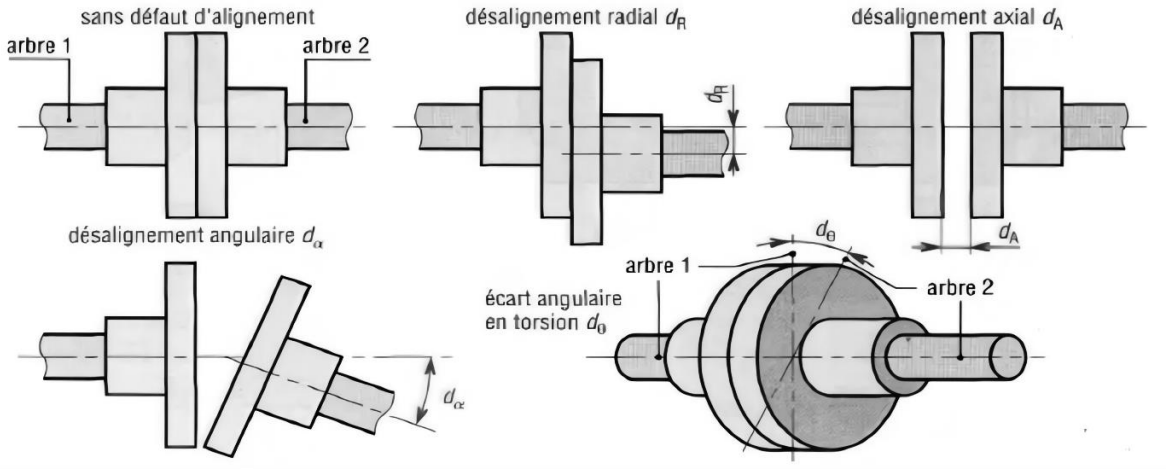


Figure I-5 : Principaux défauts d'alignement

3.5 Défaut de balourd

Le déséquilibre, ou balourd, est une défaillance fréquente des pompes centrifuges, susceptible de provoquer une détérioration prématurée de leurs composants. Il résulte d'un écart entre le centre de gravité du rotor et son axe de rotation à cause d'une répartition irrégulière de la masse des pièces mécaniques, générant une force centrifuge proportionnelle à la masse déséquilibrée et au carré de la vitesse de rotation [7].

3.6 Autres défauts

En plus des défaillances déjà mentionnées, les pompes centrifuges peuvent également présenter d'autres défauts affectant leur performance :

- **Colmatage et fuites** : L'accumulation de débris peut obstruer les conduits, tandis que des fuites entraînent des pertes de fluide et des défaillances mécaniques.
- **Défaillance de la garniture mécanique** : Une usure ou un défaut d'étanchéité peut provoquer des fuites internes et altérer le fonctionnement de la pompe.
- **Problèmes mécaniques divers** : Comme une mauvaise fixation, un arbre voilé et un défaut d'accouplement.
- **Problèmes électriques** : Des anomalies telles que surtensions ou déséquilibres de phase peuvent affecter le moteur et causer des arrêts imprévus.

4 Politiques de maintenance

Selon la norme AFNOR NF EN 13306 [4], la maintenance regroupe l'ensemble des activités techniques, administratives et de management visant à préserver ou restaurer la fonctionnalité d'un équipement tout au long de sa vie utile. Dans le cas des pompes centrifuges, dont les défaillances peuvent engendrer des arrêts coûteux et des perturbations de production, le choix d'une stratégie de maintenance adaptée est crucial.

La norme AFNOR NF EN 17485 [8], publiée en septembre 2021, définit plusieurs politiques de maintenance. Ces stratégies globales encadrent l'organisation et la gestion des activités de maintenance. Les principales approches sont les suivantes :

4.1 Maintenance corrective

La maintenance corrective vise à réparer un équipement après une défaillance et se décline en deux types : corrective non planifiée (intervention d'urgence suite à une panne) et corrective différée (réparation planifiée après détection du problème). Bien que son coût initial soit faible, cette approche présente l'inconvénient majeur d'exposer à un risque élevé d'arrêts imprévus de production.

4.2 Maintenance préventive systématique

La maintenance préventive systématique consiste à intervenir de manière planifiée (selon un calendrier ou un seuil d'usage) avant la survenue de pannes. Elle inclut des actions comme le remplacement périodique de pièces d'usure (courroies, filtres) ou la lubrification programmée. Bien qu'elle réduise efficacement les défaillances aléatoires, cette approche peut conduire à des sur-maintenances, avec des interventions parfois réalisées prématurément.

4.3 Maintenance préventive conditionnelle

La maintenance préventive conditionnelle déclenche les interventions basées sur l'état réel des équipements, surveillés via des techniques comme les analyses vibratoires, thermographiques ou l'analyse d'huile, ainsi que par des capteurs connectés. Cette approche optimise la gestion des maintenances en évitant les interventions non nécessaires, mais implique des coûts initiaux élevés en équipements de surveillance et en expertise pour l'interprétation des données. Son déploiement nécessite donc une analyse coût-bénéfice préalable.

4.4 Maintenance prédictive

La maintenance prédictive représente une approche évoluée de gestion des actifs industriels, s'appuyant sur l'analyse avancée de données et des algorithmes d'intelligence artificielle pour anticiper les défaillances potentielles. Contrairement à la maintenance conditionnelle qui repose sur des mesures instantanées, cette méthode utilise des modèles prédictifs sophistiqués capables d'identifier des schémas d'usure et de dégradation complexes.

Cette approche permet une planification optimisée des interventions, réduisant ainsi les arrêts non planifiés tout en minimisant les coûts de maintenance.

L'efficacité de cette méthode dépend fondamentalement de la qualité et de la quantité des données historiques disponibles, ainsi que de la pertinence des modèles d'intelligence artificielle développés.

4.5 Maintenance améliorative

La maintenance améliorative vise à modifier les équipements (conception, pièces) pour diminuer les besoins futurs de maintenance, en s'appuyant sur des améliorations techniques et le retour d'expérience.

5 Surveillance et diagnostic par analyse des vibrations

Les vibrations mécaniques, générées par les éléments mobiles d'une machine, constituent un indicateur clé de son état de santé. Un équipement neuf présente des niveaux vibratoires faibles, tandis que leur augmentation signale typiquement une dégradation progressive. La variation des vibrations d'une machine est souvent le premier signe physique d'une anomalie [6].

L'analyse vibratoire consiste à mesurer, interpréter et exploiter ces vibrations afin de détecter, identifier et surveiller l'évolution de défauts ou de défaillances au sein des machines tournantes.

Intégrée dans une démarche de maintenance prédictive, l'analyse de ces signatures vibratoires permet un diagnostic précoce des anomalies et une anticipation des défaillances critiques.

5.1 Définition d'une vibration

Un système mécanique est considéré en vibration lorsqu'il effectue un mouvement oscillatoire rapide autour d'une position centrale, appelée position d'équilibre [6] [9].

Les vibrations se transmettent par air, fluide ou matériau solide. Lorsqu'il se transmet par l'air ou un fluide, on parle de sons (ou ultrasons au-delà de 20 000 Hz). Les vibrations "solidiennes", transmises par les composants métalliques des machines, sont privilégiées pour la surveillance car elles sont plus directement liées aux anomalies et moins affectées par l'environnement, contrairement aux sons ou ultrasons [9].

Les vibrations mécaniques sont caractérisées par trois paramètres fondamentaux : la fréquence, l'amplitude et leur nature [6] [9].

5.1.1 Fréquence

La fréquence représente le nombre de cycles par seconde, exprimée en hertz (Hz), et est inversement proportionnelle à la période du signal vibratoire qui représente le temps nécessaire

pour effectuer une oscillation complète. La fréquence peut également être exprimée en CPM (cycles par minute) ou RPM (rotations par minute), particulièrement utile pour les systèmes rotatifs.

5.1.2 Amplitude

L'amplitude d'une vibration correspond à l'écart maximal du signal par rapport à sa position d'équilibre. Elle peut être exprimée sous différentes formes (figure I-6) :

- Amplitude crête (Ac) : Valeur maximale atteinte.
- Amplitude crête à crête (Acc) : Différence entre les valeurs maximale et minimale.
- Amplitude efficace (Aeff ou RMS) : Mesure liée à l'énergie vibratoire, utile pour évaluer le potentiel de détérioration.

L'amplitude peut être exprimée en : déplacement (mm, µm), vitesse (mm/s, m/s) ou accélération (mm/s², m/s², g).

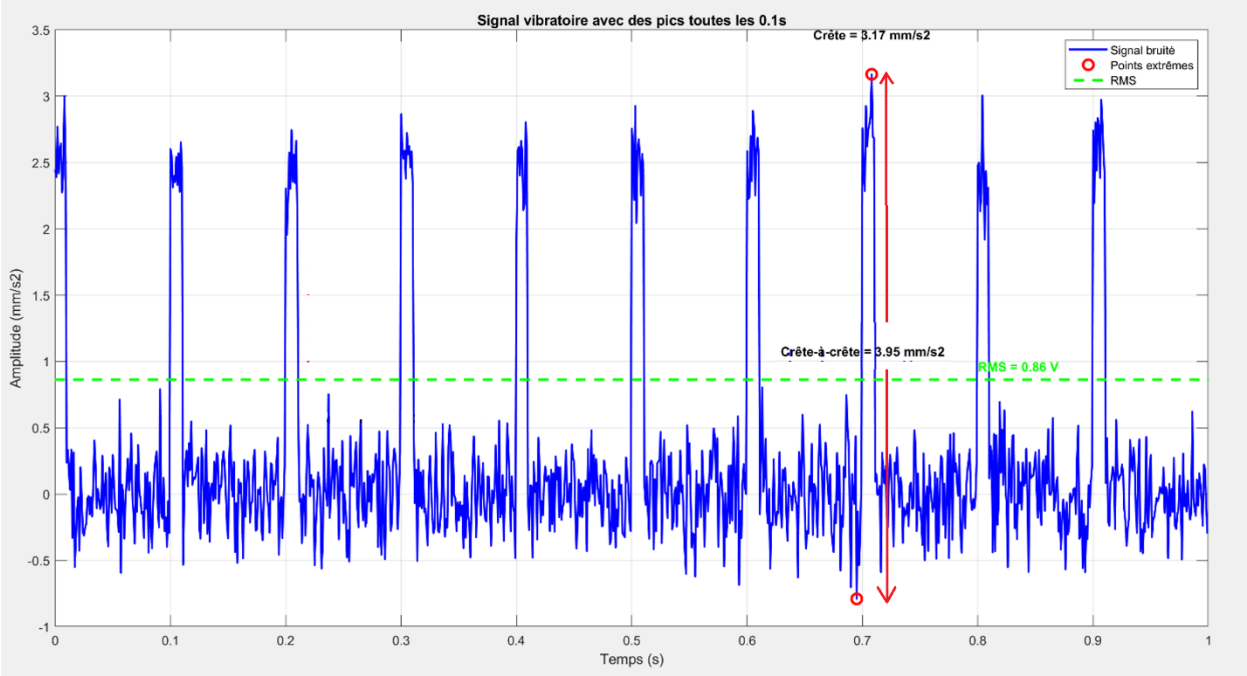


Figure I-6 : Amplitudes d'un signal vibratoire

5.1.3 Nature des vibrations

Les vibrations générées par les machines en fonctionnement peuvent être classées en trois types [9]:

- Vibrations périodiques : Sinusoïdales simples (Figure I-7.a) ou complexes (Figure I-7.b), associées aux mouvements rotatifs et anomalies mécaniques (déséquilibre, désalignement).

- Vibrations impulsionnelles (Figure I-7.c): Courtes et répétitives, résultant de chocs mécaniques normaux ou d'anomalies (écaillage de roulements, engrenages défectueux).
- Vibrations aléatoires (Figure I-7.d): Résultant de phénomènes irréguliers comme un défaut de lubrification ou la cavitation d'une pompe.

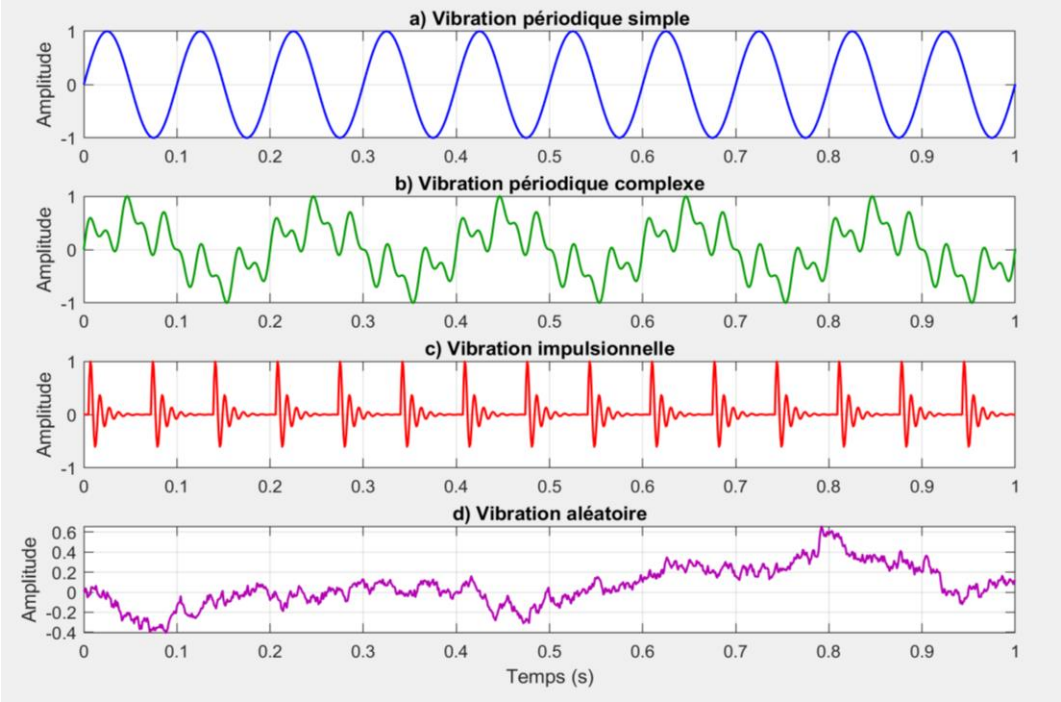


Figure I-7 : Nature d'une vibration

5.2 Capteurs de vibration

La première phase dans la mesure des vibrations consiste à convertir les mouvements mécaniques d'une machine en un signal électrique équivalent. Cette opération repose sur l'utilisation de capteurs de vibrations. Parmi les dispositifs les plus répandus, on trouve le capteur de déplacement (ou proximètre), qui détecte les variations de position ; le capteur de vitesse (ou vélocimètre), qui mesure la vitesse vibratoire ; et l'accéléromètre, qui quantifie l'accélération des vibrations.

Selon [6], plusieurs caractéristiques fondamentales permettent de décrire les performances d'un capteur de vibrations :

- **Bande passante** : Il s'agit de l'intervalle de fréquences pour lequel le capteur assure une mesure fiable, c'est-à-dire avec une erreur limitée, généralement spécifiée par le fabricant (par exemple, ±3 % ou ±3 dB dans une plage allant de 3 Hz à 8000 Hz).
- **Gamme dynamique** : Ce paramètre désigne l'écart entre l'amplitude minimale et l'amplitude maximale que le capteur peut enregistrer sans distorsion ni saturation, garantissant ainsi une mesure fidèle.

- **Sensibilité** : Elle exprime la relation entre la grandeur mécanique détectée et le signal électrique produit en sortie. Cette sensibilité est souvent donnée en millivolts par unité de déplacement (par exemple, 8 mV/µm). Le constructeur fournit généralement une courbe d'étalonnage illustrant cette relation, laquelle doit être vérifiée régulièrement afin de maintenir la précision des mesures.
- **Tenue en température** : Chaque capteur a une plage de température de fonctionnement au-delà de laquelle ses performances peuvent se dégrader. En particulier, pour les capteurs piézoélectriques, une température excessive peut modifier leur sensibilité, voire les endommager de manière irréversible.
- **Grandeurs d'influence** :Autres phénomènes pouvant affecter la mesure (température, humidité, champs électromagnétiques...). Elles peuvent fausser la précision si non maîtrisés.
- **Masse et dimensions :** peuvent influencer la mesure, surtout sur des structures légères ou fines, en modifiant leur comportement vibratoire ou en rendant l'installation difficile. Un capteur trop lourd peut modifier le comportement vibratoire de la structure.

5.2.1 Les proximètres

Les capteurs de déplacement, également appelés proximètres ou capteurs de proximité, sont conçus pour mesurer la distance entre une surface en mouvement (typiquement celle d'un arbre rotatif) et l'élément sensible du capteur, appelé sonde. Ces dispositifs sont qualifiés de capteurs relatifs, car ils détectent un déplacement par rapport à un point fixe, à la différence des capteurs de vitesse ou d'accélération, qui mesurent des grandeurs absolues [6].

Un capteur de déplacement fonctionnant sur le principe des courants de Foucault permet de mesurer le déplacement relatif de l'arbre par rapport à la structure sur laquelle le capteur est monté, généralement le bâti ou le corps du palier. En revanche, les capteurs de type vélocimètre ou accéléromètre enregistrent directement les vibrations du support, c'est-à-dire les mouvements induits par le rotor en vibration [6].



Figure I-8 : Exemples de proximètres

5.2.2 Les vélocimètres

Les vélocimètres, ou capteurs de vitesse, sont des capteurs sismiques mesurant le mouvement absolu du point d'ancrage, généralement un palier. Leur fonctionnement repose sur une masse suspendue par un ressort, solidaire d'une bobine se déplaçant dans un champ magnétique permanent. Lorsqu'une vibration se produit, le mouvement de la bobine dans ce champ génère une tension proportionnelle à la vitesse de déplacement [6].

Ces capteurs ont l'avantage de fonctionner sans alimentation externe ni pré-amplification. Leur fréquence de résonance se situe typiquement entre 8 et 15 Hz, avec une bande de mesure efficace s'étendant généralement de 10–20 Hz jusqu'à environ 2000 Hz. Grâce à l'ajout d'un circuit de linéarisation, il est possible de réduire la fréquence de coupure inférieure jusqu'à 1 Hz [6].

Historiquement très utilisés en maintenance industrielle jusqu'aux années 1990, les vélocimètres sont aujourd'hui progressivement remplacés par les accéléromètres piézoélectriques, qui offrent une meilleure compacité, une fiabilité accrue et des performances supérieures en termes de bande passante et de gamme dynamique [6].

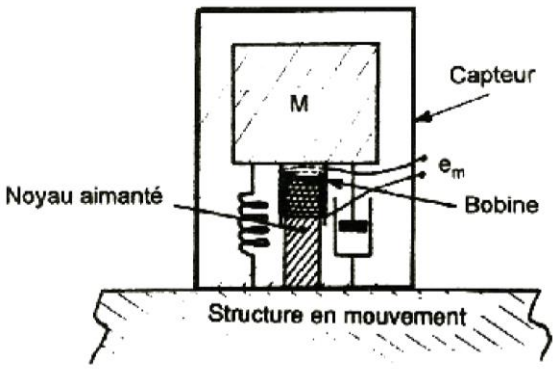


Figure I-9 : Schéma de principe d'un vélocimètre [6]

5.2.3 Les accéléromètres

La sensation d'accélération correspond à ce que l'on perçoit lorsque la vitesse à laquelle on se déplace augmente. L'accélération désigne ainsi la variation de vitesse au cours d'un certain intervalle de temps [10].

Un accéléromètre est un dispositif qui mesure l'accélération d'un objet, exprimée en mètres par seconde carrée (m/s^2) ou en multiples de 'g', où 1g représente l'accélération gravitationnelle terrestre standard (9,8 m/s^2) [10].

Quatre technologies dominent le marché des accéléromètres : piézoélectrique, piézorésistive, capacitive et asservie [10]. Les accéléromètres piézoélectriques s'imposent

progressivement comme les capteurs de vibrations absolues les plus couramment utilisés pour la surveillance des machines en rotation [6].



Figure I-10 : Exemples d'accéléromètres

Le fonctionnement des accéléromètres repose sur la capacité des matériaux piézoélectriques à produire une charge électrique proportionnelle aux contraintes de compression ou de cisaillement qu'ils subissent. Schématiquement (figure I-11), un accéléromètre se compose d'un disque en matériau piézoélectrique, agissant comme un ressort, sur lequel est appliquée une masse sismique précontrainte. Lorsqu'une accélération provoque un déplacement de cette masse, celle-ci exerce des contraintes sur le disque piézoélectrique, générant ainsi une charge électrique proportionnelle à l'accélération [6].

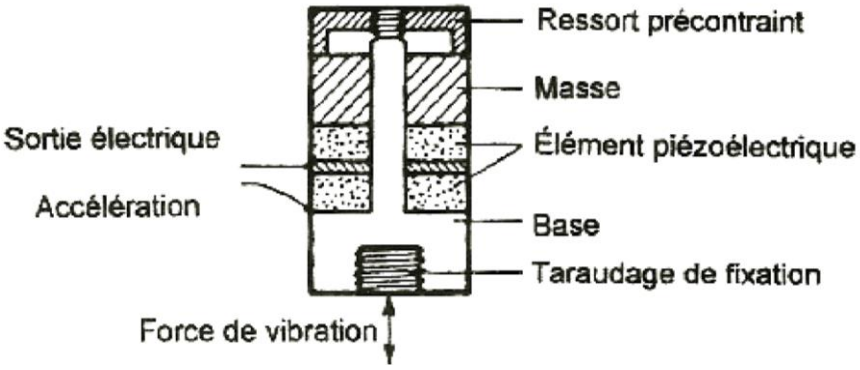


Figure I-11 : Principe de fonctionnement d'un accéléromètre piézoélectrique [6]

Sur le plan électrique (figure I-12), l'élément sensible (le matériau piézoélectrique) se comporte comme un condensateur de capacité C_a, monté en parallèle avec une résistance de fuite interne R_a de très grande valeur.

L'accéléromètre peut ainsi être modélisé de deux manières :

- Comme un générateur de charge Q_a en parallèle avec le condensateur C_a et la capacité C_c du câble de liaison.
- Ou comme un générateur de tension V_a en série avec le condensateur C_a, l'ensemble étant chargé par la capacité C_c du câble.

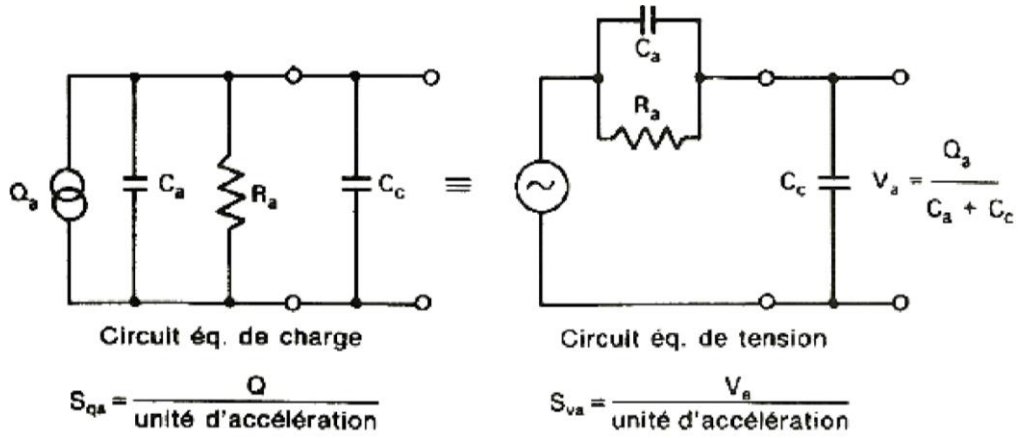


Figure I-12 : Equivalences électriques d'un accéléromètre [6]

5.3 Techniques de surveillance

La surveillance des machines tournantes repose sur l'observation continue ou périodique de certains indicateurs caractéristiques de l'état de fonctionnement de la machine. Ces indicateurs sont choisis pour leur sensibilité aux défauts potentiels affectant les organes mécaniques. Chaque indicateur est associé à un seuil d'alarme. Le dépassement de ce seuil déclenche une procédure de diagnostic pour la confirmation de l'alarme et la mise en œuvre d'une action corrective.

Dans ce cadre, plusieurs types d'indicateurs peuvent être utilisés pour assurer une surveillance efficace [6] , parmi lesquels :

5.3.1 Indicateurs scalaires en bande large (niveau global)

Le comportement vibratoire global d'une machine, qu'il soit lié à un fonctionnement normal ou à l'apparition d'un défaut, peut être suivi à l'aide d'un ou plusieurs indicateurs. Ce type de surveillance permet d'évaluer l'état vibratoire général de l'équipement et d'en suivre les variations au fil du temps. Cependant, il ne permet généralement pas d'identifier précisément la nature du défaut en cause. Les indicateurs le plus souvent utilisés sont l'énergie, l'amplitude efficace (RMS), parfois crête (V_c), du signal vibratoire (accélération, vitesse ou déplacement), avec une bande de fréquences couvrant toute la plage de sensibilité de l'instrument de mesure ou une bande normalisée. La fiabilité de cette méthode peut être réduite par l'effet de masque, où des défauts spécifiques passent inaperçus car leur signature vibratoire est noyée dans des signaux plus

dominants. Ce mode de suivi constitue donc une alerte générale, incitant à approfondir l'analyse en cas d'élévation anormale de l'indicateur.

$$V_{eff} = \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2} \qquad Éq\ 1$$

$$V_{max} = max(|x(t)|) \qquad Éq\ 2$$

$$E = \sum_{i=1}^{N} x[n]^2 \qquad Éq\ 3$$

5.3.2 Indicateurs scalaires en bande étroite

Pour atténuer les effets de masque associés à la surveillance par indicateurs scalaires larges bandes, le spectre vibratoire est divisé en différentes bandes de fréquences définies par l'utilisateur. Cette approche permet de mesurer et suivre l'évolution des indicateurs dans des bandes spécifiques, plutôt que d'analyser le signal global.

Cette méthode offre une surveillance plus ciblée, car elle permet de définir des indicateurs et des seuils mieux adaptés à la nature des défauts à surveiller, ce qui rend le diagnostic plus précis et fiable.

5.3.3 Analyse spectrale par comparaison à un gabarit

Dans cette méthode, la détection d'anomalies repose sur la comparaison entre le spectre vibratoire actuel de la machine et un spectre de référence, acquis lors d'un fonctionnement jugé normal. Toute divergence notable entre les deux, dépassant les limites fixées par un gabarit prédéfini, est interprétée comme une indication d'un comportement anormal de la machine.

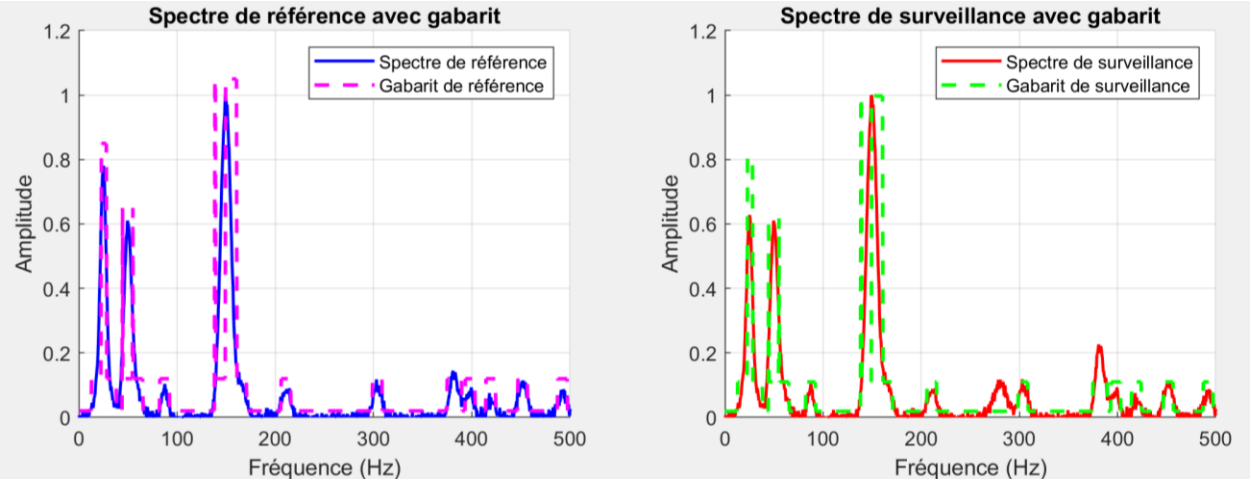


Figure I-13 : Surveillance spectrale avec alarme sur dépassement de gabarit

5.3.4 Indicateurs de défauts impulsionnels (roulements)

Certains défauts mécaniques, en particulier ceux affectant les roulements, génèrent des forces impulsionnelles se traduisant par des vibrations de très courte durée et à haute fréquence. Pour détecter ces phénomènes spécifiques, on recourt à des indicateurs plus sensibles à la forme du signal qu'à son énergie globale. Parmi les plus utilisés, on retrouve :

- **Le facteur de crête (Crest Factor)** : Cet indicateur met en évidence la présence de chocs ponctuels dans un signal. Il est défini comme le rapport entre la valeur maximale (amplitude crête) et la valeur efficace (RMS) du signal :

$$F_c = \frac{V_c}{V_{eff}} \qquad Éq\ 4$$

Une valeur élevée du facteur de crête peut indiquer la présence de défauts impulsionnels localisés dans le système.

- **Le kurtosis (ou coefficient d'aplatissement)** : Le kurtosis est un indicateur statistique qui : permet de quantifier la "pointe" d'une distribution. Dans un contexte vibratoire, une valeur de kurtosis significativement supérieure à 3 (valeur pour un signal gaussien) indique un signal comportant des pics impulsionnels :

$$K_u = \frac{1}{N}\sum_{1}^{N}\frac{(x_i - \bar{x})^4}{\sigma_x^4} = \frac{M_4}{M_2^2} \qquad Éq\ 5$$

x_i : signal mesuré temporel.

N : Nombre d'échantillant dans le signal.

σ_x : l'écart type.

M_4 : le moment statistique d'ordre 4.

M_2 : le moment statistique d'ordre 2.

5.4 Signatures vibratoires des différentes défaillances

Chaque composant mécanique génère une réponse vibratoire spécifique en fonctionnement normal. Lorsqu'un défaut survient, cette réponse se modifie, créant ce que l'on appelle une signature vibratoire caractéristique. Dans cette section, nous présentons les signatures vibratoires typiques associées aux principales défaillances rencontrées dans les pompes centrifuges.

5.4.1 Signature vibratoire liée à la cavitation

La cavitation génère un spectre de bruit couvrant une large gamme de fréquences, liées à différents mécanismes physiques. Le tableau suivant résume ces sources et les plages de fréquences associées, d'après [1].

Tableau I-2 : Plages de fréquences générées par la cavitation et leurs sources physiques

Plage de fréquence	Source physique	Description
< 10hz	Recirculation à faible NPSHA	Implosions cycliques de noyaux de vapeur dans la conduite d'aspiration
100 - 2000 hz	Fluctuations de cavités allongées	Oscillations liées à des écoulements instables (vitesse non uniforme, turbulence, vortex)
200 -1000 hz	Bruit aéroacoustique audible	Généré par de grandes nuées de bulles ou cavités de la taille du pas des pales ; perçu comme grondement
10 khz – 1 Mhz	Implosions de bulles individuelles	Bruit large bande, aléatoire ; pic d'énergie entre 20 et 400 kHz ; utilisé pour le diagnostic précoce
Fréquences super-synchrones	Cavitation tournante	Zones de cavitation tournant autour de la roue (observées dans certains types d'impulseurs)

5.4.2 Signatures vibratoires des défauts de roulements

Les défauts de roulements peuvent être identifiés par analyse vibratoire, où l'on observe des pics harmoniques à des fréquences caractéristiques, telles que la fréquence de passage des billes (BSF), la fréquence de défaillance de la bague externe (BPFO), ou celle de la bague interne (BPFI) [7] [11]. Chaque type de défaut présente une signature spécifique dans le spectre de fréquence.

Un défaut sur la bague interne se manifeste généralement par la présence de plusieurs harmoniques (entre 8 et 10) de la fréquence BPFI, souvent modulées par des bandes latérales à 1x la fréquence de rotation (RPM). Les défauts de la bague externe, quant à eux, sont caractérisés par des pics multiples entre 8 et 10 harmoniques de la fréquence BPFO, mais sans bandes latérales significatives, car la bague externe est généralement fixe.

En ce qui concerne les éléments roulants, des défauts sur les billes ou les rouleaux génèrent des pics aux harmoniques de la BSF, et l'harmonique de plus forte amplitude peut souvent indiquer le nombre d'éléments détériorés. Ces défauts s'accompagnent fréquemment de détériorations sur les chemins de roulement.

Les défauts de cage, bien que plus rares, apparaissent dans le spectre par la fréquence de défaut de cage (FTF) et ses harmoniques. Ils sont généralement accompagnés de défauts

secondaires sur les bagues, et la fréquence FTF module alors les fréquences de défaut des races, produisant des combinaisons de fréquences (sommes et différences). Par ailleurs, les défauts d'écaillage ou de fatigue de surface se traduisent typiquement par une augmentation de l'énergie dans les hautes fréquences (souvent >1000 Hz), couplée à des modulations liées à la vitesse de rotation, ce qui permet une détection précoce [11].

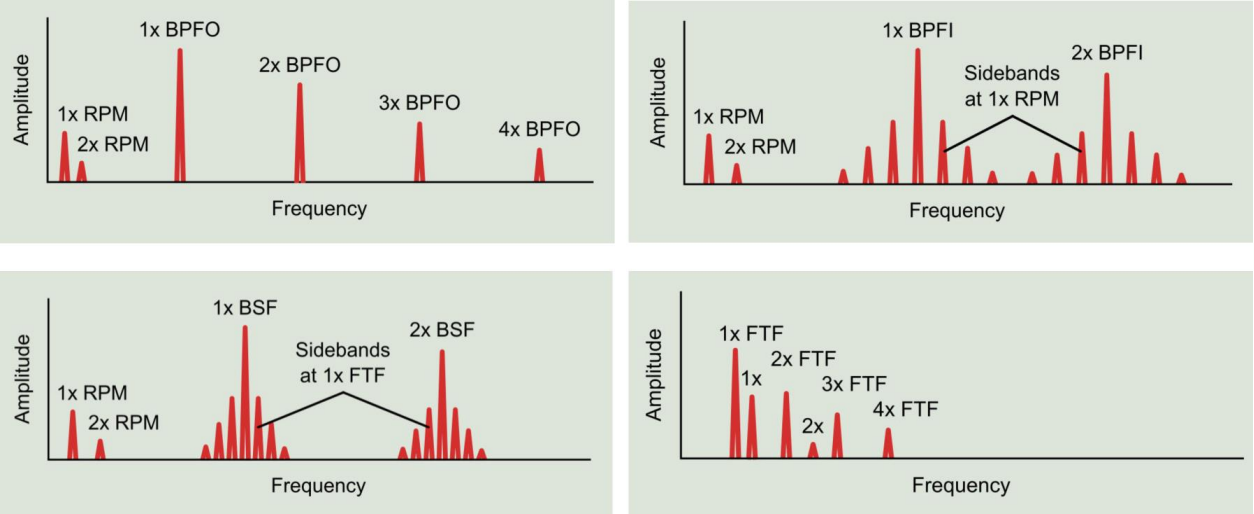


Figure I-14 : Spectre des différents défauts de roulements

$$BPFO\ (Hz) = \frac{n}{2} f_r (1 - \frac{D_b}{D_m} \cos \beta) \qquad \text{Éq 6}$$

$$BPFI\ (Hz) = \frac{n}{2} f_r (1 + \frac{D_b}{D_m} \cos \beta) \qquad \text{Éq 7}$$

$$FTF\ (Hz) = \frac{1}{2} f_r (1 - \frac{D_b}{D_m} \cos \beta) \qquad \text{Éq 8}$$

$$BSF\ (Hz) = \frac{D_m}{2D_b} f_r (1 - (\frac{D_b}{D_m} \cos \beta)^2) \qquad \text{Éq 9}$$

Avec : **Dm** : Diamètre moyen (primitif). **Db** : Diamètre de bille. **n** : Nombre de billes ou de rouleaux. **fr** : Fréquence de rotation. **β** : Angle de contact

La figure I-15 représente un exemple d'un spectre fréquentiel d'un signal vibratoire d'une pompe centrifuge avec un défaut dans la bague interne du roulement du moteur. Afin de comparer les calculs théoriques et les valeurs réel, les fréquences caractéristiques ont été calculées à partir

des paramètres géométriques du roulement : nombre de billes = 8, diamètre de bille ≈ 11.112 mm, diamètre moyen ≈ 47 mm, et un angle de contact de 0°.

En appliquant les formules classiques, la fréquence BPFI (Ball Pass Frequency Inner race), correspondant à un défaut sur la piste intérieure, est déterminée comme suit :

$$BPFI = \frac{n}{2} f_{rot}\left(1 + \frac{d}{D_m}\right) = \frac{8}{2} 24.5\left(1 + \frac{11.112}{47}\right) = 121.2\ Hz$$

Lors de l'analyse du spectre du signal vibratoire, une fréquence dominante a été observée à 1086.5 Hz. Cette fréquence correspond très précisément à environ 9 fois la BPFI, soit :

$$9 \times 121.2 = 1090.8\ Hz \approx 1086.5\ Hz$$

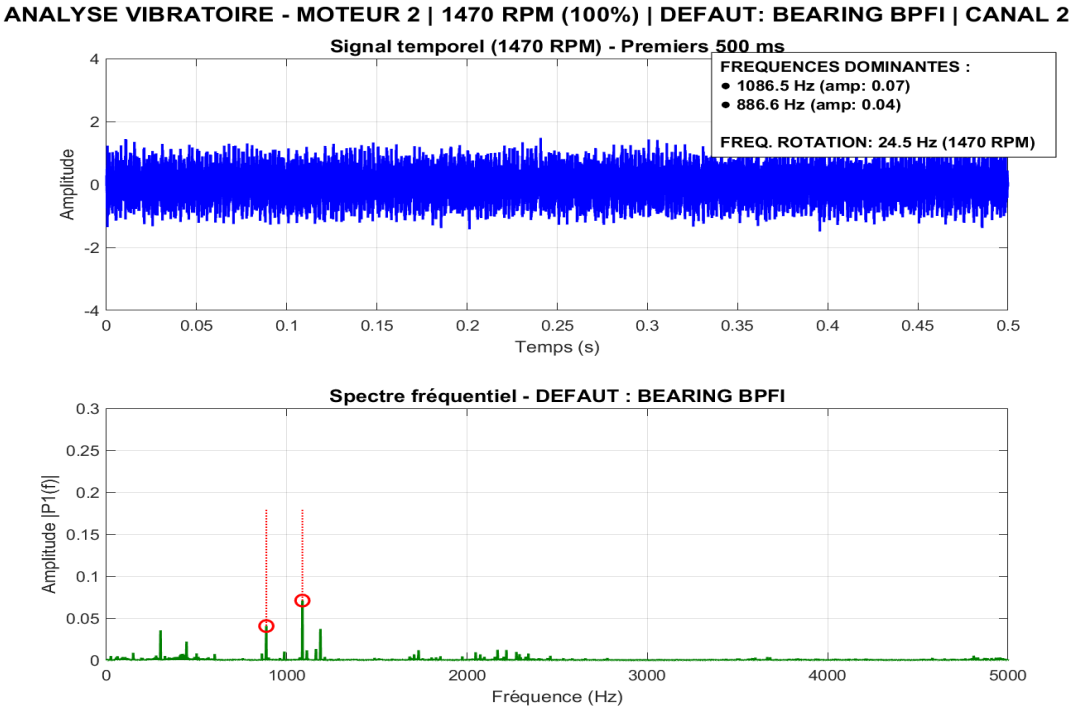


Figure I-15 : Spectre d'un signal vibratoire avec un défaut BPFI

5.4.3 Signature vibratoire d'un impulseur endommagé

Un impulseur endommagé dans une pompe centrifuge génère des signatures vibratoires caractéristiques, détectables par analyse spectrale. Ces signatures varient selon le type et la gravité du défaut, mais certaines fréquences clés sont généralement observées.

- **Fréquence de passage des pales (BPF – Blade Pass Frequency)** : Cette fréquence correspond au produit du nombre de pales de l'impulseur par la vitesse de rotation de la pompe. En cas de défauts tels que des fissures ou des érosions sur les pales, une augmentation notable de l'amplitude à cette fréquence est souvent observée. Des

harmoniques de cette fréquence (2× BPF, 3× BPF, etc.) peuvent également apparaître, indiquant une dégradation plus avancée [12].

- **Fréquence de rotation (1× RPM)** : Un déséquilibre de l'impulseur, dû par exemple à une usure inégale, se manifeste par une augmentation de l'amplitude à la fréquence de rotation de la pompe. Des harmoniques (2× RPM, 3× RPM, etc.) peuvent également être présentes en cas de désalignement ou de jeu mécanique.

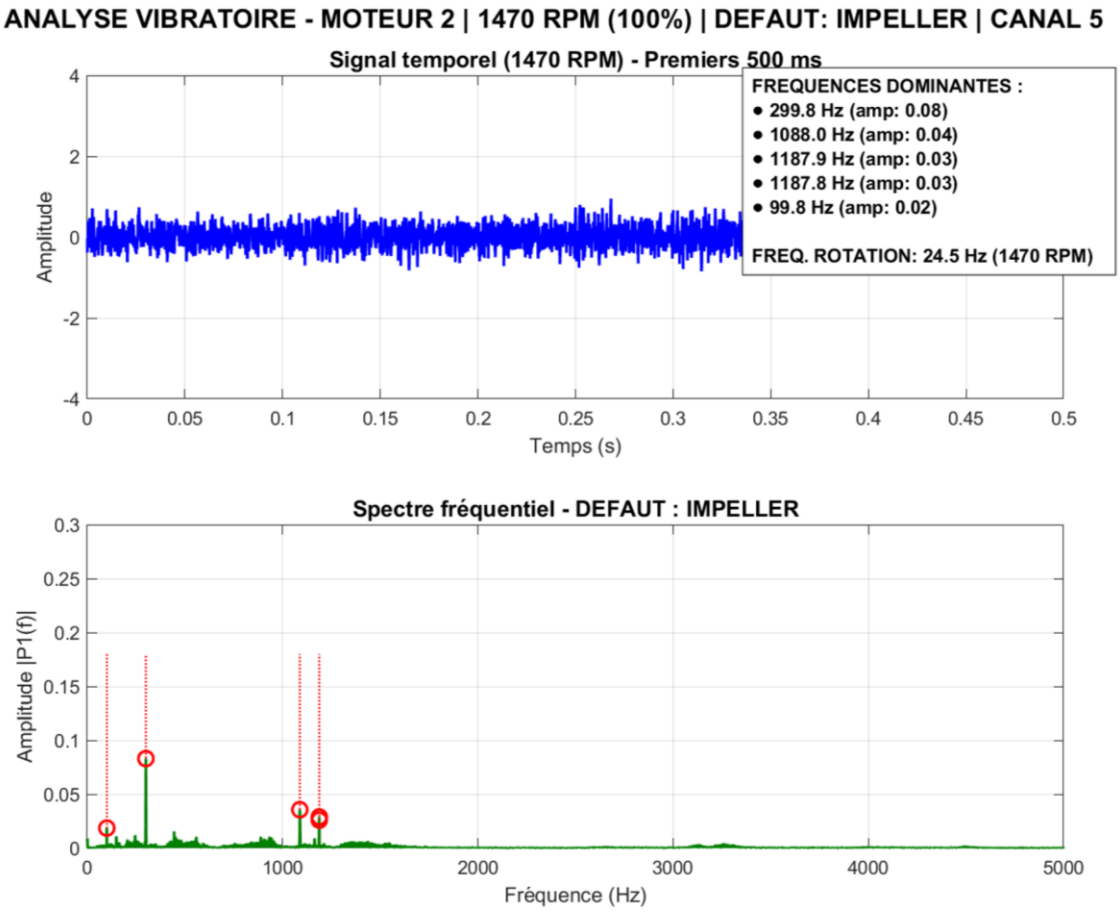


Figure I-16 : Spectre vibratoire d'un impulseur endommagé

La figure I-16 représente un spectre vibratoire d'une pompe avec un impulseur endommagé à 6 pales. La fréquence BPF théorique est égale à 24.5 x 6 = 147 Hz, on peut observer un pic avec une fréquence égale à environ 2 x BPF (299.8 Hz), et un autre pic égale à 4 x F_{rot} (99 Hz).

- **Fréquences élevées (4,5 kHz à 6 kHz)** : Des pics d'amplitude dans cette plage peuvent indiquer des phénomènes de cavitation ou des résonances structurelles, souvent exacerbés par des défauts de l'impulseur. La cavitation, en particulier, génère des vibrations à haute fréquence dues à l'implosion des bulles de vapeur [13].

- **Composantes aléatoires à large bande** : Outre les pics à des fréquences spécifiques, un impulseur endommagé peut induire une augmentation du bruit de fond dans le spectre vibratoire, reflétant des turbulences et des irrégularités de l'écoulement [14].

5.4.4 Signature vibratoire d'un déséquilibre dynamique

- **Composante principale : fréquence de rotation (1× RPM)** : Le déséquilibre dynamique se manifeste principalement par une vibration à la fréquence de rotation de la pompe (1× RPM), souvent avec une amplitude significative dans la direction radiale [15].
- **Harmoniques (2× RPM, 3× RPM, etc.)** : Bien que le déséquilibre pur génère principalement une vibration à 1× RPM, des harmoniques peuvent apparaître en présence de conditions supplémentaires telles que le désalignement ou la flexion de l'arbre [16].

5.4.5 Signatures vibratoires d'autres anomalies

En plus des défaillances mentionnées précédemment, d'autres défaillances des pompes centrifuges sont présentées dans le tableau suivant.

Tableau I-3 : Signatures vibratoire d'autres anomalies

Type d'anomalie	Fréquences	Remarque
Tourbillon d'huile	de 0,45 à 0,49 x f_{rot}	Uniquement dans le cas de paliers hydrodynamiques à grande vitesse
Balourd	1 x f_{rot}	Déphasage voisin de 90˚ entre deux mesures effectuées synchrones sur le même palier selon deux directions radiales orthogonales
Défaut de fixation	1, 2, 3, 4 x f_{rot}	Déphasage quasi nul entre deux mesures ou sur deux mesures effectuées synchrones sur le même palier selon 2 directions radiales orthogonales
Défaut d'alignement	2 x f_{rot}	Vibration axiale en général plus importante si le défaut d'alignement comporte un écart angulaire
Défaut élecromagnétique	1, 2, 3, 4 x 50 Hz	Vibration disparaissant dès la coupure de l'alimentation électrique.
Excitation hydrodynamique	Fréquence de passage des aubes, pales, augets, ailettes…	Présence de bandes latérales de modulation espacées de la fréquence de rotation dans le cas où l'entrefer pales volute n'est pas constant

6 Conclusion

Ce chapitre a mis en évidence le rôle clé des pompes centrifuges dans l'industrie, en présentant leur fonctionnement, leurs composants, et leurs applications. Il a souligné l'importance de détecter précocement les défaillances pour limiter les arrêts coûteux, en passant en revue les principales stratégies de maintenance définies par les normes.

L'analyse vibratoire a ensuite été présentée comme un outil puissant de diagnostic et de surveillance des défaillances des pompes centrifuges, grâce aux proximètres (basses fréquences, installation précise), vélocimètres (fréquences intermédiaires) et accéléromètres (large bande),

L'analyse des signatures vibratoires permet d'identifier précisément des défauts comme le déséquilibre, le désalignement ou l'usure, chaque défaillance produisant un motif distinct facilitant un diagnostic ciblé.

Enfin, ce chapitre a ouvert la voie à l'exploitation des signaux vibratoires comme information pour la détection des anomalies. Le traitement avancé du signal, combiné à l'intelligence artificielle, permet d'automatiser l'analyse, d'identifier des motifs complexes et de renforcer la précision du diagnostic, ouvrant la voie à un système de surveillance prédictif, autonome et capable de recommander des actions correctives en temps réel.

Chapitre II
Méthodes de traitement vibratoire appliquées au diagnostic intelligent

1 Introduction

Ce chapitre traite du traitement des signaux vibratoires et de leur intégration dans un processus de diagnostic intelligent basé sur l'intelligence artificielle. Il présente d'abord la chaîne d'acquisition des signaux, essentielle pour garantir la qualité des données, puis les principales méthodes de traitement permettant d'en extraire les caractéristiques pertinentes.

Dans un second temps, l'accent est mis sur l'apport de l'intelligence artificielle dans l'analyse automatique des défauts. Les principaux modèles d'apprentissage automatique sont abordés, ainsi que les outils permettant d'évaluer leurs performances et leur capacité de généralisation.

2 Acquisition et prétraitement des signaux vibratoires

Avant toute analyse avancée comme la transformée en ondelettes, les signaux bruts doivent subir une série d'opérations de prétraitement. Cette étape vise à améliorer la qualité des données, à réduire les bruits et à préparer le signal pour une analyse fiable et efficace. Toutefois, avant d'aborder les aspects liés à l'analyse des signaux, il est essentiel de comprendre le processus par lequel ces données ont été initialement capturées. Cette section est donc consacrée à la présentation de la chaîne d'acquisition et des étapes de prétraitement appliquées aux signaux vibratoires.

2.1 Chaine d'acquisition

Selon [17] une chaîne d'acquisition a pour rôle de collecter les informations indispensables à la compréhension et au pilotage d'un procédé, et de les restituer sous une forme exploitable pour les traitements ou les analyses ultérieures (figure II-1).

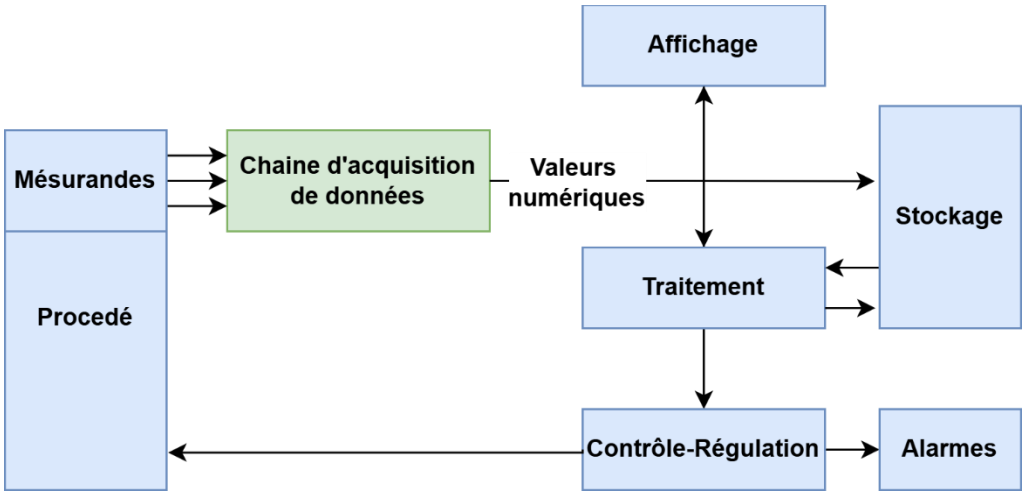


Figure II-1 : Emplacement de la chaîne d'acquisition dans le processus de mesure et de régulation

Une chaine d'acquisition de données est constituée des élément suivants (Figure II-2)

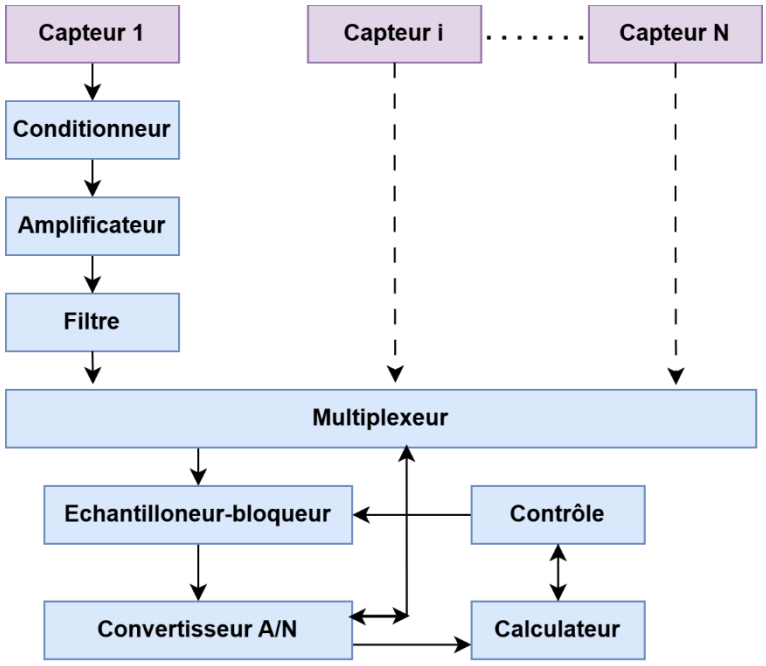


Figure II-2 : Schéma d'une chaîne d'acquisition type

2.1.1 Capteur

La première étape du traitement du signal est l'acquisition des données à partir de capteurs placés sur les équipements surveillés, dans notre cas l'équipement à surveiller est une pompe centrifuge. Selon [17] pour chaque grandeur physique à mesurer (appelée mesurande), un capteur est utilisé afin de la convertir en une grandeur électrique, notée s(m), selon une relation connue. Cette conversion permet d'associer à chaque valeur du mesurande une valeur unique de la grandeur électrique. Ce signal électrique constitue ensuite l'entrée du système d'acquisition chargé de le traiter.

Parmi les différents types de capteurs disponibles, l'accéléromètre est le plus adapté pour la surveillance des machines tournantes. En effet, comme évoqué dans le premier chapitre à propos de l'analyse vibratoire, les signaux émis par ce type de machines couvrent une large bande de fréquences. Contrairement aux proximètres ou aux vélocimètres, qui présentent une bande passante plus limitée, l'accéléromètre permet de capter efficacement ces hautes fréquences, ce qui en fait l'outil privilégié pour une acquisition de données fiable et complète.

2.1.2 Conditionneur de signal

La plupart des dispositifs ne peuvent traiter que des signaux sous forme de tension. Le conditionneur a donc pour rôle de convertir la grandeur électrique issue du capteur, si elle n'est pas déjà une tension, en une tension exploitable. Cette conversion permet de représenter les variations du signal, en amplitude et/ou en fréquence, selon les caractéristiques du capteur.

Certains conditionneurs peuvent également corriger le signal, par exemple en compensant les effets de grandeurs d'influence ou en le linéarisant.

2.1.3 Amplificateur

En général, un amplificateur joue trois rôles essentiels dans une chaîne d'acquisition :

- Il élève le niveau du signal, ce qui permet de le protéger contre les interférences, le bruit de fond et les dérives susceptibles d'affecter les composants en aval.
- Grâce à sa haute impédance d'entrée et à sa faible impédance de sortie, il garantit un transfert efficace du signal entre les différents modules du système.
- Enfin, il adapte l'amplitude du signal pour qu'elle corresponde précisément à l'échelle attendue par le convertisseur analogique-numérique (CAN) afin d'améliorer la précision des mesures.

2.1.4 Filtre

Le signal acquis peut contenir du bruit indésirable (interférences, vibrations parasites, etc.) qui doit être atténué pour ne pas fausser les analyses ultérieures [18]. Le signal analogique est donc appliqué à un filtre passe-bas afin d'éliminer les composantes fréquentielles non souhaitées. Le choix de la fréquence de coupure de ce filtre est crucial : il doit être suffisamment élevé pour conserver toutes les composantes utiles du signal vibratoire, tout en supprimant le bruit haute fréquence. Ce choix est également guidé par le théorème de Shannon-Nyquist, qui stipule que la fréquence d'échantillonnage doit être au moins deux fois supérieure à la fréquence maximale du signal utile. Un exemple de diagramme de Bode d'un filtre passe bas est illustré dans la figure II-3.

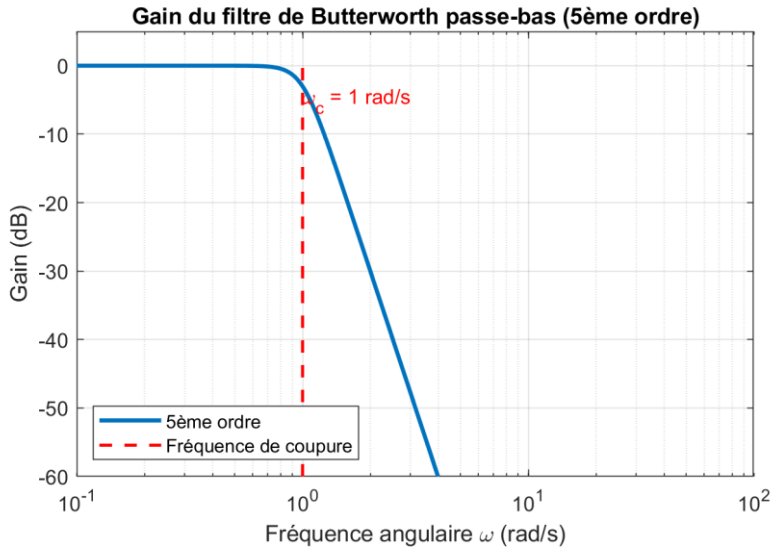


Figure II-3 : Diagramme de Bode d'un filtre butterworth de 5ème ordre

2.1.5 Multiplexeur

Dans le cas où plusieurs grandeurs physiques doivent être mesurées simultanément, chacune disposant de son propre chemin de traitement (capteur, conditionneur, filtre, etc.), un multiplexeur est utilisé pour orienter sélectivement l'un de ces signaux vers les unités de traitement suivantes. La sélection d'un canal s'effectue via une adresse binaire transmise par le contrôleur du système, correspondant au numéro du canal. Cette adresse est décodée afin d'activer les commutateurs qui connectent le canal choisi à la sortie du multiplexeur.

2.1.6 Convertisseur analogique numérique

La conversion analogique-numérique transforme un signal continu en une suite de valeurs numériques à l'aide de trois étapes :

- **Échantillonneur-bloqueur** (figure II-4) : prélève le signal analogique à intervalles réguliers (selon une fréquence d'échantillonnage) et maintient sa valeur constante durant chaque intervalle.
- **Quantification** (figure II-5): arrondit chaque valeur échantillonnée à l'un des niveaux discrets prédéfinis selon la résolution du convertisseur.
- **Codage** : attribue à chaque valeur quantifiée un code binaire, exploitable par les systèmes numériques.

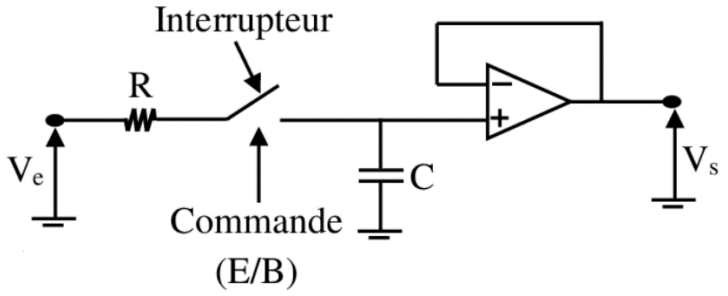


Figure II-4 : Schéma de principe d'un échantillonneur bloqueur

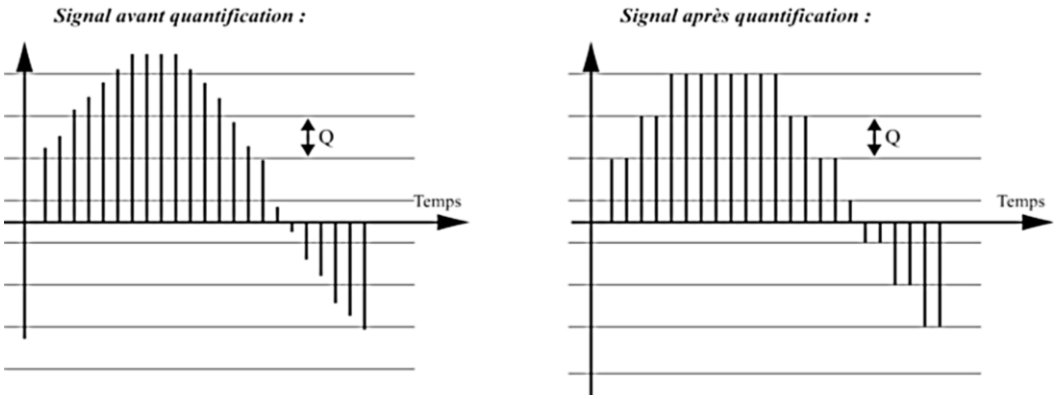


Figure II-5 : Exemple de quantification

2.1.7 Calculateur et control

Pour assurer un fonctionnement cohérent de la chaîne d'acquisition, tous ses composants doivent être synchronisés avec précision. C'est au calculateur que revient la tâche de piloter cette coordination temporelle, en générant les signaux de commande au bon moment. Il gère notamment la sélection des canaux via le multiplexeur, le déclenchement de l'échantillonnage et du blocage, le lancement de la conversion analogique-numérique, ainsi que la lecture du résultat une fois la conversion terminée.

Au-delà de ce rôle central de pilotage, le calculateur peut également assurer diverses fonctions supplémentaires à visée métrologique, destinées à améliorer la qualité ou l'exploitation des mesures, telles que :

- L'ajustement de la fréquence de coupure du filtre antirepliement.
- L'exécution automatique des opérations de mise à zéro et d'étalonnage.
- La correction des non-linéarités.
- La compensation des facteurs d'influence.
- La gestion d'alertes, l'affichage des données, etc.

2.2 Système d'acquisition (DAQ)

Dans le cas d'acquisition des données vibratoires en temps réel (pour un système de surveillance des pompes centrifuges), il est préférable d'utiliser un système d'acquisition multi-voies synchrone pour garantir la précision temporelle des mesures.

La carte USB-4432 de national instruments (figure II-6) est un exemple d'une carte d'acquisition multi-voies conçu pour des applications de mesure de vibrations et de bruit.



Figure II-6: Carte d'acquisition de données multi-voies NI USB-4432

2.3 Ordinateur et logiciel de traitement

Dans une chaîne d'acquisition dédiée à la surveillance vibratoire, l'ordinateur joue un rôle central dans le traitement, l'interprétation et l'archivage des données. Il agit comme une plateforme de calcul permettant d'exécuter l'ensemble des opérations logicielles nécessaires à la détection et à l'identification des défauts.

2.3.1 Traitement et analyse des données

Une fois les signaux vibratoires numérisés par la carte d'acquisition (comme la NI USB-4432), ceux-ci sont transmis à l'ordinateur via une interface logicielle. L'ordinateur assure plusieurs fonctions essentielles :

- **Prétraitement** : suppression du bruit résiduel, normalisation, fenêtrage, transformation temporelle ou fréquentielle (FFT, DWT, etc.).
- **Extraction de caractéristiques** : calcul d'indicateurs statistiques (RMS, kurtosis, skewness), énergétiques (bande fréquentielle), ou issus de transformations (coefficients DWT, spectres de fréquence).
- **Réduction de dimension et sélection des paramètres pertinents** pour les modèles d'intelligence artificielle.
- **Diagnostic automatique** : l'ordinateur applique les modèles d'apprentissage automatique ou de deep learning, entraînés à partir de données labellisées pour détecter et classifier les défauts.

2.3.2 Environnement logiciel

Le traitement est effectué dans un environnement de développement adapté. Dans notre cas, l'analyse repose sur l'utilisation d'une base de données vibratoire préexistante, sans phase d'acquisition en temps réel. Les outils Python et MATLAB ont été utilisés pour exploiter cette base de données, notamment à travers des bibliothèques spécialisées en traitement du signal et en apprentissage automatique, permettant l'extraction de caractéristiques, la visualisation et le diagnostic intelligent des défauts.

2.4 Stockage et base de données

Pour assurer la traçabilité des mesures et permettre une amélioration continue des algorithmes, les données sont archivées selon les besoins :

- **Données brutes** : signaux vibratoires au format temporel.
- **Données traitées** : caractéristiques extraites et résultats des analyses.
- **Support de stockage** : fichiers structurés (CSV, MAT) ou base de données locale selon le volume et la fréquence d'acquisition.

Le stockage permet notamment de :

- Suivre l'évolution de l'état de la machine dans le temps,
- Réentraîner les modèles d'IA avec de nouvelles données,
- Comparer différents épisodes de fonctionnement anormal.

2.5 Interface utilisateur et exploitation

L'ordinateur permet également de développer une interface graphique pour visualiser les signaux, afficher les alarmes, ou encore consulter les résultats de diagnostic. Cette visualisation est essentielle pour les opérateurs afin de réagir rapidement en cas de défaillance.

3 Traitement du signal

Comme présenté dans le chapitre précédent, le spectre des défauts des pompes centrifuges présente des composantes spécifiques qui varient en fonction de la nature du défaut. Afin d'analyser ces composantes, il est pertinent de représenter le signal vibratoire dans le domaine fréquentiel. Cette représentation, appelée spectre, met en évidence les fréquences ou harmoniques contenues dans le signal, obtenues à travers l'analyse de Fourier appliquée au signal temporel.

3.1 Analyse de Fourier

3.1.1 Série de Fourier

En 1807, Joseph Fourier présenta sa célèbre théorie [19], selon laquelle toute fonction périodique peut être représentée comme une série infinie de fonctions sinusoïdales. Cette représentation mathématique d'une fonction périodique x(t) est exprimée par l'équation suivante :

$$x(t) = \sum_{k=-\infty}^{\infty} a_k \, e^{jk\omega_0 t} \qquad \text{Éq 10}$$

Avec

$$a_k = \frac{1}{T}\int_0^T f(t)\; e^{-jk\omega_0 t}\, dt \qquad et \qquad T = \frac{2\pi}{\omega_0}$$

3.1.2 Transformé de Fourier

Pour un signal non périodique et continu, le passage du domaine temporel au domaine fréquentiel se réalise à l'aide de la transformée de Fourier.

$$x(\omega) = \int_{-\infty}^{+\infty} f(t)\, e^{-j\omega t} dt \qquad \text{Éq 11}$$

3.1.3 Transformé de Fourier Discrète

En traitement du signal numérique, le signal est discret, et on utilise la DFT :

$$x(k) = \sum_{n=0}^{N-1} x[n] e^{-j2\pi \frac{kn}{N}} \qquad \text{Éq 12}$$

où :

- N : est le nombre total d'échantillons,
- n : est l'indice temporel,
- k : est l'indice fréquentiel.

3.2 Analyse temps-fréquence

La transformé de Fourier ne fournit aucune représentation conjointe temps-fréquence, ce qui constitue une limitation majeure dans le traitement des signaux non stationnaires [20]. En d'autres termes, une fois le signal transformé dans le domaine fréquentiel, on ne peut plus savoir à quel moment chaque fréquence apparaît. Pour surmonter ces limitations, plusieurs approches temps-fréquence ont été développées.

3.2.1 Transformée de Fourier à court terme (STFT)

La Transformée de Fourier à Court Terme (STFT) est une méthode d'analyse temps-fréquence utilisée pour étudier des signaux non stationnaires en décomposant le signal en segments courts et en appliquant la Transformée de Fourier (TF) sur chaque segment.

Pour un signal $x(t)$, la STFT est définie par :

$$STFT(t,f) = \int_{-\infty}^{+\infty} x(\tau).w(\tau - t).e^{-j2\pi f\tau} d\tau \qquad \text{Éq 13}$$

où :

- $x(\tau)$: le signal original,
- $w(\tau - t)$: une fenêtre glissante centrée en tt (ex: fenêtre de Hamming, Hanning, etc.),
- $e^{-j2\pi f\tau}$: le noyau de la TF.

3.2.2 Transformée de Fourier à court terme Discrète (STFTD)

Pour un signal discret $x[n]$, la STFT devient :

$$STFT[m,k] = \sum_{n=-\infty}^{+\infty} x[n].w[n-m].e^{-j\frac{2\pi k}{N}n} \qquad \text{Éq 14}$$

où :

- m : indice temporel (position de la fenêtre),
- k : indice fréquentiel (bin de fréquence),
- N : taille de la FFT.

La STFT trouve des applications variées, notamment dans l'analyse spectrale des signaux vibratoires et l'extraction de caractéristiques pour le traitement du signal, comme les MFCC (Mel-Frequency Cepstral Coefficients) [21]. Elle génère un spectrogramme, une représentation 2D combinant temps, fréquence et amplitude, essentielle pour visualiser l'évolution fréquentielle d'un signal (Figure II-7).

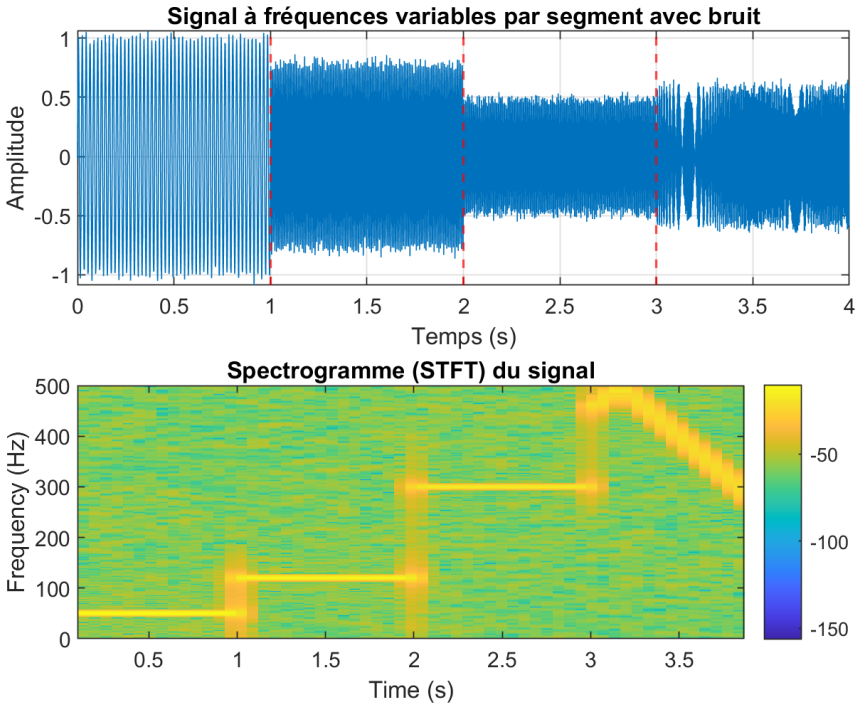


Figure II-7 :Spectrogramme (STFT)

3.3 Transformé en ondelettes

La STFT analyse un signal en le découpant en fenêtres fixes, offrant une représentation temps-fréquence [20]. Cependant, sa résolution constante la rend inadaptée aux signaux non stationnaires. Les ondelettes résolvent cette limite par une résolution adaptative : basse résolution fréquentielle (haute résolution temporelle) pour les hautes fréquences, et inversement pour les basses fréquences [20] .

Introduite dans les années 1970 par Y. Meyer [22] pour l'analyse du signal (notamment pétrolière), l'analyse par ondelettes a été formalisée dans les années 1980 par J. Morlet et al., devenant une théorie mathématique aboutie [19].

3.3.1 Définition d'une ondelette

Une ondelette est une fonction qui, à l'image d'une onde, présente un comportement oscillant, mais qui est fortement atténuée dans le temps, ce qui justifie son nom, c'est-à-dire une petite onde [20].

L'analyse en ondelettes continue repose sur une ondelette mère (Éq 15) localisée dans le temps et la fréquence. En la dilatant (paramètre a) et en la translatant (paramètre b), on génère une famille de fonctions analysantes :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi(\frac{t-b}{a}) \qquad \text{Éq 15}$$

Cette approche permet d'adapter l'analyse à différentes échelles et positions, rendant l'étude des signaux particulièrement efficace.

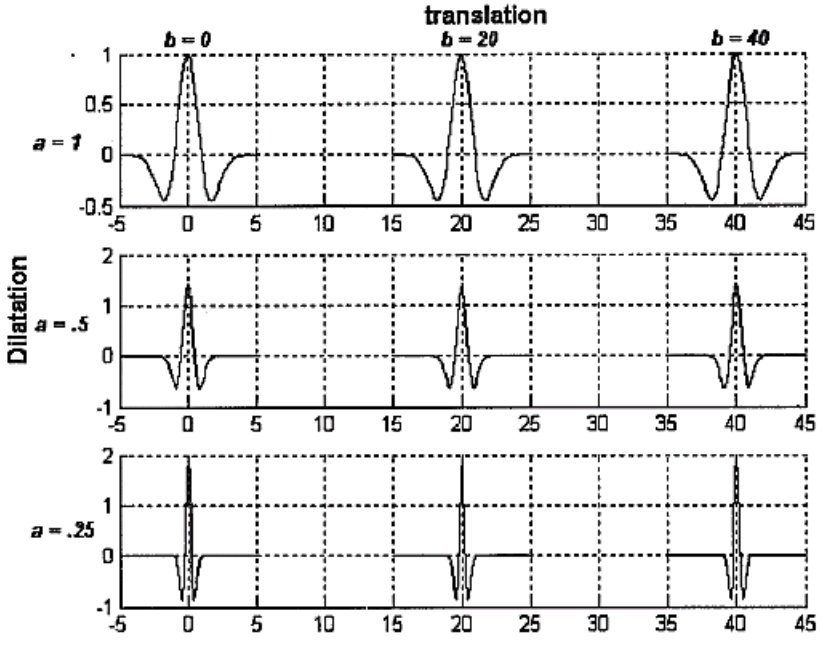


Figure II-8 : Translation et dilatation des ondelettes

3.3.2 Transformée en ondelettes continue (CWT)

L'analyse en ondelettes continue (Continuous Wavelet Transform, CWT) est une technique qui permet de représenter un signal en fonction du temps et de l'échelle (ou fréquence), en utilisant des ondelettes.

On projette le signal x(t) sur une famille d'ondelettes obtenue par translation et dilatation d'une ondelette mère ψ(t). Cela donne le coefficient de corrélation entre le signal et chaque ondelette à un instant et une échelle donnée. La transformée en ondelettes continue est définie par [23] :

$$CWT_x(a,b) = \int_{-\infty}^{+\infty} x(t).\frac{1}{\sqrt{a}}\psi^*\left(\frac{t-b}{a}\right)dt \qquad \text{Éq 16}$$

Prenons un signal composé de deux sinusoïdes de fréquences différentes, l'une présente au début, l'autre plus tard, la figure II-9 illustre la représentation du CWT de ce signal:

$$x(t) = sin(2\pi 5t)\, pour\ t < 1, sin(2\pi 20t)\, pour\ t \geq 1 \qquad \text{Éq 17}$$

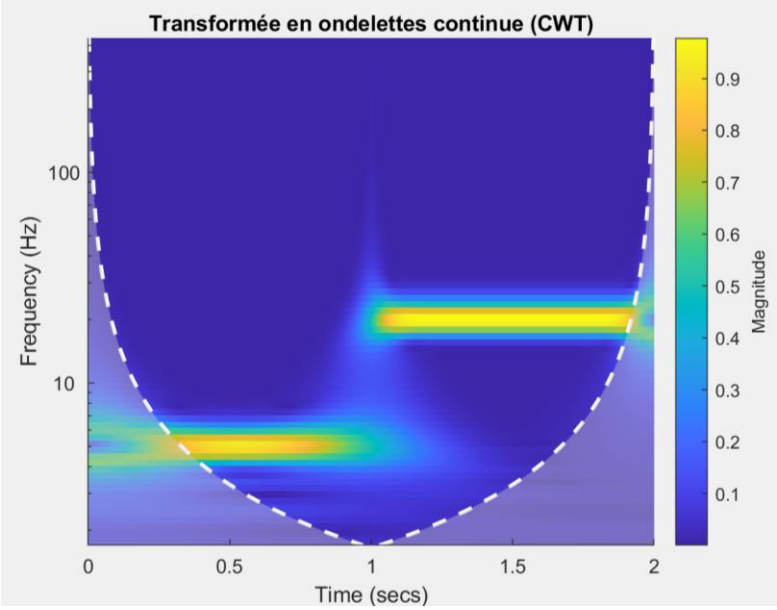


Figure II-9 : Transformée en ondelettes (CWT)

3.3.3 Transformée en ondelettes discrète

Contrairement à la CWT, qui reste redondante et coûteuse en calcul, la DWT offre une représentation compacte et efficace, particulièrement bien adaptée à l'analyse de signaux discrets en contexte numérique.

Dans la transformée en ondelettes discrètes (DWT), les fonctions de base sont obtenues par dilatation dyadique ($a = 2^{-j}$) et translation discrète ($b = k \cdot 2^{-j}$). Pour un signal discrétisé avec un

pas d'échantillonnage unitaire, la DWT s'exprime comme une somme pondérée de fonctions de base dilatées et translatées :

$$DWT\left(2^{-j}, k2^{-j}\right) = 2^{\frac{j}{2}} \sum_{n} x(n)\ \psi(2^{j}n - k) \qquad \text{Éq 18}$$

La transformée en ondelettes discrètes (DWT) permet de décomposer un signal en composantes d'approximation et de détail à différentes résolutions. Elle repose sur l'utilisation de filtres passe-bas et passe-haut suivis d'un sous-échantillonnage (Figure II-10 et II-11). Le calcul est efficacement réalisé par l'algorithme de Mallat.

L'algorithme de Mallat s'applique de manière itérative :

- Un **filtre passe-bas** pour extraire les **approximations**,
- Un **filtre passe-haut** pour extraire les **détails**.

À chaque étape, seule la sortie du filtre passe-bas est utilisée pour continuer la décomposition.

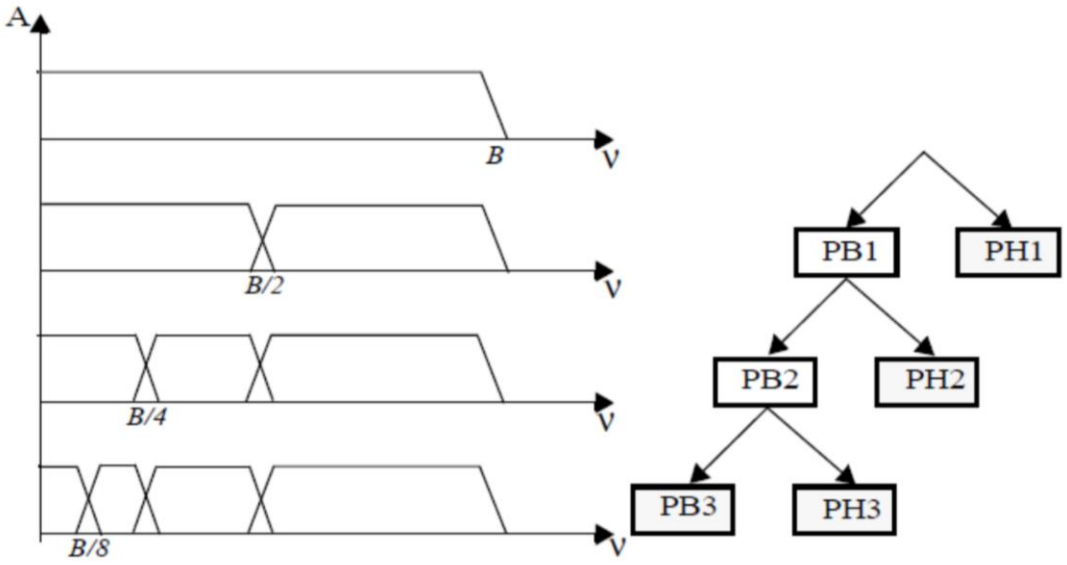


Figure II-10 : Décomposition par bancs de filtres

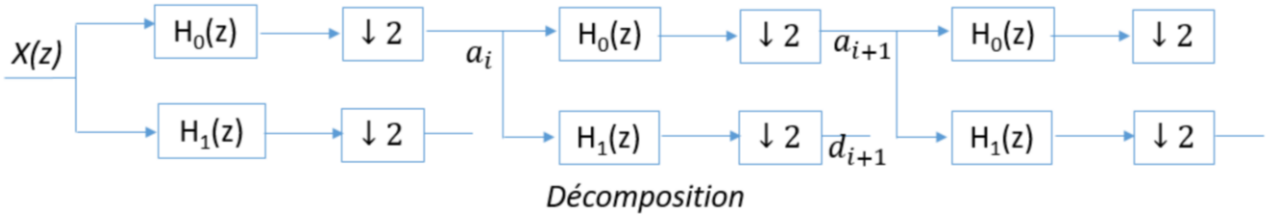


Figure II-11 : Décomposition par algorithme de Mallat

La décomposition suivant l'algorithme de Mallat est obtenue par :

$$a_{j+1}[n] = \sum_k h_0[2n-k]a_j[k] \qquad \text{Éq 19}$$

$$d_{j+1}[n] = \sum_k h_1[2n-k]a_j[k] \qquad \text{Éq 20}$$

La figure suivante illustre un exemple d'un signal chirp linéaire de 100 Hz à 5 kHz bruité, ainsi que sa décomposition en ondelettes discrètes (DWT) sur 4 niveaux, mettant en évidence les composantes fréquentielles distinctes (approximation A4 et détails D1-D4), chacune représentée par une couleur spécifique.

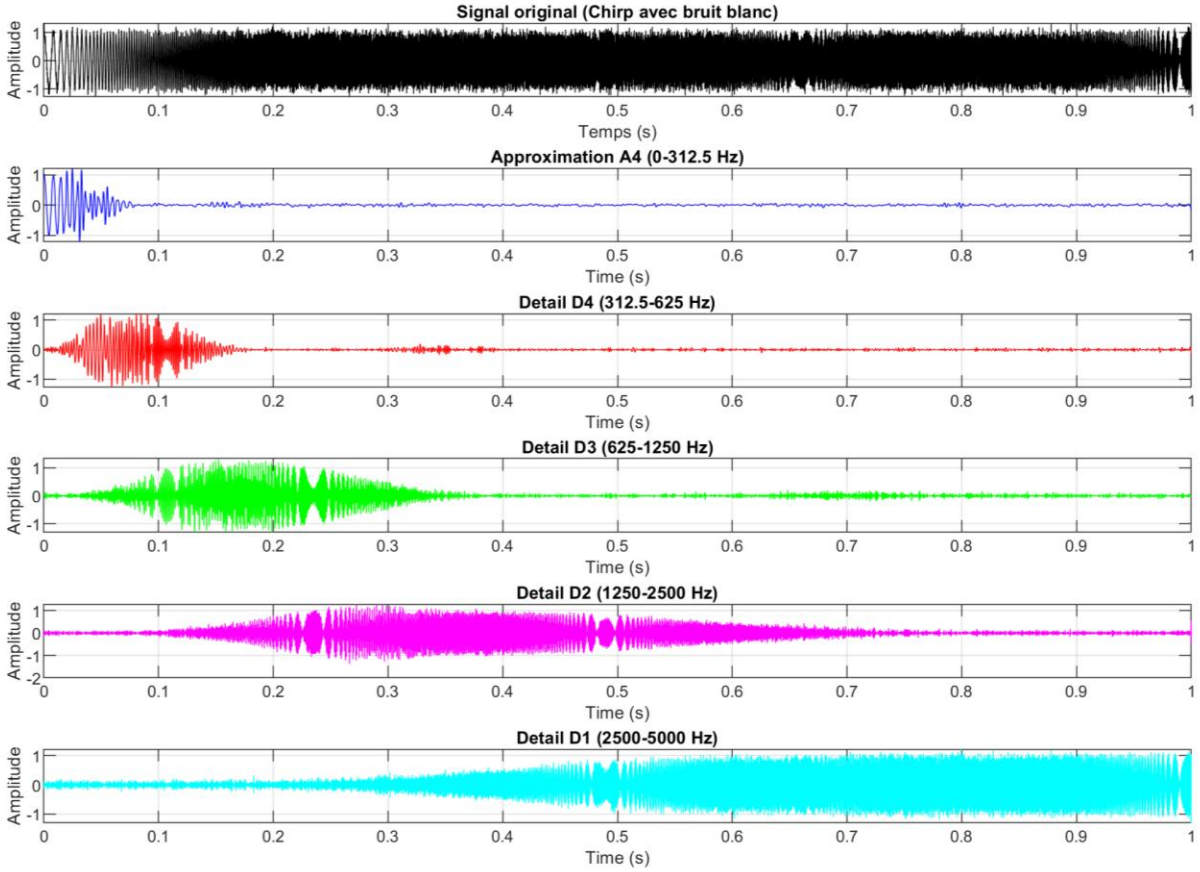


Figure II-12: Signal Chirp décomposé par ondelette discrète

4 Intelligence artificielle

L'intelligence artificielle (IA) constitue aujourd'hui un domaine scientifique interdisciplinaire à la croisée de l'informatique, des mathématiques appliquées et des sciences

cognitives [24]. Son émergence comme discipline académique remonte aux travaux fondateurs de Turing (1950) [25] et McCarthy (1956) [26], mais connaît depuis une décennie une accélération remarquable grâce aux avancées conjointes en puissance computationnelle, disponibilité des données et sophistication des algorithmes.

4.1 Définition de l'IA

l'IA peut être définie comme l'ensemble des théories et techniques visant à reproduire, simuler ou étendre certains aspects de l'intelligence humaine par des systèmes artificiels [27].

Le développement de l'intelligence artificielle a donné naissance à plusieurs sous-domaines spécialisés, notamment l'apprentissage automatique (Machine Learning), l'apprentissage profond (Deep Learning) et divers systèmes prédictifs dont les relations conceptuelles et les délimitations précises restent souvent floues dans la pratique professionnelle [28].

La relation hiérarchique entre ces concepts peut être représentée par des cercles concentriques :

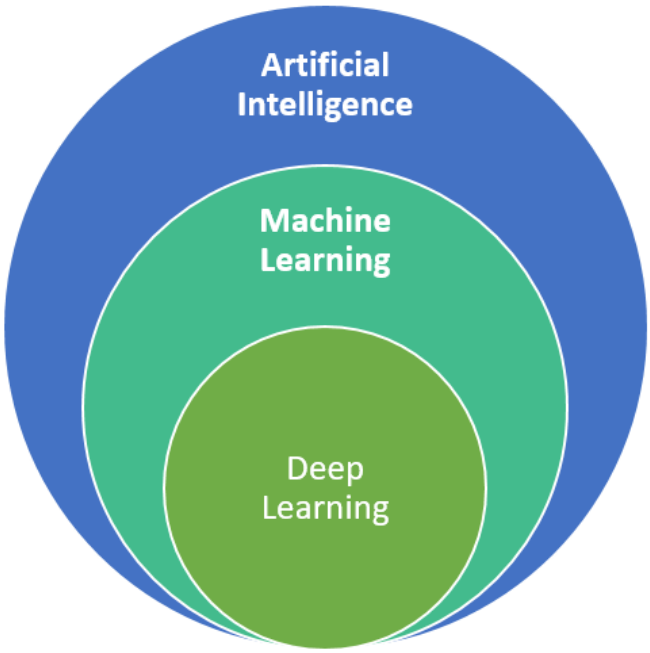


Figure II-13 : IA, ML, DL

- **Intelligence Artificielle (IA)** : Discipline visant à créer des systèmes capables d'exécuter des tâches nécessitant normalement l'intelligence humaine.
- **Apprentissage Automatique (Machine Learning)** : Sous-domaine de l'IA où les systèmes apprennent à partir de données sans être explicitement programmés.
- **Apprentissage Profond (Deep Learning)** : Type spécifique de ML utilisant des réseaux neuronaux profonds pour apprendre des représentations hiérarchiques des données.

4.2 Machine Learning

Le schéma suivant présente une classification hiérarchique des différents types d'algorithmes en Machine Learning, selon quatre grandes familles : apprentissage supervisé (Supervised Learning), apprentissage non supervisé (Unsupervised Learning), apprentissage semisupervisé (Semi-Supervised Learning), et apprentissage par renforcement (Reinforcement Learning) [29]. Chacune de ces familles regroupe des techniques spécifiques adaptées à des tâches particulières.

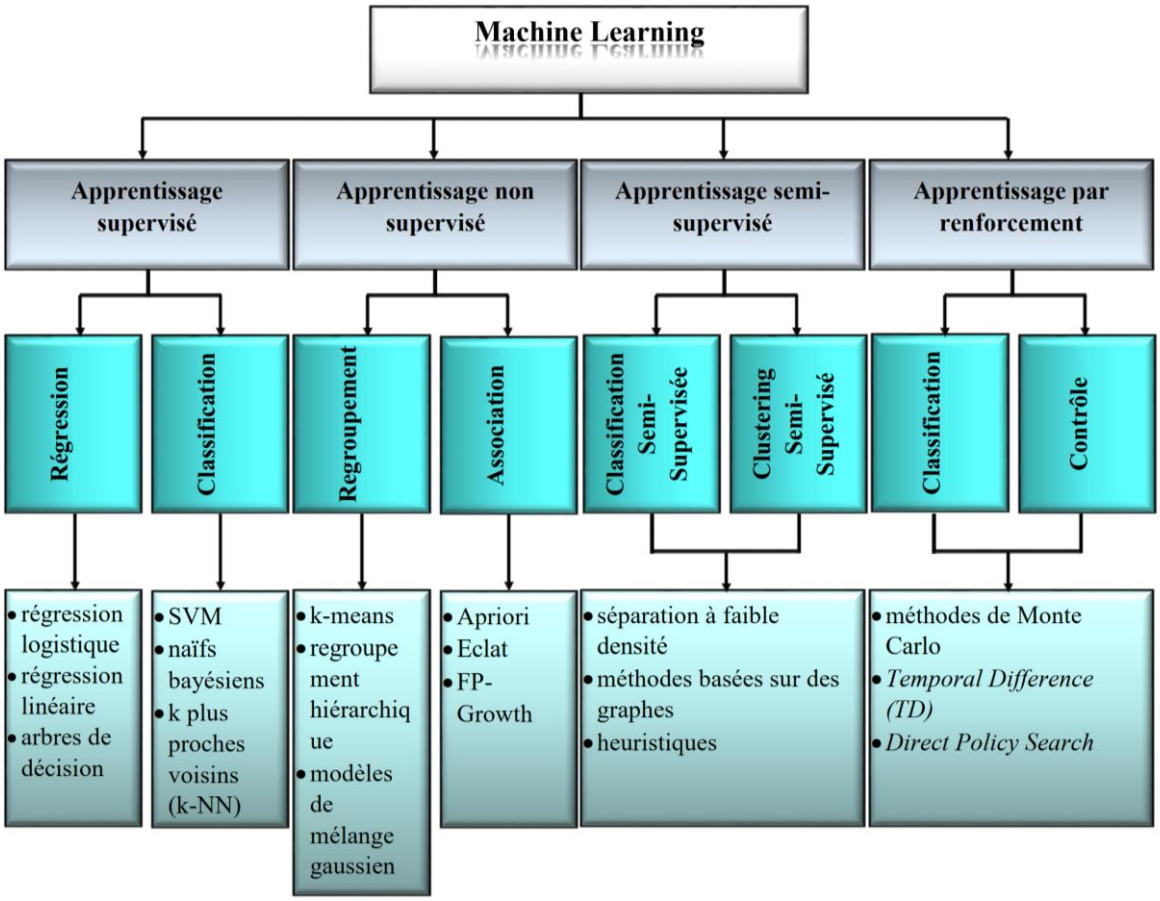


Figure II-14 : Types d'algorithmes d'apprentissage automatique

4.2.1 Apprentissage supervisé

L'apprentissage supervisé consiste à entraîner un modèle à partir de **données étiquetées**, c'est-à-dire pour lesquelles chaque entrée est associée à une sortie attendue (label). Le modèle apprend à faire des prédictions ou des classifications en généralisant à partir des exemples fournis [28].

Exemple : Classification d'e-mails comme "spam" ou "non-spam".

- **Régression :** La régression est utilisée pour prédire une valeur continue. Par exemple, on peut utiliser la régression linéaire pour estimer la température ou la consommation d'énergie en fonction de variables d'entrée [30] [31].
- **Classification :** La classification consiste à attribuer une étiquette ou une classe à une entrée inconnue. Ces méthodes sont robustes pour identifier les classes dans des jeux de données complexes [32] [31].

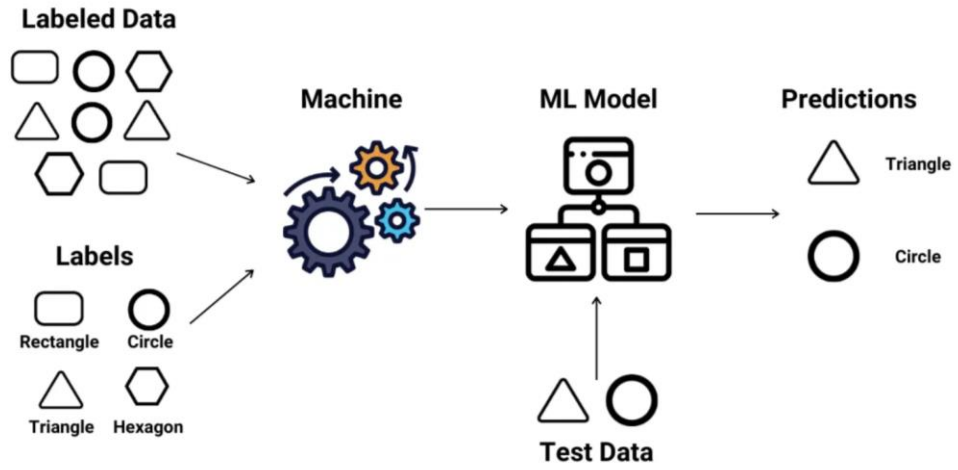


Figure II-15 : Apprentissage supervisé : entraînement sur des entrées/étiquettes pour prédire des entrées inconnue

4.2.2 Apprentissage non supervisé

Dans l'apprentissage non supervisé, les données ne sont pas étiquetées. L'objectif est de découvrir des structures sous-jacentes, comme des regroupements (clustering) ou des réductions de dimensionnalité [33].

Exemple : Regrouper des clients par comportement d'achat (segmentation de marché).

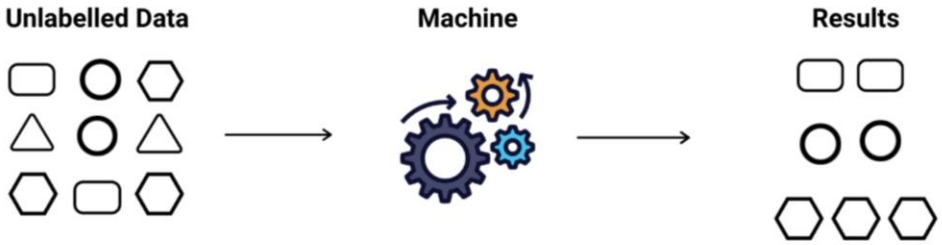


Figure II-16 : Apprentissage non-supervisé : regroupement automatique des entrées sans étiquettes

- **Regroupement (Clustering) :** Le clustering permet de diviser un jeu de données en groupes (ou clusters) dont les membres sont similaires [31] [34].
- **Association :** Les règles d'association visent à trouver des relations fréquentes entre des variables dans de grandes bases de données [34].

4.2.3 Apprentissage par renforcement (Reinforcement Learning)

L'apprentissage par renforcement repose sur un système d'agents qui apprennent à prendre des décisions en interagissant avec un environnement. L'agent reçoit des récompenses ou des punitions en fonction de ses actions, ce qui l'amène à améliorer ses performances au fil du temps [35].

Exemple : Enseigner à un robot à marcher ou à un programme à jouer à un jeu.

4.2.4 Apprentissage Semi-Supervisé (Semi-Supervised Learning)

L'apprentissage semi-supervisé combine un petit ensemble de données étiquetées avec un grand volume de données non étiquetées pour entraîner un modèle. Cela permet d'exploiter les données disponibles tout en limitant les coûts de labellisation. Cette méthode est très utile dans des contextes où l'annotation manuelle est difficile ou coûteuse [32] [28].

4.3 Théorie des algorithmes d'IA

4.3.1 Perceptron

Le perceptron est un modèle d'intelligence artificielle inspiré directement du neurone biologique. Ce dernier, composé de dendrites, d'un soma, et d'un axone, traite des signaux électriques transmis entre cellules nerveuses [36].

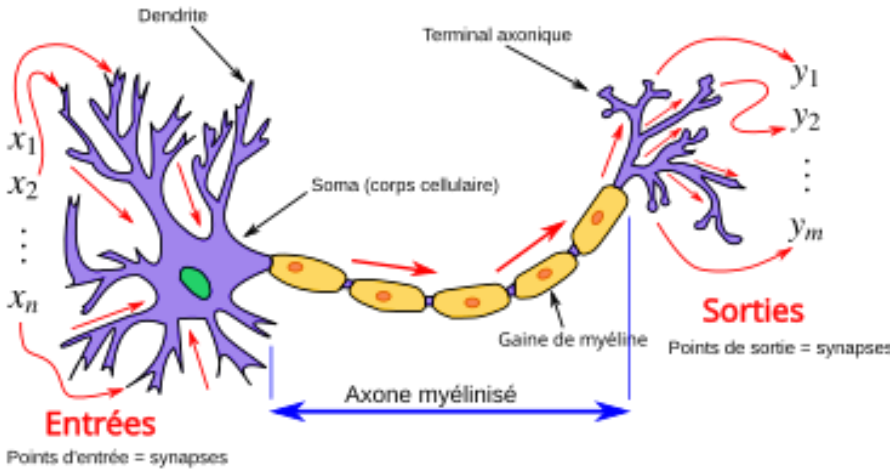


Figure II-17 : Neurone Biologique

En 1943, McCulloch et Pitts [37] ont proposé le premier modèle mathématique du neurone artificiel, sous forme d'un circuit logique simple. En 1958, Frank Rosenblatt [36] introduit le perceptron, capable de classer linéairement des données. Il associe à chaque entrée un poids, calcule une somme pondérée, puis applique une fonction d'activation pour décider si la sortie est activée ou non. Les poids sont ajustés automatiquement durant l'apprentissage selon l'erreur commise [28].

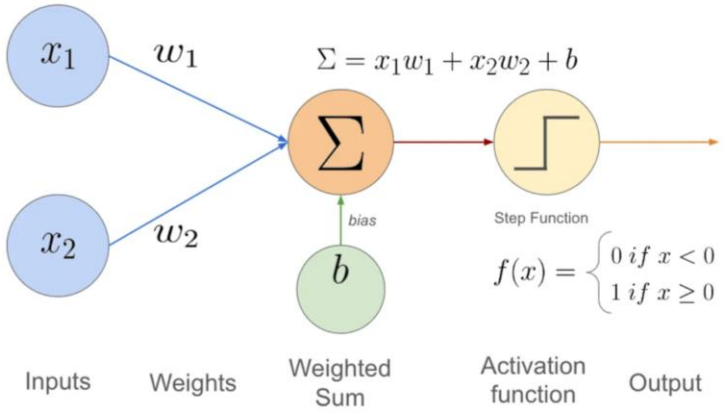


Figure II-18 : Perceptron (neurone artificiel)

4.3.2 Réseau de neurones artificiels

Un réseau de neurones est une architecture composée de neurones artificiels interconnectés, capables de traiter plusieurs entrées pour générer une unique sortie. En général, il comprend une couche d'entrée, une couche de sortie, et une ou plusieurs couches intermédiaires appelées couches cachées. On parle d'Artificial Neural Network (ANN) lorsqu'il n'y a qu'une seule couche cachée, tandis que les Deep Neural Networks (DNN) comportent plusieurs couches cachées, ce qui leur permet de modéliser des relations plus complexes [28].

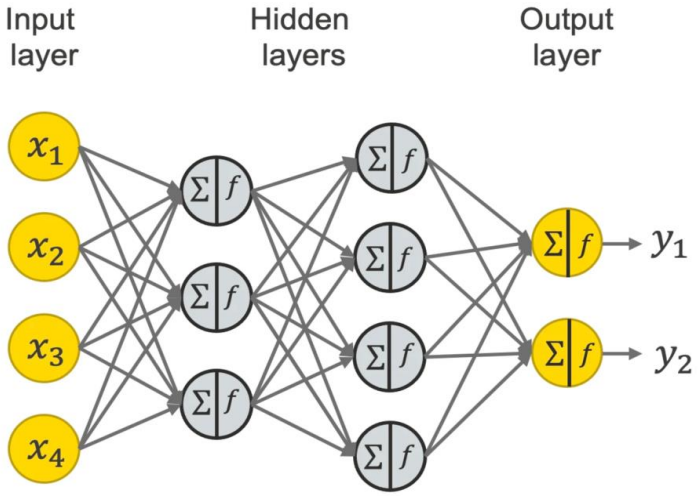


Figure II-19 : Architecture d'un réseau de neurones artificiels

4.3.3 Fonctions d'activation

Les fonctions d'activation sont des composantes essentielles des réseaux de neurones, permettant d'introduire des non-linéarités et de rendre possible l'apprentissage de modèles complexes [28]. Parmi les fonctions d'activation les plus couramment utilisées, on retrouve :

- **Fonction Seuil (Échelon Unité) :** Cette fonction d'activation, la plus simple, est définie par :

$$f(x) = \begin{cases} 1 \; si \; x \geq 0 \\ 0 \; si \; x < 0 \end{cases} \qquad \text{Éq 21}$$

  Sortie 1 si l'entrée pondérée x est positive ou nulle.

  Sortie 0 si x est strictement négative.

- **Sigmoïde :** Elle transforme l'entrée en une valeur entre 0 et 1, mais peut provoquer des problèmes de vanishing gradient lors de l'apprentissage profond.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \qquad \text{Éq 22}$$

- **Tanh (hyperbolique tangente) :** Similaire à la sigmoïde mais centrée sur zéro, elle est souvent plus efficace dans les couches cachées.

$$Tanh(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}} \qquad \text{Éq 23}$$

- **ReLU (Rectified Linear Unit) :** C'est actuellement l'une des fonctions les plus utilisées pour sa simplicité et son efficacité en apprentissage profond, bien qu'elle puisse souffrir du problème de "neurones morts".

$$ReLU(x) = max(0, x) \qquad \text{Éq 24}$$

- **Softmax :** utilisée principalement dans la couche de sortie pour les tâches de classification multi-classes, elle transforme un vecteur de valeurs réelles en une distribution de probabilités. Mathématiquement, pour un vecteur d'entrée y=(y1,…,yn) on définit :

$$Softmax(y_i) = \frac{e^{y_i}}{\sum_{j=1}^{n} e^{y_i}} \qquad \text{Éq 25}$$

  Où n est le nombre total de classes.

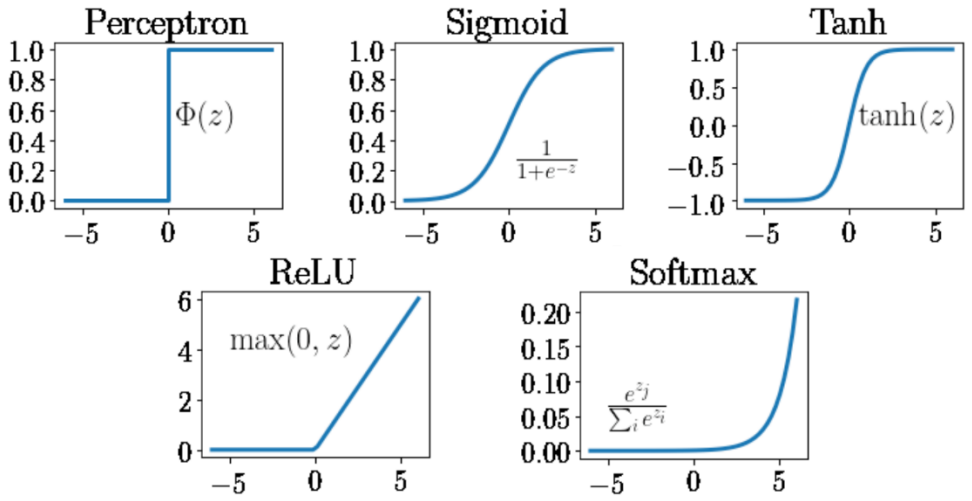


Figure II-20 : Fonctions d'activation

4.3.4 Étapes d'apprentissage des réseaux de neurones

L'apprentissage d'un réseau de neurones se déroule en plusieurs étapes successives, qui permettent au modèle d'ajuster ses poids internes afin de minimiser l'erreur entre les prédictions et les valeurs réelles [28]. Les principales étapes sont les suivantes :

1. **Initialisation** : Les poids du réseau sont initialisés (souvent aléatoirement) avant l'entraînement.
2. **Propagation avant (forward propagation) :** Les données d'entrée sont transmises à travers le réseau, couche par couche, jusqu'à produire une sortie prédite. Cette étape repose sur l'application de fonctions d'activation après chaque couche.
3. **Calcul de l'erreur (fonction de perte)** : L'écart entre la sortie prédite et la sortie réelle (étiquette) est mesuré à l'aide d'une fonction de coût (par exemple : entropie croisée, erreur quadratique moyenne).
4. **Rétropropagation (backpropagation)** : L'erreur est propagée en sens inverse dans le réseau, à l'aide du théorème de la dérivation en chaîne. Cela permet de calculer le gradient de l'erreur par rapport à chaque poids.
5. **Mise à jour des poids (optimisation)** : Les poids sont ajustés à l'aide d'un algorithme d'optimisation (comme la descente de gradient ou Adam) pour réduire l'erreur lors de l'itération suivante.
6. **Répétition (boucle d'apprentissage)** : Ces étapes sont répétées sur plusieurs époques et lots de données (batchs) jusqu'à ce que la performance du réseau se stabilise.

4.3.5 Surapprentissage et sous-apprentissage

- **Surapprentissage (Overfitting) :** Le surapprentissage se produit lorsqu'un modèle apprend trop précisément les données d'entraînement, y compris le bruit et les détails spécifiques qui ne sont pas représentatifs des données générales. Cela donne l'impression que le modèle fonctionne très bien sur l'ensemble d'entraînement, mais il échoue à prédire correctement sur des données nouvelles ou non vues.

  Symptôme : Erreur très faible sur l'entraînement, mais élevée sur la validation/test.

  Solutions :

  - Régularisation (L2, Dropout)
  - Réduction de la complexité du modèle
  - Augmentation de données (data augmentation)
  - Early stopping (Arrêt anticipé d'apprentissage)

- **Sous-apprentissage (Underfitting) :** Le sous-apprentissage survient lorsqu'un modèle est trop simple ou mal entraîné pour capturer les motifs importants dans les données. Il n'arrive pas à bien performer, même sur les données d'entraînement.

  Symptôme : Erreur élevée à la fois sur l'entraînement et la validation.

  Causes possibles :

  - Trop peu de neurones ou de couches
  - Temps d'entraînement insuffisant
  - Fonction d'activation ou d'optimisation mal choisie

  Solutions :

  - Utiliser un modèle plus complexe (DNN au lieu d'ANN)
  - Former plus longtemps
  - Changer l'architecture ou les hyperparamètres

4.3.6 Répartition des données

Quand on entraîne un modèle, on ne veut pas juste qu'il mémorise les données, mais qu'il puisse généraliser à de nouvelles données jamais vues. C'est pour cela qu'on divise les données en plusieurs ensembles.

- **Données d'entraînement (Training Set)** : cet ensemble est utilisé pour apprendre les paramètres du modèle (ex. : les poids dans un réseau de neurones). Le model s'ajuste pour minimiser l'erreur sur cet ensemble. Leur pourcentage typique est environ 60% à 80% des données totales.
- **Données de validation (Validation Set) :** cet ensemble est utilisé pour évaluer le model entre les époques, ajuster les hyperparamètres comme le taux d'apprentissage et surveiller le surapprentissage. Leur pourcentage typique est entre 10% à 20%.
- **Données de test (Test Set) :** ces données ne doivent jamais être utilisées pendant l'entrainement. Elles sont utilisées pour évaluer la performance finale du modèle après l'entraînement et la validation. Leur pourcentage est entre 10% à 20%.

4.3.7 Arbres de décision et forêts aléatoires (Decision Trees & Random Forest)

Un arbre de décision est un algorithme d'apprentissage supervisé qui divise récursivement les données en sous-groupes homogènes en posant des questions (conditions) sur les attributs (features). L'objectif est de construire une structure en forme d'arbre où chaque nœud interne représente une condition et chaque feuille correspond à une classe prédite [38]. À chaque nœud, l'algorithme choisit la meilleure variable de séparation selon une mesure d'impureté (comme l'entropie) et construit une structure en forme d'arbre [39].

L'entropie permet de mesurer l'incertitude ou de l'hétérogénéité dans les données.

$$H(s) = -\sum_{i=1}^{k} p_i log_2 p_i \qquad \text{Éq 26}$$

La figure ci-dessous illustre un arbre de décision utilisé pour prédire une action (jouer ou non) à partir de quatre variables : le temps, la température, l'humidité et la présence de vent.

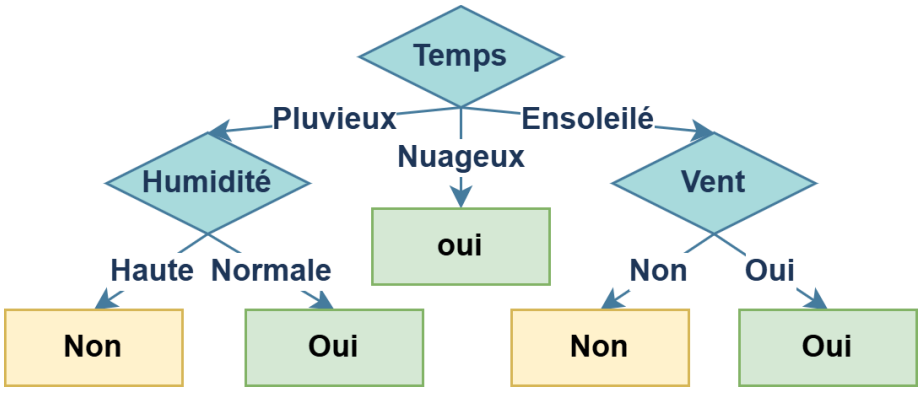


Figure II-21 : Arbre de décision (decision tree)

Les forêts aléatoires (Random Forest) sont des ensembles d'arbres de décision construits à partir d'échantillons aléatoires des données, permettant de réduire le surapprentissage et d'améliorer la robustesse du modèle. Ces modèles sont très utilisés en maintenance prédictive et en diagnostic de pannes [32].

4.3.8 XGBoost

XGBoost repose sur l'utilisation d'arbres de décision faibles enchaînés selon le principe du gradient boosting. Chaque arbre est entraîné pour corriger les erreurs des arbres précédents, formant ainsi un modèle performant et robuste [40].

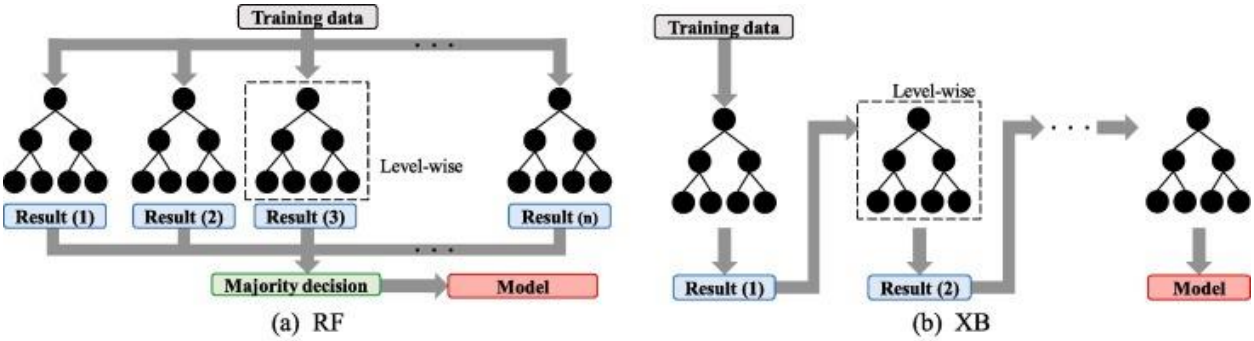


Figure II-22 : Random Forest vs XGBoost

4.3.9 Machines à Vecteurs de Support (SVM) (SVC)

Les SVM sont des modèles puissants pour les tâches de classification binaire. Ils cherchent à trouver l'hyperplan optimal qui sépare les données de deux classes avec la plus grande marge possible. Grâce à l'utilisation de noyaux (kernels), ils peuvent aussi gérer des séparations non linéaires. Les SVM sont performants même sur de petits ensembles de données, ce qui les rend utiles dans des contextes industriels où les données annotées sont rares [39].

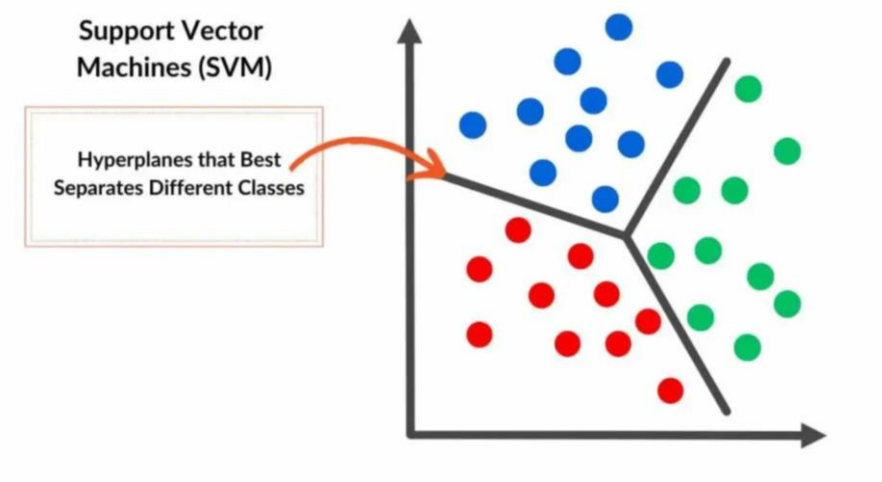


Figure II-23 : SVM

4.3.10 Autres modèles d'intelligence artificielle

Il existe d'autres approches d'IA qui ont montré une efficacité remarquable selon le type de données et l'application.

- **Naive Bayes :** Basé sur le théorème de Bayes et l'hypothèse d'indépendance entre les variables, ce classificateur est rapide, simple et efficace notamment pour le filtrage de spam et la classification de documents [32].
- **Convolutional Neural Networks (CNN) :** Spécialement conçus pour les images et les données structurées, les CNN utilisent des couches de convolution pour extraire automatiquement les caractéristiques, réduisant le besoin de prétraitement. Ils sont très utilisés en vision par ordinateur et surveillance industrielle [41].
- **Recurrent Neural Networks (RNN) :** Adaptés aux données séquentielles, les RNN peuvent mémoriser des informations dans le temps. Les variantes comme les LSTM améliorent cette mémoire à long terme. Ils sont utilisés en prédiction de pannes, traitement du langage ou encore en maintenance prédictive [42].
- **Generative Adversarial Networks (GANs) :** Ces modèles non supervisés reposent sur un duel entre un générateur et un discriminateur, permettant de produire des données synthétiques réalistes. Ils sont utilisés pour la génération de données, la détection d'anomalies et la simulation de scénarios industriels [43].

4.4 Préparation des Données

4.4.1 Normalisation des données

La normalisation des données est une étape cruciale du prétraitement. Elle permet de mettre toutes les caractéristiques sur une échelle comparable, facilitant ainsi la convergence des algorithmes d'apprentissage automatique et améliorant la performance globale du modèle. Parmi les méthodes de normalisation les plus couramment utilisées on trouve le StandardScaler [44].

Chaque caractéristique est transformée de manière à avoir une moyenne de 0 et un écart-type de 1 en utilisant :

$$z = \frac{x - \mu}{\sigma} \qquad \text{Éq 27}$$

Avec μ la moyenne, et σ la déviation standard

$$\mu = \frac{1}{n}\sum_{i=1}^{n} x_i \qquad \text{Éq 28}$$

$$\sigma = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(x_i - \mu)^2} \qquad \text{Éq 29}$$

4.4.2 Encodage des étiquettes (LabelEncoder)

Les classes cibles catégorielles sont transformées en entiers (0, 1, …) pour être interprétées par les algorithmes de classification [44].

4.5 Évaluation des Modèles développés

Lorsqu'un modèle d'IA est entraîné à reconnaître les signes d'un défaut mécanique, il ne suffit pas de savoir qu'il « fonctionne ». Il faut évaluer à quel point il fonctionne et avec quelle précision.

Un bon modèle doit non seulement être précis, mais aussi stable, généralisable (performant sur de nouvelles données) et cohérent dans ses prédictions. Pour cela, plusieurs méthodes et métriques sont utilisées.

4.5.1 Courbe d'apprentissage (Learning curve)

La courbe d'apprentissage montre comment la performance du modèle évolue avec plus d'itérations d'entraînement. Généralement, on affiche le nombre d'itérations (époques) sur l'axe X et le score (ex. : précision, perte, F1-score) sur l'axe Y.

Parmi ces indicateurs, la fonction de perte (Loss) joue un rôle important : elle mesure l'erreur du modèle pendant l'apprentissage. Bien qu'elle ne soit pas une métrique de performance directe, elle fournit une indication essentielle sur la manière dont le modèle apprend. Une perte faible est souhaitable, à condition qu'elle s'accompagne de bonnes performances sur les données de validation, indiquant une bonne capacité de généralisation.

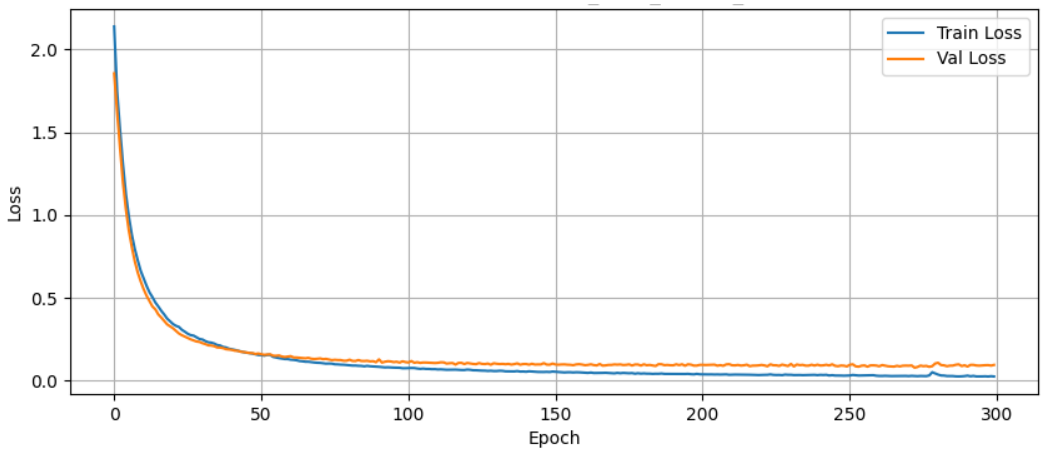


Figure II-24 : Courbe d'apprentissage d'un réseau ANN

L'analyse conjointe des courbes de perte et de performance permet d'identifier les phénomènes de sous-apprentissage (*underfitting*), lorsque la perte reste élevée et les scores de performance sont faibles pour l'entraînement comme pour la validation. À l'inverse, un surapprentissage (*overfitting*) se manifeste par une perte faible et de bonnes performances sur l'ensemble d'entraînement, mais des résultats dégradés sur l'ensemble de validation. Une bonne généralisation se traduit par une perte faible et des scores de performance élevés, proches entre les deux ensembles.

4.5.2 Matrice de confusion

La matrice de confusion est un outil visuel fondamental pour évaluer la performance d'un modèle de classification. Elle compare les prédictions du modèle avec les valeurs réelles (véridiques). Dans cet exemple, la matrice de confusion 2x2 permet de visualiser les performances du modèle en distinguant les cas suivants :

- **Vrais positifs (VP)** : nombre de fois où le modèle a correctement prédit la classe 1 (Défaut).
- **Vrais négatifs (VN)** : nombre de fois où le modèle a correctement prédit la classe 0 (Normal).
- **Faux positifs (FP)** : nombre de fois où le modèle a prédit la classe 1 alors que la vraie classe était 0.
- **Faux négatifs (FN)** : nombre de fois où le modèle a prédit la classe 0 alors que la vraie classe était 1.

Pour cet exemple, les valeurs obtenues sont : VP = 40, VN = 42, FP = 11, FN = 7

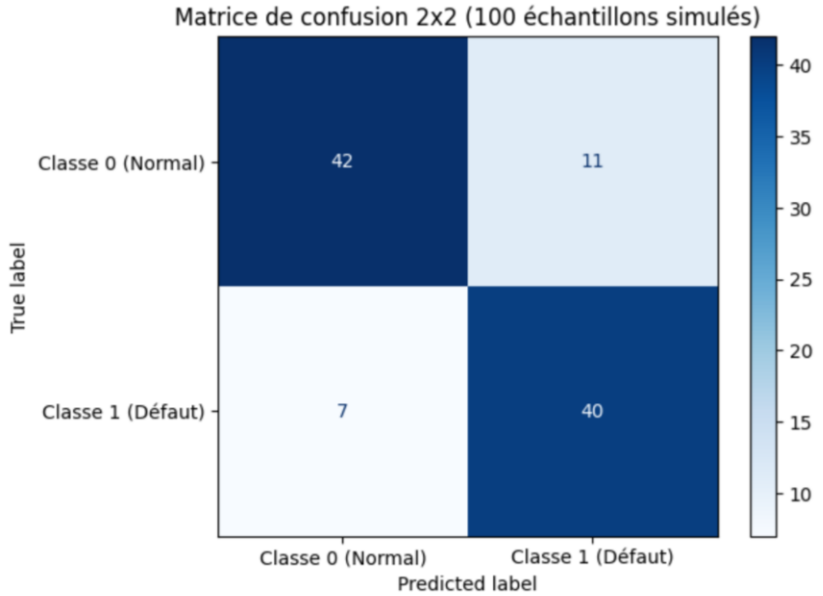


Figure II-25 : Exemple de matrice de confusion

4.5.3 Exactitude (Accuracy)

Pourcentage de prédictions correctes (positives et négatives) par rapport au total. On l'utilise généralement lorsque les classes sont équilibrées.

$$Exactitude = \frac{VP + VN}{VP + VN + FP + FN} \qquad Éq\ 30$$

Avec : VP : vrais positif ; VN : vrais négatif ; FP : faux positif ; FN : faux négatif

4.5.4 Précision

Pourcentage de prédictions positives correctes. On l'utilise quand les faux positifs sont coûteux.

$$Précision = \frac{VP}{VP + FP} \qquad Éq\ 31$$

4.5.5 Rappel (recall)

Le rappel (recall) mesure la capacité du modèle à retrouver tous les cas pertinents (positifs).

$$Recall = \frac{VP}{VP + FN} \qquad Éq\ 32$$

4.5.6 Score F1

C'est une moyenne harmonique entre la précision et le rappel.

$$F1 = 2 \times \frac{P \times R}{P + R} \qquad Éq\ 33$$

Avec : P (Précision) et R (Rappel).

4.5.7 Moyenne macro

C'est la moyenne non pondérée des scores de chaque classe. Elle est obtenue par le calcul de score de chaque classe individuellement puis calculer leur moyenne.

$$Moyenne\ Macro = \frac{1}{N}\sum_{i=1}^{N} Metric_i \qquad Éq\ 34$$

4.5.8 Moyenne pondérée

C'est la moyenne de la métrique sur toutes les classes, pondérée par le nombre d'exemples réels (support) dans chaque classe. On calcule la métrique pour chaque classe, puis on effectue une somme pondérée en fonction du nombre d'exemples réels dans chaque classe.

$$Moyenne\ pondérée = \frac{\sum_{i=1}^{N}(Support_i \times Metric_i)}{\sum_{i=1}^{N} Support_i} \qquad Éq\ 35$$

5 Conclusion

Ce chapitre souligne que la qualité du diagnostic vibratoire repose sur deux volets complémentaires : la collecte et le prétraitement des signaux, puis leur exploitation via l'intelligence artificielle. La première partie a détaillé la chaîne d'acquisition, du choix des capteurs à la conversion numérique, garantissant un signal fidèle et nettoyé, exploité par des méthodes classiques comme la FFT, STFT et DWT pour extraire des caractéristiques robustes.

La seconde partie a présenté l'apport de l'IA pour automatiser la détection des défauts, en exposant les principaux algorithmes (perceptron, réseaux neuronaux, arbres de décision, SVM, XGBoost) et l'importance de préparer les données pour éviter l'overfitting. L'évaluation des modèles via les métriques de classification, la matrice de confusion et les courbes d'apprentissage a été aussi mise en avant, avec la gestion des hyperparamètres garantissant la fiabilité de la surveillance.

En résumé, le succès d'un système prédictif dépend autant de la rigueur du traitement du signal que de la pertinence des algorithmes IA, combinant ingénierie et apprentissage automatique pour un diagnostic rapide, précis et autonome, clé de la maintenance proactive.

Chapitre III
Expérimentation, analyse des résultats et implémentation

1 Introduction

Ce chapitre présente les étapes clés de l'expérimentation, depuis le choix et l'entraînement des modèles d'apprentissage jusqu'à l'évaluation de leurs performances. Plusieurs algorithmes sont comparés selon des critères de précision, robustesse et complexité. L'objectif est d'identifier la méthode la plus adaptée pour une future implémentation embarquée dans un système de surveillance de pompes.

Enfin, ce chapitre aborde l'implémentation embarquée d'un modèle optimisé sur une carte ESP32. Cette étape vise à démontrer la faisabilité d'un système de surveillance autonome, capable d'effectuer un diagnostic en temps réel directement à la source. L'accent est mis sur la simplification du modèle, la conversion du code pour compatibilité avec la plateforme embarquée, ainsi que sur les tests fonctionnels réalisés sur le microcontrôleur.

2 Présentation de la base de données

2.1 Origine et source de la base de données

Pour les besoins de cette étude, nous avons utilisé une base de données publique intitulée « NLN-EMP - Motor Current and Vibration Monitoring Dataset for various Faults in an E-motor-driven Centrifugal Pump » [45].

Cette base de données a été développée dans le cadre d'une collaboration entre la Marine royale néerlandaise, l'Université de Twente et Fieldlab Techport, et publiée via *4TU.ResearchData*. Elle a été utilisée pour soutenir des recherches sur la détection de défauts dans les systèmes de pompes entraînées par moteur électrique.

Les données expérimentales comprennent des mesures de vibrations, courants et tensions électriques, collectées à partir de deux bancs d'essai distincts :

- Le premier banc a été exploité à trois vitesses de fonctionnement différentes ;
- Le second banc à une vitesse fixe.

Dans le cadre de cette étude, uniquement les données vibratoires seront exploitées. Les données sont mises à disposition sous licence CC0, ce qui autorise leur utilisation libre à des fins de recherche.

2.2 Dispositif expérimental

L'expérience a été conçue de manière à produire des données structurées permettant l'étude et la détection de différents défauts sur des pompes centrifuges entraînées par des moteurs asynchrones. Les mesures ont été réalisées pour deux méthodes de mesure, quatre vitesses de

fonctionnement du moteur, et onze types de défauts simulés, chacun appliqué à différents niveaux de sévérité.

2.2.1 Banc d'essai

Le dispositif expérimental complet est composé de quatre pompes centrifuges, chacune étant entraînée par un moteur électrique asynchrone (Figure III-1). Toutefois, seules deux configurations ont été utilisées dans cette campagne de mesure (2 et 4). Le fluide utilisé est de l'eau douce, stockée dans un réservoir de 60 m³, puis circulée à travers un réseau de tuyauterie équipé de vannes de réglage situées avant et après chaque pompe afin de contrôler le débit.



Figure III-1 : Banc d'essai ((1) Moteur électrique, (2) Pompe, (3) Entrée d'eau principale, (4) Sortie d'eau principale, (5) Vanne de décharge, (6) Variateur de fréquence (VFD))

Les caractéristiques techniques détaillées des moteurs et des pompes sont disponibles dans les tableaux correspondants (Tableaux III-1 et III-2). Le montage a été conçu pour permettre la simulation contrôlée de différents types de défauts mécaniques et hydrauliques dans des conditions réalistes.

Tableau III-1 : Détails des moteurs électriques utilisés

N°	Nom du moteur	Poles	U_{max}(v)/I_{max}(A)	kW @ RPM	Roulements
2	MG160MA4042-H3	4 poles	380–415/23.4–22.4	11 @ 1470	6309.C4
4	MG180MB2–48-F1	2 poles	380–415/43.5	22 @ 2950	6310.C4

Tableau III-2 : Caractéristiques des pompes utilisées

N°	Nom du pompes	Accouplement	Débit (m^3/h) @ RPM	Roulements
2	NK80–250/270 A2F2AE-SBQQE	Spacer	119.9 @ 1470	6308.2Z.C3.SYN
4	NK80–160/167 A2F2AE-SBQQE	Spacer	200.4 @ 2950	6306.2Z.C3.SYN



Figure III-2 : Pompe NK 80-250/270

2.2.2 Méthodes de mesure

Les données vibratoires utilisées dans cette étude ont été acquises à l'aide de capteurs accélérométriques de type Wilcoxon 786B-10 (Figure III-3.a), avec une sensibilité de 100 mV/g, connectés à une unité d'acquisition National Instruments USB-4432 (Figure III-3.b). Pour chaque banc d'essai, cinq accéléromètres ont été installés à des emplacements distincts de la pompe et du moteur, permettant de capturer les vibrations dans plusieurs directions (axiale, radiale, etc.) et zones critiques de la machine (Figure III-4).

Les signaux électriques, comprenant les courants et tensions triphasés, mesurés à l'aide de pinces de courant CR Magnetics CR3110 et de taps de tension Wago 855.

La fréquence d'échantillonnage est 20 kHz pour les signaux vibratoires et électriques.

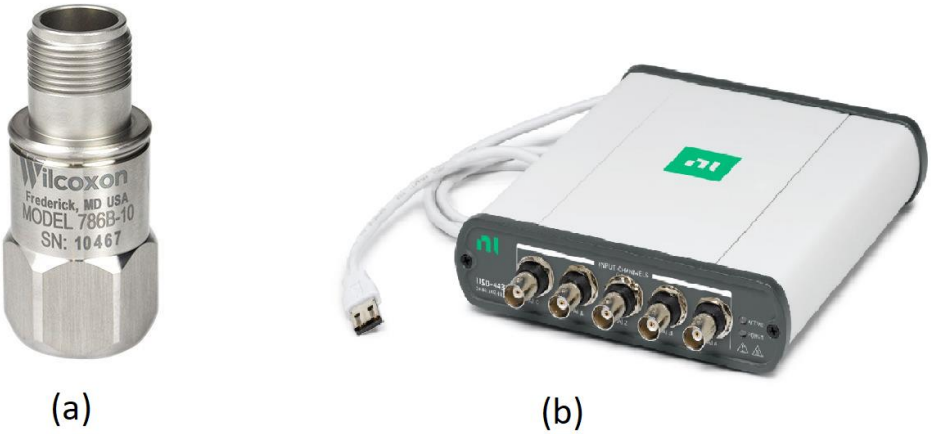


Figure III-3 : Accéléromètre et carte d'acquisition utilisés

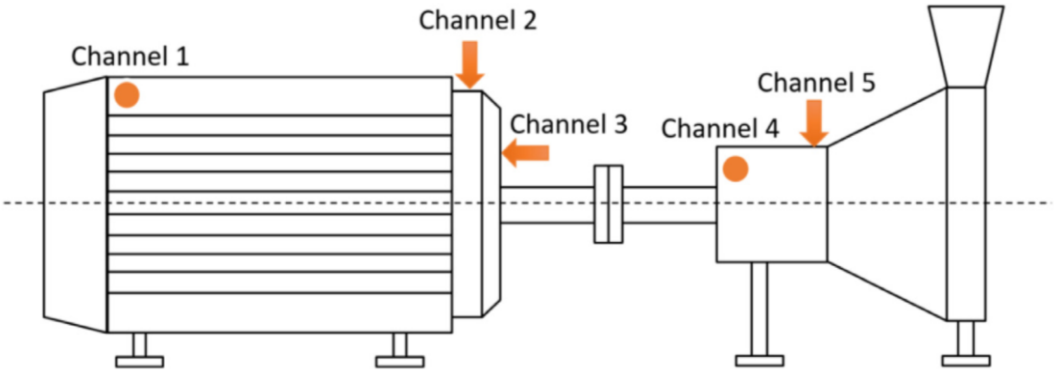


Figure III-4 : Emplacements de mesure des vibrations : les flèches indiquent la position et la direction, tandis que les points représentent une direction perpendiculaire au schéma

2.2.3 Procédure de mesure

La procédure suivie pour chaque mesure est résumée dans le diagramme de la Figure III-5. Elle comprend les étapes suivantes :

- Implémentation du défaut à étudier (désalignement, cavitation, obstruction, etc.)
- Alignement du moteur et réglage de la vitesse via le variateur de fréquence (VFD)
- Démarrage du moteur et stabilisation pendant 5 minutes
- Acquisition des mesures vibratoires et électriques
- Traitement et conversion des données (.csv)
- Répétition pour chaque vitesse de rotation définie

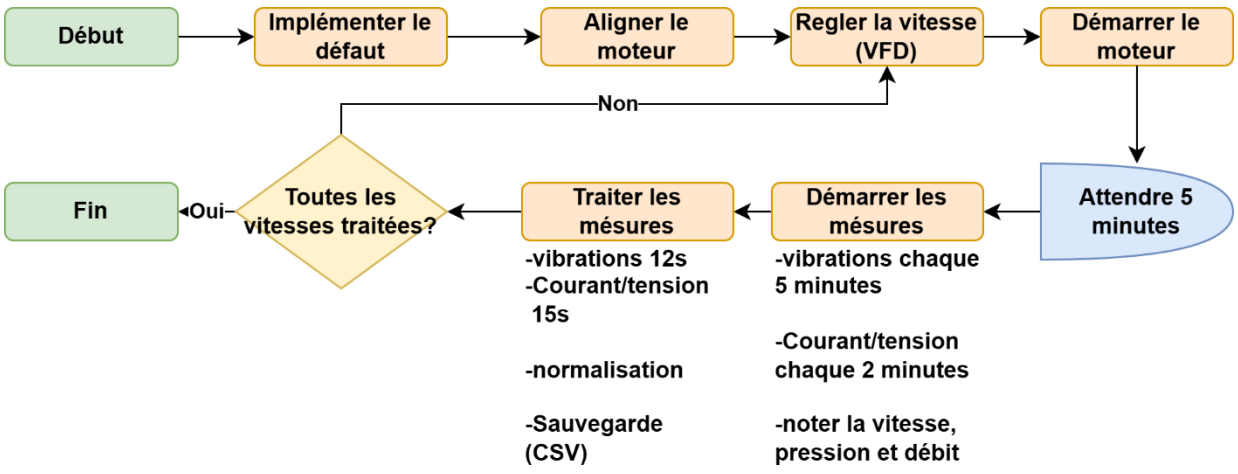


Figure III-5 : Diagramme d'acquisition des données

Les signaux de vibration ont été enregistrés toutes les 5 minutes pour une durée de 60 secondes, puis convertis en fichiers CSV contenant des segments de 12 secondes. Les signaux électriques ont été enregistrés toutes les 2 minutes pour une durée de 15 secondes, également transformés en fichiers CSV. La structure des données est illustrée dans la figure III-6.

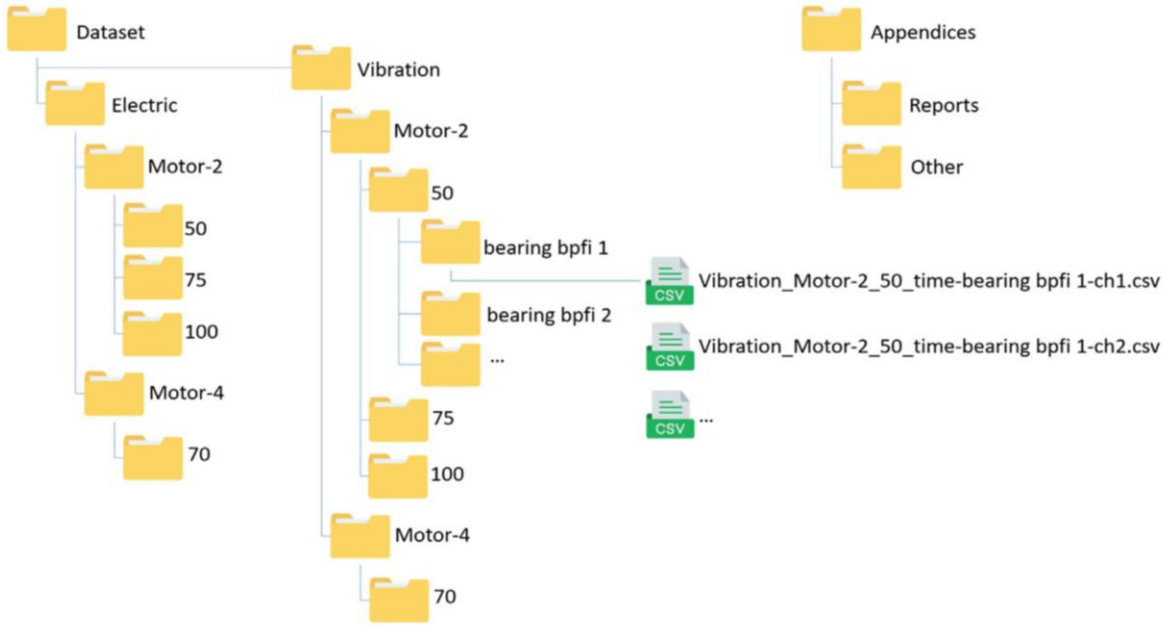


Figure III-6 : Structure des fichiers de la base de données

2.3 Types de défauts

Une grande variété de défauts mécaniques et électriques ont été induit sur le banc d'essai, et plusieurs niveaux de gravité ont été appliqués pour chaque type de défaut. Ce niveau de détail rend cette base particulièrement pertinente pour les travaux de classification automatique via des méthodes d'intelligence artificielle. Des exemples des signaux vibratoires de cette base de données sont représentés dans les figures I-15 et I-16.

La base de données couvert 11 grandes familles de défauts (Tableau III-3).

Tableau III-3 : Défauts induits

Famille de défaut	Mécanisme / référence	Niveaux de gravité
Roulements	Inner/outer ring (BPFI/BPFO), éléments roulants (BSF), contamination de la graisse	1 à 3
Désalignement	Angular, parallèle, combiné	4 à 5
Déséquilibre	Poids ajoutés côté moteur ou pompe	3 à 6

Accouplement	Usure des blocs élastomères	3
Pieds desserrés	Vis de fixation desserré côté moteur ou pompe	1
Soft foot	Shims sous pieds opposés	2
Empalements / cavitation	Détérioration des pales / réglage des vannes	4 à 5
Rotor cassé	Barrette de rotor supprimée	1
Enroulement statorique court-circuité	Pont via résistance variable	2
Arbre voilé	Cintrage permanent 0,2 mm	1
Bruit de fond	Autres pompes actives dans l'installation	–

3 Environnement Logiciel

Avant l'entraînement des modèles, il est essentiel de préparer les signaux à l'aide de différentes étapes de traitement et d'analyse. Pour cela :

- Les traitements du signal (filtrage, segmentation, transformation en ondelettes) ainsi que l'extraction des caractéristiques ont été réalisés principalement sur MATLAB.
- L'implémentation des modèles de classification et l'analyse comparative des performances ont été effectuées dans JupyterLab en Python, en utilisant les bibliothèques TensorFlow et Scikit-learn.

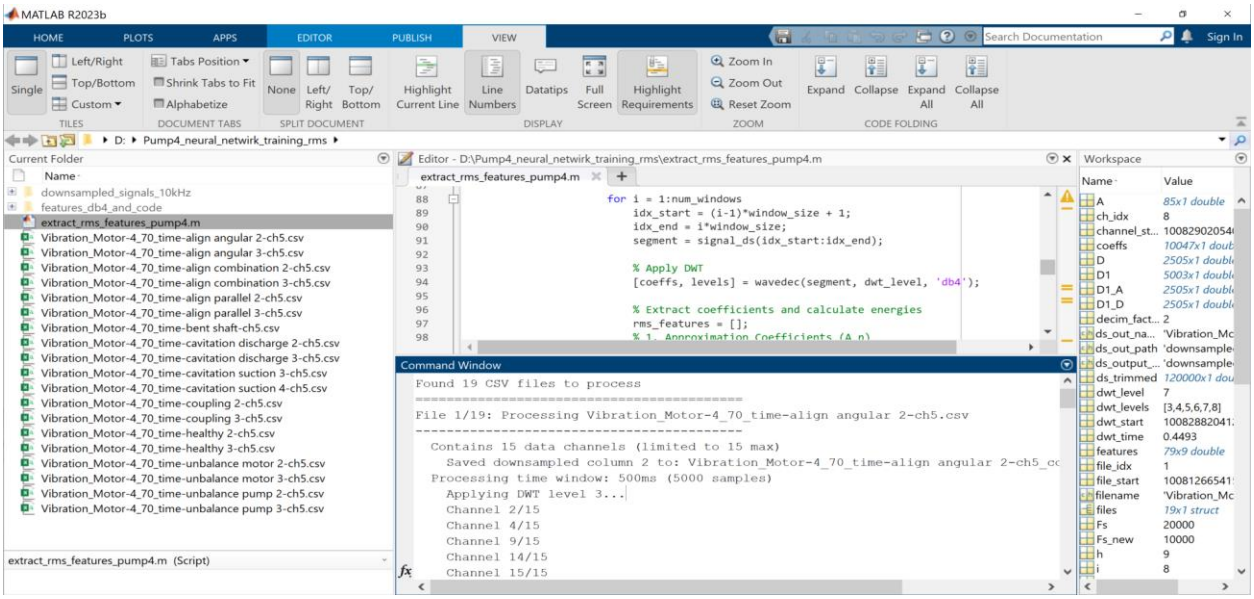


Figure III-7 : L'exécution du code d'extraction des caractéristiques avec MATLAB

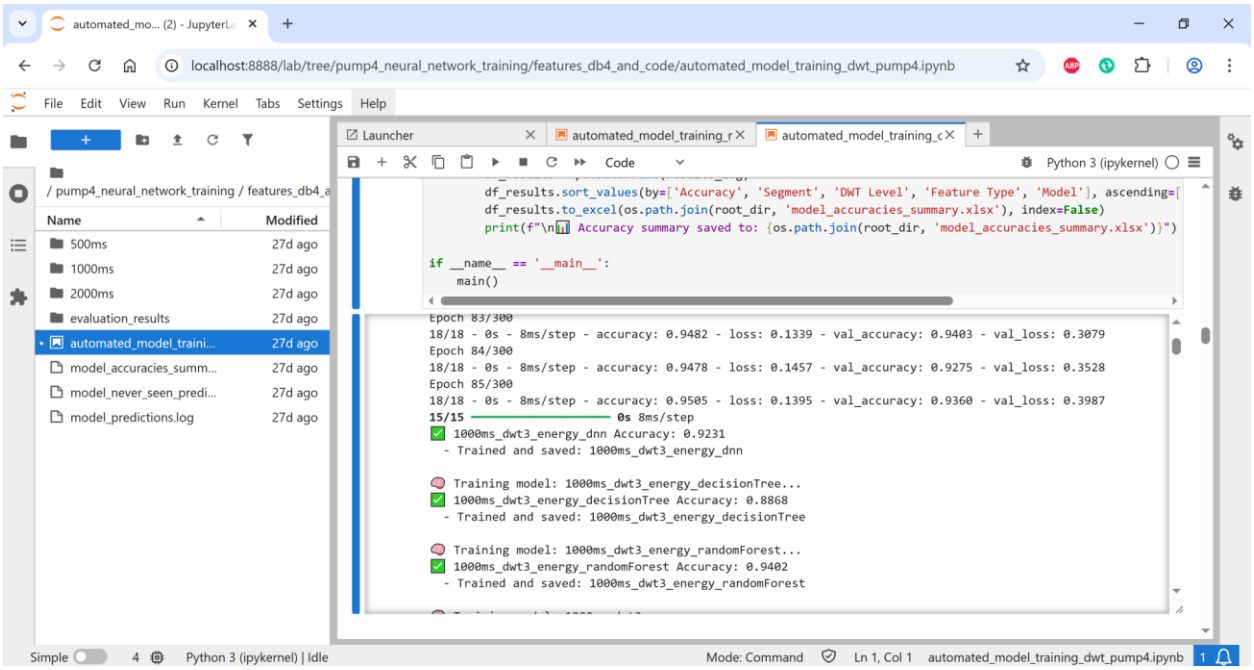


Figure III-8 : L'exécution du code d'apprentissage automatique sur Jupyter Lab

4 Prétraitement des données

4.1 Préparation et extraction des caractéristiques

La préparation des signaux est une étape fondamentale (Figure III-9). Pour chaque fichier CSV, une colonne de données correspondant à 12 secondes de signal a d'abord été extraite. Ces segments de 12 secondes ne sont pas utilisés lors du développement des modèles, mais sont conservés pour une évaluation finale indépendante afin de confirmer leur performance sur des données non vues.

Pour le reste des signaux, un filtre passe-bas avec une fréquence de coupure de 5 kHz a été appliqué, conformément au théorème de Shannon, afin d'éviter le repliement de spectre lors du sous-échantillonnage. Les signaux, initialement échantillonnés à 20 kHz, ont ensuite été sous-échantillonnés à 10 kHz, puis segmentés en fenêtres de 500 ms, 1000 ms et 2000 ms pour étudier l'effet de la durée de mesure sur la précision des modèles.

Chaque segment a subi une décomposition en ondelettes discrètes (DWT) avec des niveaux variant de 3 à 8, afin d'évaluer également l'impact du niveau de décomposition sur la performance des modèles. En complément de ces décompositions complètes, une approche alternative a également été appliquée, une décomposition à un seul niveau a été effectuée, en décomposant le détail du premier niveau (D1). Cette méthode vise à exploiter spécifiquement les hautes fréquences du signal, susceptibles de contenir des informations discriminantes précoces et locales.

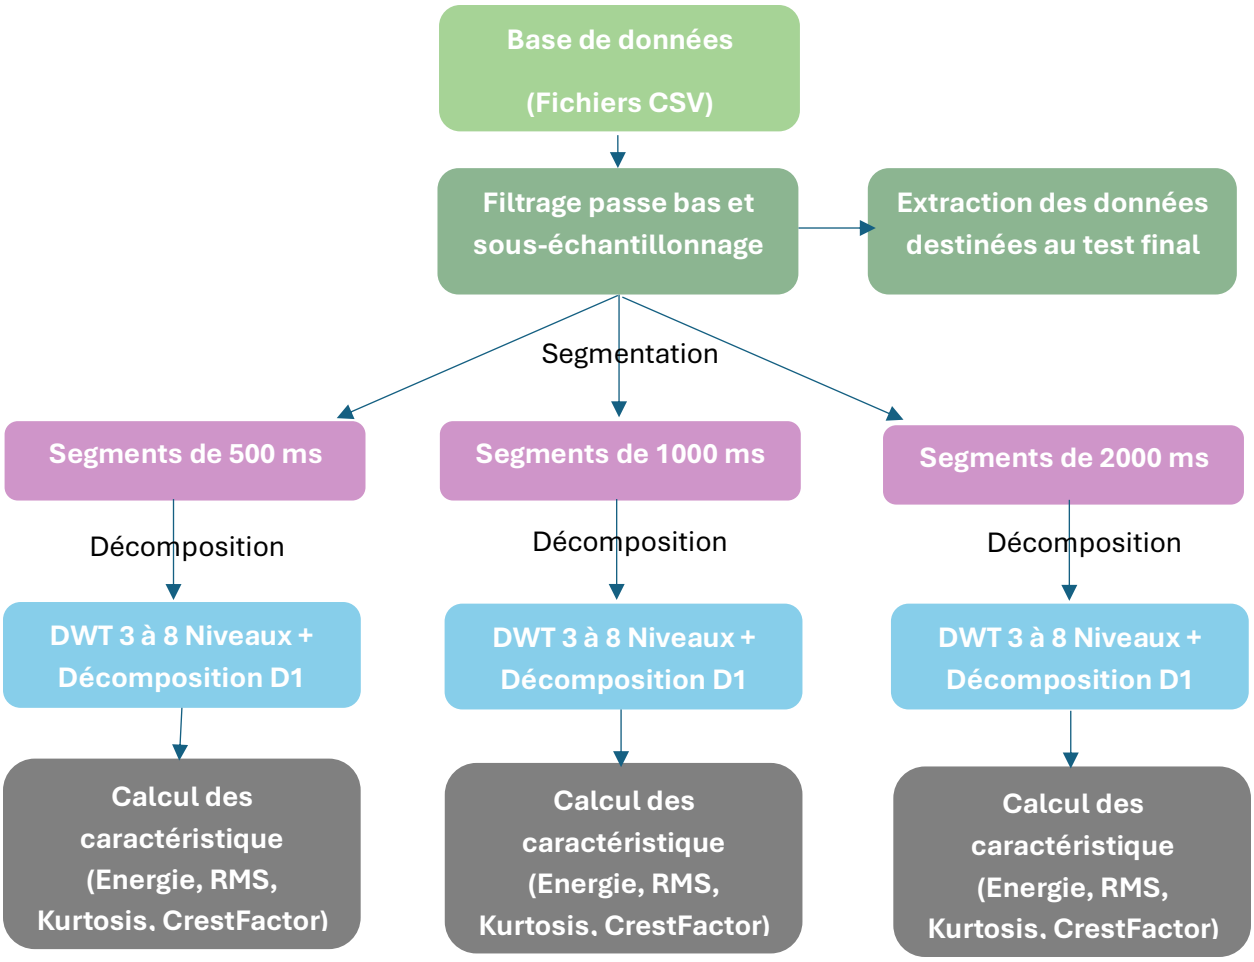


Figure III-9 : Diagramme de prétraitement des données

Des caractéristiques telles que l'énergie des sous-bandes, le kurtosis, la valeur RMS et le crest factor ont été extraites afin d'évaluer différentes configurations pour la classification.

Le sous-échantillonnage et la segmentation contribuent également à réduire la charge computationnelle, un point essentiel pour une éventuelle implémentation sur un système embarqué.

Après la première étape de préparation et d'extraction des caractéristiques à partir des signaux bruts, une nouvelle base de données composée uniquement de vecteurs de caractéristiques est obtenue. Chaque échantillon de cette base correspond à un vecteur dont la dimension dépend du niveau de décomposition DWT appliqué. Par exemple, un segment de 1s, échantillonné à 10 kHz, contient 10 000 points de données. Après une décomposition en ondelettes discrètes de niveau 7, ce segment est réduit à un vecteur de seulement 9 caractéristiques, représentant ainsi une réduction significative de la dimension des données tout en conservant l'information discriminante nécessaire à la classification

Il est à noter qu'il est également possible de concaténer plusieurs types de vecteurs de caractéristiques (energie, RMS, kurtosis etc…) en un seul vecteur global. Cette approche permet d'enrichir la représentation des signaux et d'apporter une diversité d'informations utiles, ce qui peut contribuer à améliorer la performance des modèles d'intelligence artificielle développés.

4.2 Normalisation, encodage et séparation des données

Une fois la base de données de caractéristiques constituée, elle peut être utilisée pour entraîner les modèles d'intelligence artificielle. Toutefois, avant cette étape, il est essentiel de procéder à une normalisation (ou mise à l'échelle) des données. En effet, les différentes caractéristiques extraites peuvent présenter des plages de valeurs très variées, ce qui risquerait d'altérer l'efficacité de l'apprentissage des modèles et de nuire à leur capacité de généralisation.

Dans l'étape d'encodage des étiquettes (label encoding), les noms des fichiers CSV ont été exploités pour générer automatiquement les labels associés à chaque échantillon. Comme mentionné précédemment, les fichiers sont nommés de manière structurée et explicite, ce qui permet d'extraire facilement les informations pertinentes. Cette organisation rigoureuse des fichiers facilite considérablement la création fiable des étiquettes nécessaires à l'entraînement supervisé des modèles.

L'étape suivante consiste à diviser la base de données des caractéristiques en trois sous-ensembles distincts : un ensemble d'entraînement (70 %), un ensemble de validation (15 %) et un ensemble de test (15 %). L'ensemble d'entraînement est utilisé pour ajuster les paramètres internes des modèles pendant la phase d'apprentissage, l'ensemble de validation sert à évaluer leur performance pendant l'apprentissage, tandis que l'ensemble de test est réservé pour une évaluation finale.

5 Test expérimentaux et validations des modèles

5.1 Choix des modèles

Pour ce projet, des modèles variés ont été choisis afin de comparer des approches classiques et avancées : ANN simple et DNN permettent de capturer des relations non linéaires complexes [28], SVM est efficace pour la classification avec peu d'échantillons [46], Decision Tree offre une bonne interprétabilité, Random Forest améliore la robustesse par l'agrégation de plusieurs arbres [47], et XGBoost est connu pour ses performances élevées et sa capacité à gérer les données bruitées [48].

D'autres modèles plus simples (comme k-NN ou Naive Bayes) ou plus complexes (comme RNN/LSTM) n'ont pas été retenus car soit trop limités, soit trop coûteux en calcul pour une application embarquée sur système de surveillance de pompe [49] [50].

5.2 Description de l'architecture des modèles

Cette section présente l'architecture des modèles utilisés dans ce projet. Les configurations et paramètres adoptés pour chaque modèle ont été sélectionnés après plusieurs essais empiriques, dans le but d'optimiser la performance tout en assurant une bonne capacité de généralisation.

Tableau III-4 : Architecture des modèles ANN et DNN

Modèle	Architecture	Compilation	Entrainement
ANN	• Couche d'entrée dont la taille correspondant au nombre de caractéristiques extraites. • Couche Dense de 32 neurones avec activation ReLU • Couche de sortie Dense dont la taille correspondant au nombre de classes et fonction d'activation Softmax	• Optimiseur : Adam (learning rate = 0.01) • Fonction de perte : *sparse_categorical_crossentropy* • Métrique : *accuracy*	• 300 époques maximum • EarlyStopping avec patience de 40 et restauration des meilleurs poids
DNN	• Couche d'entrée dont la taille correspondant au nombre de caractéristiques extraites. • Dense 32 neurones + ReLU • BatchNormalization • Dense 16 neurones + ReLU • BatchNormalization • Dense 16 neurones + ReLU • Couche de sortie Dense avec activation Softmax	• Optimiseur : Adam (learning rate = 0.003) • Fonction de perte : *sparse_categorical_crossentropy* • Métrique : *accuracy*	• 300 époques maximum • EarlyStopping (patience 30)

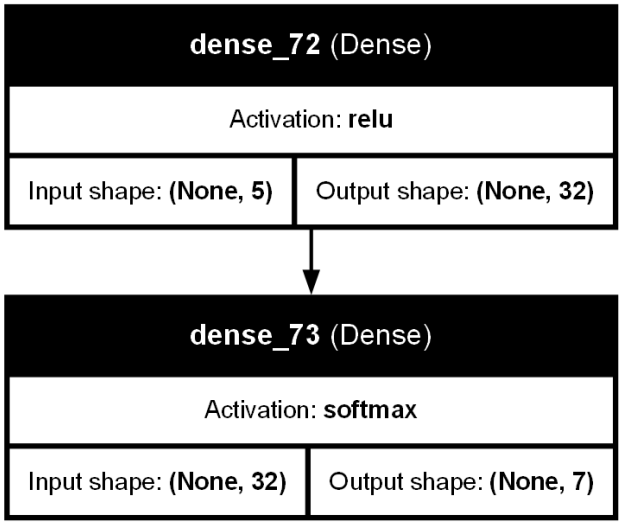


Figure III-10 : Architecture ANN

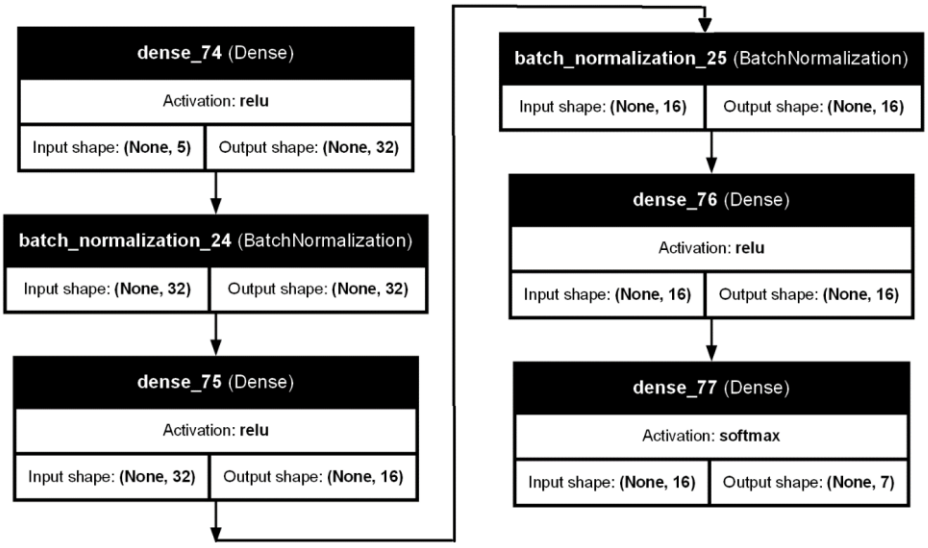


Figure III-11 : Architecture DNN

Tableau III-5 : Architecture des modèles Decision Tree et Random Forest

Modèle	Profondeur	Critère de division	Contrôle
Decision Tree	non limitée	Gini	random_state fixé
Random Forest	500	Gini	random_state fixé

Tableau III-6 : Architecture du modèle XGBoost

Modèle	Nombre d'arbres	Profondeur maximale	Taux d'apprentissage	Fonction d'évaluation
XGBoost	200	10	0.3	mlogloss

Tableau III-7 : Architecture du modèle SVM

Modèle	Type	Noyau	Activation des probabilités	Paramètres
SVM	SVC	RBF	oui	C = 1.0, gamma = 'scale'

5.3 Entraînement des modèles

L'étape d'entraînement des modèles repose sur un pipeline automatisé qui permet d'évaluer plusieurs algorithmes d'apprentissage supervisé afin de déterminer celui offrant les meilleures performances sur les données fournies (L'organigramme du code est présenté en **annexe A**. Le code est écrit avec Jupyter Lab et implémente l'entraînement de six types de modèles. Le processus d'entraînement est le suivant :

1- Pour chaque dossier de données contenant des fichiers CSV, les données sont chargées et leurs labels extraits à l'aide d'une fonction personnalisée qui mappe le nom du fichier à une classe.

2- Les labels sont encodés numériquement, puis les données sont divisées en ensembles d'entraînement, validation et test.

3- Les données sont normalisées via un StandardScaler.

4- Chaque modèle est entraîné sur l'ensemble d'entraînement, avec validation sur l'ensemble de validation.

5- Pour les réseaux de neurones, un EarlyStopping est utilisé pour éviter le surapprentissage, sauvegardant le meilleur modèle.

6- Les modèles entraînés sont sauvegardés dans un dossier spécifique, avec leurs poids, architectures, et préprocesseurs (encodeur classe, scaler).

Cette approche multi-modèles permet de comparer la robustesse et l'efficacité de diverses méthodes sur le même jeu de données, facilitant la sélection du modèle optimal. On obtient à la fin de l'apprentissage 108 modèles (pour chaque type de caractéristiques, Energie, RMS, etc…), sauvegardés dans des dossiers structurés comme illustré à la figure suivante.

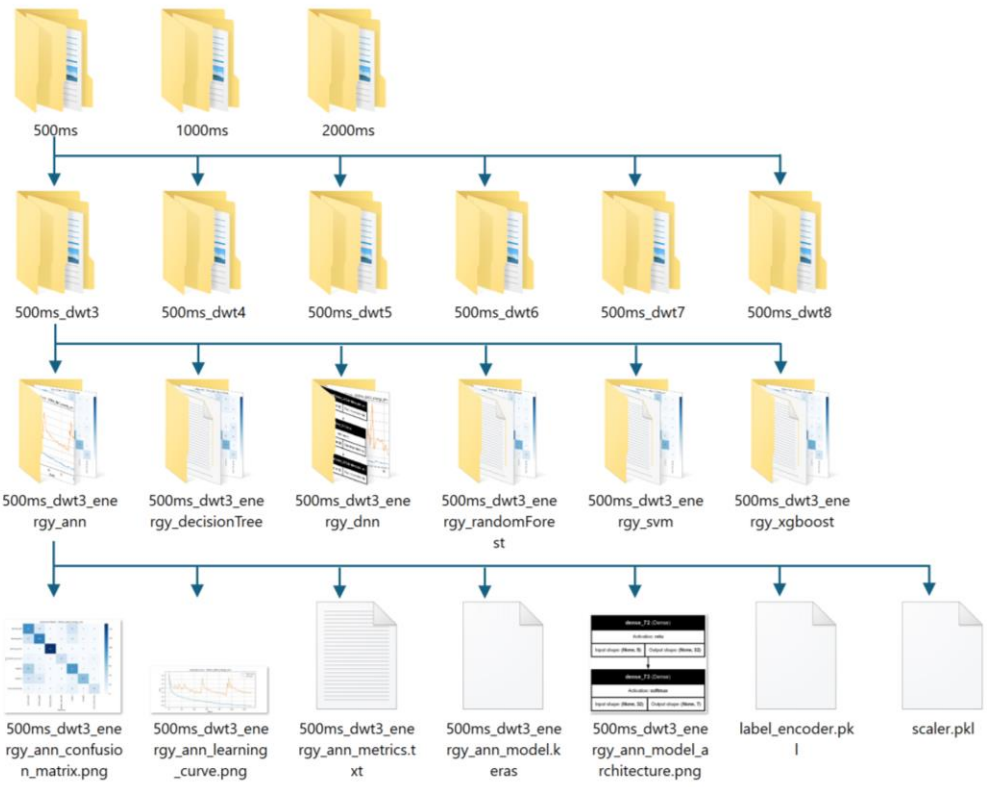


Figure III-12 : Exemple de structure des fichiers à la fin d'apprentissage

5.4 Validation des modèles

Après la phase de développement des modèles, une étape essentielle consiste à évaluer leur capacité de généralisation à l'aide de données jamais vues lors de l'entraînement. Ces données, dédiées uniquement à l'évaluation, sont extraites dès le départ à partir de la base de données originale. Cette validation permet de simuler un usage réel du modèle et repose sur un protocole rigoureux structuré en plusieurs phases.

1- **Préparation des fichiers de test :** Les fichiers sont extraits de segments de signaux vibratoires transformés par ondelettes (DWT), avec des durées fixes (500 ms, 1000 ms, etc.). Les noms de fichiers permettent d'identifier leur classe, leur durée et leur niveau DWT. Ils sont ensuite regroupés par configuration (segment_size et dwt_level).

2- **Chargement des modèles et outils associés :** Chaque modèle est chargé avec son scaler (normalisation) et son LabelEncoder. Les fichiers sont organisés de manière à regrouper automatiquement les éléments compatibles.

3- **Appariement modèle/données :** Les modèles ne sont testés que sur les fichiers dont les paramètres correspondent à leur configuration d'entraînement. Cela garantit la cohérence des évaluations.

4- **Prédiction et évaluation :** Les signaux sont normalisés puis soumis aux modèles. Les prédictions sont comparées aux étiquettes (classes) réelles pour calculer l'exactitude et produire une matrice de confusion, enregistrée sous forme d'image.

5- **Synthèse automatique :** Un tableau récapitulatif (Excel) est généré, listant pour chaque modèle sa configuration et sa précision, facilitant la comparaison des performances.

6 Analyses des résultats

Avant d'entamer l'analyse des résultats d'apprentissage des modèles d'intelligence artificielle, il est essentiel de préciser que les défauts simulés sur la pompe 2 diffèrent de ceux appliqués à la pompe 4.

Pour la pompe 2, les scénarios de défaillance incluent : défaut BPFI du roulement, défaut BPFO du roulement, roulement de la pompe défectueux, rotor cassé, impulseur endommagée, pied de pompe desserré, ainsi que l'état normal (sans défaut). En revanche, la pompe 4 a été soumise à des défauts de nature différente, tels que défauts d'alignement, arbre tordu, cavitation, défaut d'accouplement, déséquilibre du moteur, déséquilibre de la pompe, ainsi que l'état normal.

La pompe 2 a été soumise à cinq configurations expérimentales, chacune reposant sur une combinaison spécifique de caractéristiques extraites :

1. Énergie uniquement

2. Énergie + facteur de crête (crest factor)
3. Énergie + coefficient d'aplatissement (kurtosis)
4. Énergie + valeur efficace (RMS)
5. RMS uniquement

De manière similaire, la pompe 4 a été analysée selon deux approches :

1. Extraction de la valeur RMS,
2. Extraction de l'énergie.

Chaque expérimentation a généré un fichier Excel contenant 108 résultats, issus de la combinaison des paramètres suivants :

- Trois tailles de segments temporels (500 ms, 1000 ms, 2000 ms),
- Six niveaux de décomposition DWT (de 3 à 8),
- Six modèles d'intelligence artificielle (ANN, DNN, SVM, Decision Tree, Random Forest, XGBoost).

Les meilleurs résultats pour chaque configuration seront présentés et analysés dans les sections suivantes. Des tableaux récapitulatifs illustreront les performances les plus élevées, tandis que l'ensemble des résultats est disponible en annexe pour consultation complète.

6.1 Résultats de la pompe 2

Les tableaux suivants présentent un résumé des performances de la pompe 2.

Tableau III-8: Les quatre meilleurs résultats obtenus avec l'énergie uniquement

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000 ms	7	Energie	Random Forest	95.63%
2000 ms	8	Energie	Random Forest	95.63%
2000 ms	5	Energie	Random Forest	95.15 %
2000 ms	7	Energie	XGBoost	94.66 %

Tableau III-9 : Les quatre meilleurs résultats obtenus en combinant l'énergie avec le facteur de crête

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	dwt8	Energie + crest factor	xgboost	96.60 %
2000ms	dwt7	Energie + crest factor	randomForest	96.12 %
2000ms	dwt7	Energie + crest factor	xgboost	96.12 %
2000ms	dwt8	Energie + crest factor	randomForest	96.12 %

Tableau III-10: Les quatre meilleurs résultats obtenus en combinant l'énergie avec le kurtosis

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	dwt8	Energie + Kurtosis	xgboost	97,09 %
2000ms	dwt8	Energie + Kurtosis	randomForest	96,60 %
2000ms	dwt7	Energie + Kurtosis	randomForest	96,12 %
2000ms	dwt6	Energie + Kurtosis	randomForest	95,63 %

Tableau III-11 : Les quatre meilleurs résultats obtenus en combinant l'énergie avec la valeur efficace (RMS)

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	dwt8	Energie + RMS	randomForest	96,12 %
2000ms	dwt8	Energie + RMS	xgboost	96,12 %
2000ms	dwt7	Energie + RMS	randomForest	95,63 %
2000ms	dwt7	Energie + RMS	xgboost	95,63 %

Tableau III-12 : Les quatre meilleurs résultats obtenus avec la valeur efficace uniquement

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	dwt8	RMS	randomForest	96,12 %
2000ms	dwt8	RMS	xgboost	96,12 %
2000ms	dwt6	RMS	randomForest	95,63 %
2000ms	dwt7	RMS	randomForest	95,63 %

Tableau III-13 : Les quatre meilleurs résultats obtenus en combinant la valeur efficace avec le kurtosis

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	Dwt8	Rms + kurtosis	Xgboost	96,12 %
2000ms	Dwt8	Rms + kurtosis	Randomforest	96,60 %
2000ms	Dwt7	Rms + kurtosis	Randomforest	96.12 %
2000ms	Dwt6	Rms + kurtosis	Randomforest	95,63 %

L'interprétation des performances de la pompe 2 met en évidence plusieurs points clés :

- Les fenêtres temporelles longues (2000 ms) offrent de meilleurs résultats en raison de la richesse d'information contenue.
- Les modèles Random Forest et XGBoost, s'imposent comme les plus performants.
- Les niveaux de décomposition DWT 8, 7, 6 et 5 sont les plus pertinents, car ils capturent les bandes fréquentielles caractéristiques des défauts.
- Combiner l'énergie avec le crest factor améliore nettement les performances, atteignant 96,60 %.
- La combinaison de l'énergie avec kurtosis est plus efficace que celle avec le crest factor ou RMS.

- La combinaison d'énergie avec RMS a donné une bonne amélioration par rapport à l'énergie seule, mais reste inférieure à la combinaison avec kurtosis.
- L'utilisation du RMS seule a donné des performances identiques à "Énergie + RMS", ce qui indique une corrélation forte entre énergie et RMS.
- La combinaison du RMS avec Kurtosis est moins performante que la combinaison de l'énergie avec kurtosis.
- Enfin, le meilleur résultat obtenu est **97.09 % avec XGBoost,** un segment de 2000ms, DWT niveau 8 et une combinaison de caractéristiques entre énergie et kurtosis.

6.2 Résultats de la pompe 4

Les tableaux suivants présentent un résumé des performances de la pompe 4.

Tableau III-14: Les 10 meilleurs résultats obtenus avec l'énergie uniquement

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	dwt7	Energie	ann	99,57 %
2000ms	dwt7	Energie	randomForest	99,57 %
2000ms	dwt8	Energie	ann	99,57 %
2000ms	dwt8	Energie	dnn	99,57 %
2000ms	dwt8	Energie	randomForest	99,57 %
2000ms	dwt8	Energie	svm	99,57 %
2000ms	dwt8	Energie	xgboost	99,57 %
500ms	dwt8	Energie	randomForest	99,47 %
500ms	dwt8	Energie	xgboost	99,47 %
1000ms	dwt7	Energie	xgboost	99,36 %

Tableau III-15: Les 10 meilleurs résultats obtenus avec la valeur efficace uniquement

Segment	Niveau DWT	Caractéristique	Modèle	Exactitude
2000ms	dwt7	RMS	decisionTree	99,57 %
2000ms	dwt7	RMS	randomForest	99,57 %
2000ms	dwt8	RMS	dnn	99,57 %
2000ms	dwt8	RMS	randomForest	99,57 %
2000ms	dwt8	RMS	xgboost	99,57 %
2000ms	dwt7	RMS	ann	99,15 %
2000ms	dwt7	RMS	dnn	99,15 %
2000ms	dwt7	RMS	xgboost	99,15 %
2000ms	dwt8	RMS	ann	99,15 %
2000ms	dwt8	RMS	decisionTree	99,15 %

L'interprétation des performances de la pompe 4 met en évidence plusieurs points clés :

- Tous les meilleurs résultats atteignent une exactitude maximale de **99,57 %** pour l'énergie et RMS.

- Les performances élevées sont obtenues pour les segments de 2000 ms avec les niveaux dwt7 et dwt8.
- Tous modèles atteignent cette exactitude maximale selon la caractéristique utilisée.
- Le modèle simple ANN a atteindre l'exactitude maximale.
- En résumé, le paramètre énergie s'avère plus robuste, offrant des résultats constants quel que soit le modèle ou la taille du segment utilisé. Bien que la valeur RMS puisse atteindre des niveaux d'exactitude similaires, elle reste plus sensible au choix du modèle et au niveau de décomposition DWT. Par ailleurs, le niveau DWT 8 se distingue comme le plus performant, quelle que soit la caractéristique analysée. Enfin, le segment de 2000 ms apparaît comme le plus optimal, indépendamment du critère ou du modèle appliqué.

6.3 Comparaison entre modèles

Dans cette section, une comparaison entre les performances des différents modèles utilisés dans cette expérience a été effectuée. L'objectif est d'évaluer l'efficacité de chaque modèle en fonction de l'exactitude maximale obtenue, en tenant compte des caractéristiques extraites, de la durée des fenêtres et des niveaux de transformation en ondelettes discrètes (DWT), afin de sélectionner le modèle le plus adapté pour une implémentation sur un système embarqué.

Tableau III-16: Meilleurs modèles de chaque type

Modèle	Exactitude (pompe 4)	Exactitude (pompe 2)
ANN	99.57 % (2s, dwt 7, énergie)	91.75 % (2s, dwt 5, RMS)
DNN	99.57 % (2s, dwt 8, énergie et RMS)	93.2 % (2s, dwt 6, énergie+RMS)
Decision Tree	99.57 % (2s, dwt 7, RMS)	89.81% (2s, dwt 7 , énergie+Kurtosis)
Random Forest	99.57 % (2s, dwt 7, énergie et RMS)	96.6 % (2s, dwt 8, énergie et RMS + kurtosis)
SVM	99.57 % (2s, dwt 7, énergie)	85.92 % (2s, dwt 7, RMS)
XGBoost	99.57 % (2s, dwt 8, RMS)	97.09 % (2s, dwt 8, énergie+Kurtosis)

- **Pompe 4 :**

Tous les modèles atteignent une exactitude maximale de 99.57 %. La différence se situe essentiellement dans les caractéristiques.

- **ANN, SVM** : utilisent des caractéristiques simples comme l'énergie, ce qui les rend potentiellement plus légers à implémenter sur ESP32.
- **DNN, Random Forest, XGBoost** : intègrent des combinaisons comme énergie + RMS, nécessitant un traitement plus riche.
- **Decision Tree** : bon compromis entre simplicité et performance, avec l'utilisation du RMS uniquement.

- **Pompe 2** :
  - **XGBoost** : obtient la **meilleure exactitude (97.09 %)** avec énergie + kurtosis, mais sa complexité peut poser problème sur un microcontrôleur comme l'ESP32.
  - **Random Forest** : très bonne performance (96.6 %) avec énergie, RMS et kurtosis, mais également plus lourd.
  - **DNN** : bon équilibre entre précision (93.2 %) et complexité modérée.
  - **ANN** : performance acceptable (91.75 %) avec seulement RMS, ce qui en fait un **bon candidat pour une implémentation embarquée**.
  - **Decision Tree** : plus simple mais moins précis (89.81 %).
  - **SVM** : la moins performante (85.92 %) pour ce banc, ce qui limite son intérêt ici.

6.4 Résultats de validation des modèles

À l'issue du protocole d'évaluation rigoureux mis en place (présenté dans la section 5.4), les performances des modèles ont été systématiquement analysées. Les résultats obtenus sont très proches des résultats d'apprentissage et reflètent leur capacité de généralisation sur des données inédites. À titre d'exemple, le modèle ANN a obtenu une exactitude de 92,16 % sur les données inédites (contre 91,75 % pendant l'apprentissage).

7 Implémentation sur un système embarqué

Après une étude comparative des performances de modèles de classification, le modèle ANN (Artificial Neural Network) a été retenu pour l'implémentation embarquée. Ce choix repose sur sa bonne précision, combinée à une architecture simple, ce qui en fait un excellent compromis entre efficacité et légèreté.

Le microcontrôleur ESP32 a été sélectionné pour accueillir le modèle ANN en raison de sa polyvalence, de sa puissance de calcul et de son intégration native du Wi-Fi et du Bluetooth, ce qui en fait une solution idéale pour les applications embarquées connectées. Il dispose de deux cœurs, d'un processeur cadencé jusqu'à 240 MHz, de capacités suffisantes en RAM pour exécuter des modèles légers comme un ANN et le traitement de décomposition par DWT.

Par ailleurs, l'ESP32 est largement supporté par des outils de développement accessibles comme l'Arduino IDE, et est compatible avec TensorFlow Lite for Microcontrollers, ce qui facilite le déploiement de modèles d'IA. Son coût abordable, sa communauté active et ses nombreux modules disponibles en font une plateforme parfaitement adaptée à une implémentation embarquée d'un système de surveillance intelligent.

Parallèlement, le modèle XGBoost sera déployé sur un PC afin de comparer ses performances avec l'ANN embarqué. Ce dernier recevra les caractéristiques extraites transmises par l'ESP32, puis effectuera les prédictions localement.

7.1 Présentation du microcontrôleur ESP32

7.1.1 Caractéristiques techniques

L'ESP32-S3 est un système sur puce (SoC) basé sur un microcontrôleur (MCU) à faible consommation, développé par Espressif Systems [51]. Il est équipé d'un processeur dual-core Tensilica LX7, cadencé jusqu'à 240 MHz, et dispose de 520 Ko de SRAM, et accompagné de PSRAM externe jusqu'à 8 Mo. Il propose également plusieurs interfaces de communication telles que UART, SPI, I2C, PWM, ADC, DAC, ce qui facilite l'intégration avec divers capteurs et modules.

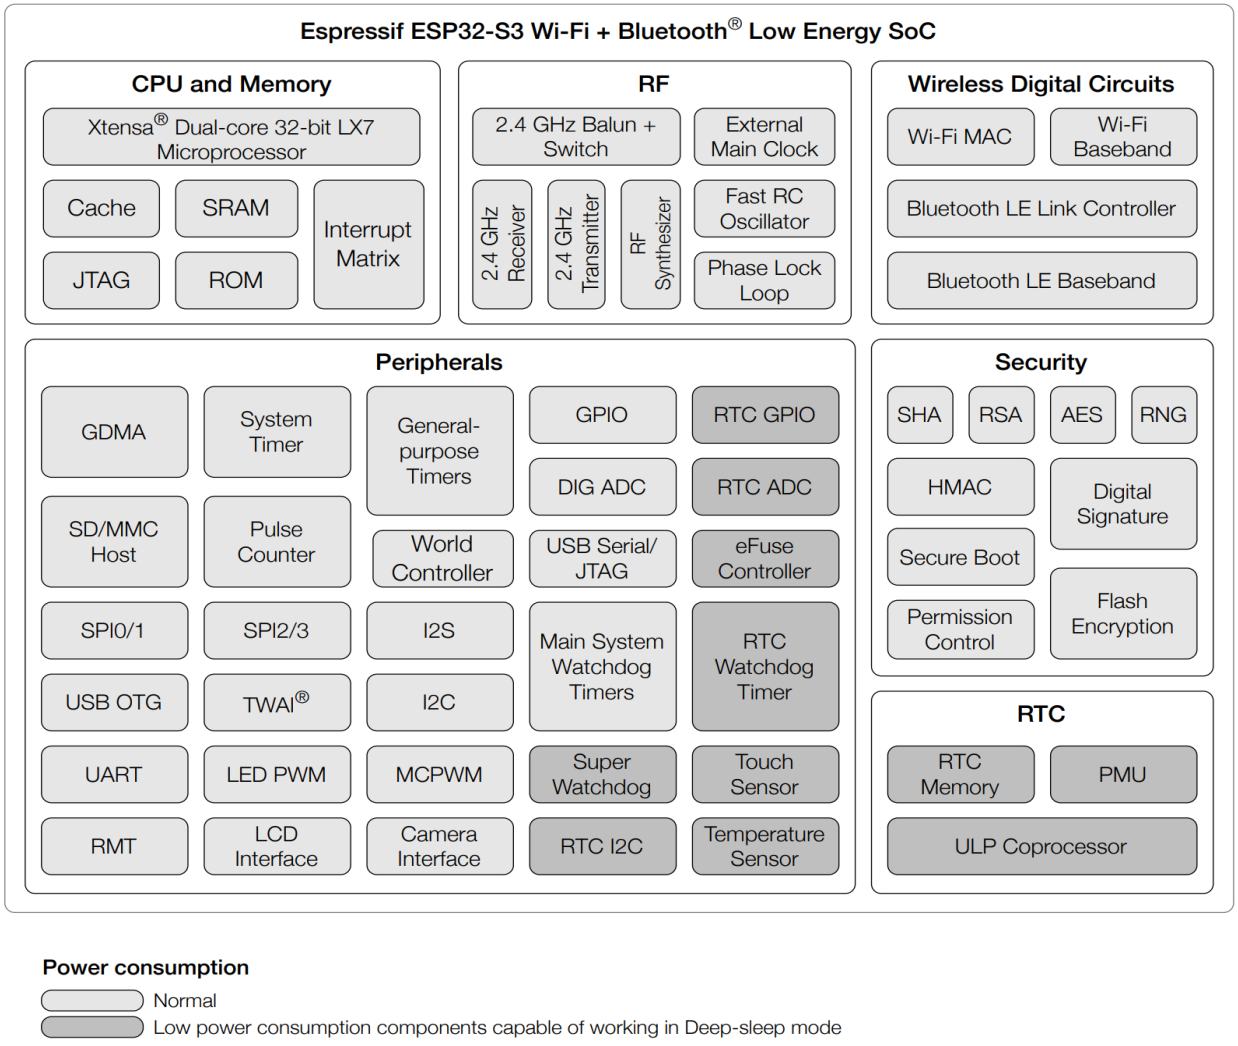


Figure III-13: Diagramme fonctionnel de l'ESP32-S3

L'ESP32 est alimenté en 3.3 V. Il prend en charge plusieurs modes d'économie d'énergie, ce qui est particulièrement utile pour les applications autonomes ou sur batterie.

7.1.2 Capacités de connectivité

L'un de ses principaux atouts est l'intégration native du Wi-Fi (802.11 b/g/n), ce qui élimine le besoin de modules de communication supplémentaires. Dans le cadre de ce projet, le Wi-Fi est utilisé pour permettre à l'ESP32 de communiquer avec un broker MQTT, facilitant ainsi l'envoi des résultats de classification vers une interface utilisateur distante via Node-RED.

7.2 Environnement de développement

Le développement du système embarqué a été réalisé à l'aide de l'IDE Arduino, un environnement de programmation simple et largement utilisé pour les microcontrôleurs. Grâce à sa compatibilité avec l'ESP32-S3 et la grande disponibilité de bibliothèques, il permet une intégration rapide de composants matériels et logiciels. De plus, il prend en charge les extensions spécifiques à l'ESP32, facilitant l'accès aux broches GPIO, aux interfaces de communication (I2C, UART, SPI) et aux fonctionnalités réseau.

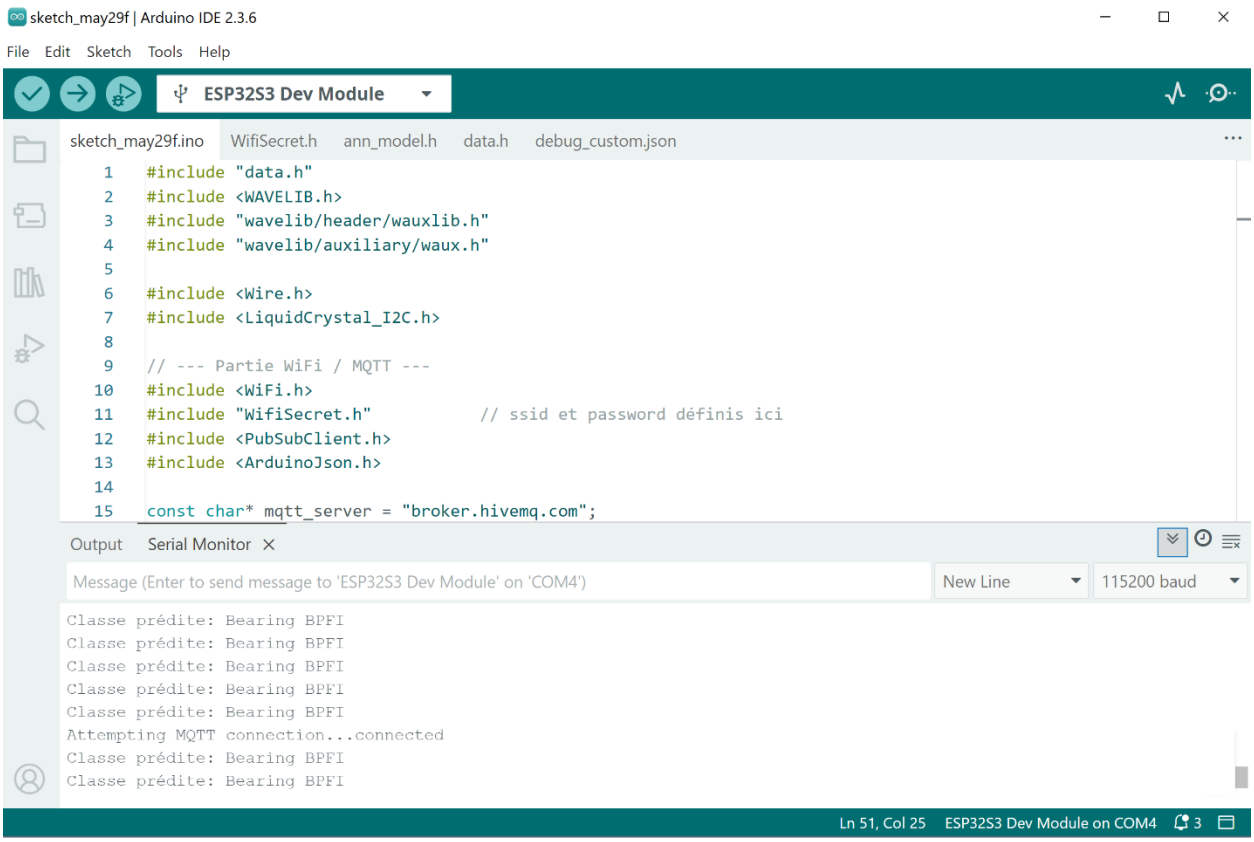


Figure III-14 : Interface Arduino IDE

7.3 Déploiement du modèle ANN sur ESP32

Le déploiement du modèle de réseau de neurones artificiels (ANN) sur l'ESP32 s'effectue selon les étapes suivantes :

- **Entraînement du modèle avec Jupyter Lab** : Le modèle ANN est d'abord conçu, entraîné et validé à l'aide de bibliothèques Python telles que TensorFlow, dans un environnement Jupyter Lab. Une fois le modèle performant, il est sauvegardé au format TensorFlow.
- **Conversion en format TensorFlow Lite** : Pour pouvoir être exécuté sur un microcontrôleur comme l'ESP32, le modèle doit être converti au format TensorFlow Lite (.tflite) à l'aide de l'outil TFLiteConverter de TensorFlow. Ce format est allégé et optimisé pour les environnements embarqués.
- **Conversion en fichier header C++ (.h)** : Le fichier .tflite est ensuite converti en tableau binaire C compatible avec l'environnement Arduino. Ce fichier .h contient les données binaires du modèle sous forme de tableau C prêt à être inclus dans le code Arduino.
- **Utilisation de la bibliothèque TensorFlowLite_ESP32 sur Arduino IDE** : Sur l'Arduino IDE, la bibliothèque TensorFlowLite_ESP32 est utilisée pour interpréter et exécuter le modèle ANN. Le fichier ANN_model.h est inclus dans le projet, et le modèle est chargé via l'API MicroInterpreter. L'entrée du modèle (vecteur mis à l'échelle) est copiée dans le tenseur d'entrée, et l'inférence retourne la classe prédite.

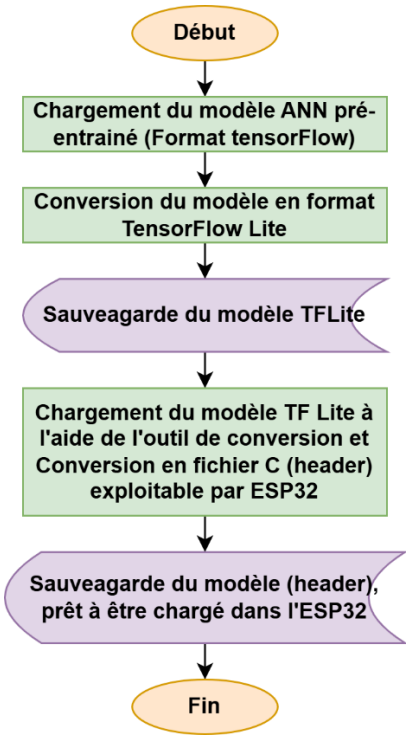


Figure III-15 : Etapes de conversion du modèle ANN en fichier C

7.4 Communication des données avec MQTT

Afin d'assurer une communication efficace entre le microcontrôleur ESP32 et l'interface utilisateur, le protocole MQTT (Message Queuing Telemetry Transport) a été adopté pour la transmission des données de classification et de supervision. Ce protocole léger, basé sur le modèle publish/subscribe, est particulièrement bien adapté aux systèmes embarqués à ressources limitées.

L'architecture repose sur un modèle centralisé autour d'un broker MQTT. L'ESP32 agit en tant que publisher, envoyant périodiquement des messages contenant l'état de la pompe. Un autre client, tel que Node-RED, se comporte comme un abonné (subscriber) et reçoit ces messages pour traitement ou affichage sur l'interface HMI.

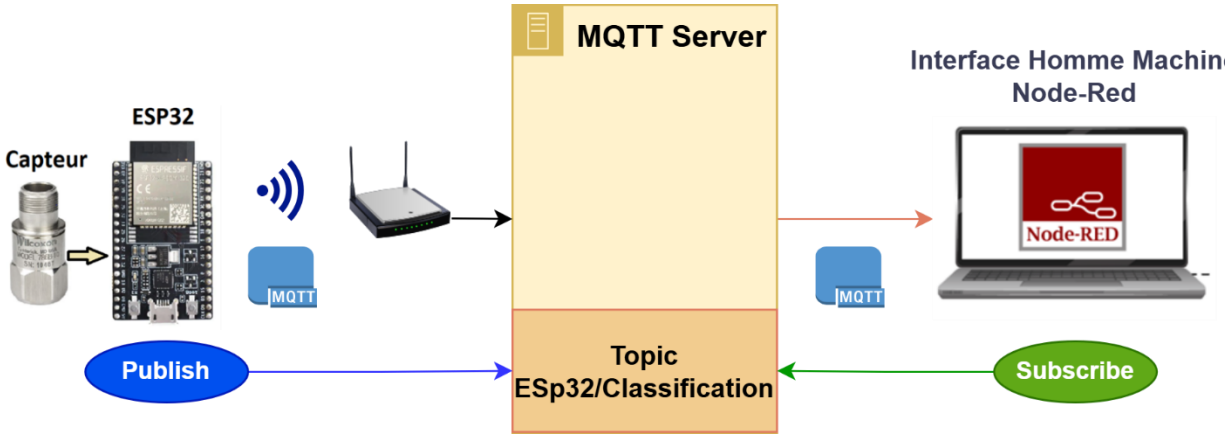


Figure III-16 : Architecture de communication MQTT

7.5 Création de l'interface HMI

Pour offrir un système de supervision convivial, une interface HMI (Human-Machine Interface) a été développée à l'aide de Node-RED. Cette interface permet d'afficher en temps réel les résultats de la classification. Plusieurs outils ont été mobilisés pour enrichir l'aspect visuel et fonctionnel de cette interface.

7.5.1 Présentation de Node-RED et son rôle dans l'HMI

Node-RED est un environnement de développement visuel, conçu pour la création rapide d'applications IoT. Dans ce projet, il joue plusieurs rôles :

Abonnement au broker MQTT pour recevoir les messages publiés par l'ESP32.

Traitement des données et prédiction avec XGBoost

Affichage graphique des prédictions de l'ANN embarqué et XGBoost dans l'HMI.

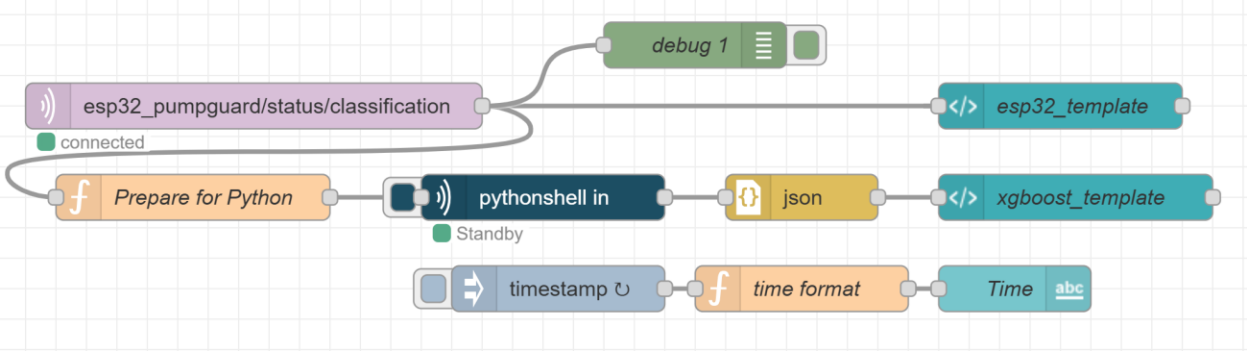


Figure III-17: Programme Node-Red

7.5.2 Création de l'HMI

L'interface HMI a été conçue à l'aide de Node-RED en intégrant des composants graphiques issus de Symbol Factory, insérés et combinés via Inkscape. Ce dernier a permis de concevoir des illustrations SVG interactives représentant le système, facilitant la visualisation des défauts détectés.

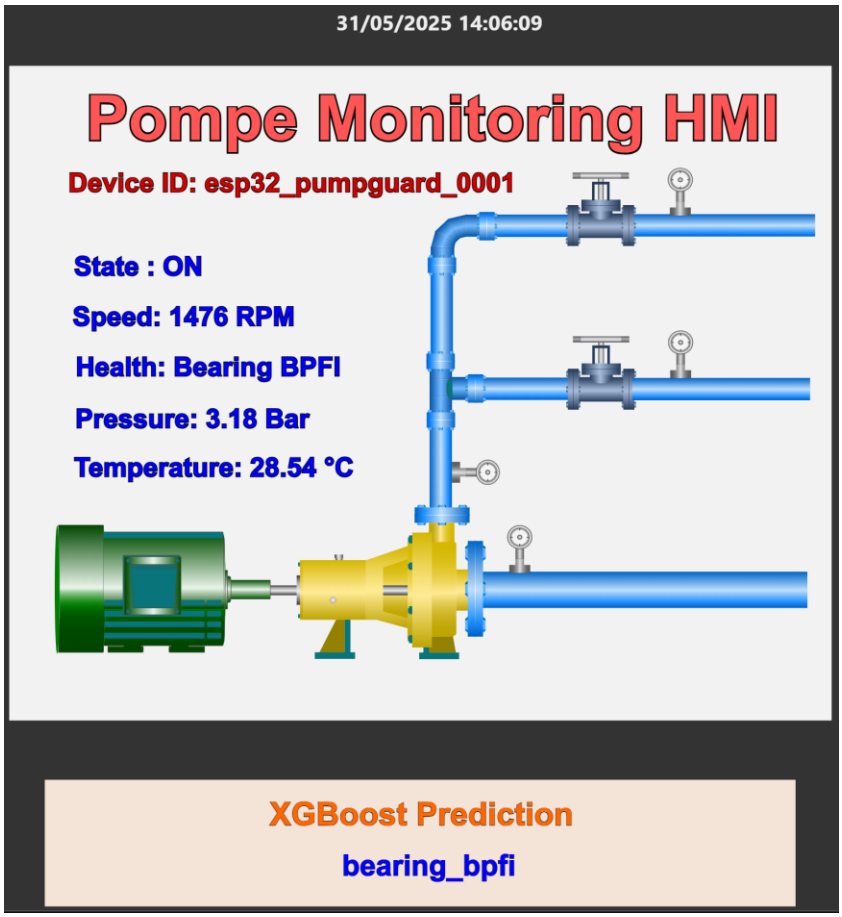


Figure III-18 : Interface Homme Machine développée

7.6 Schéma global du système

7.6.1 Fonctionnement du système embarqué

Le diagramme de fonctionnement du code implémenté ESP32 est illustré dans la figure suivante :

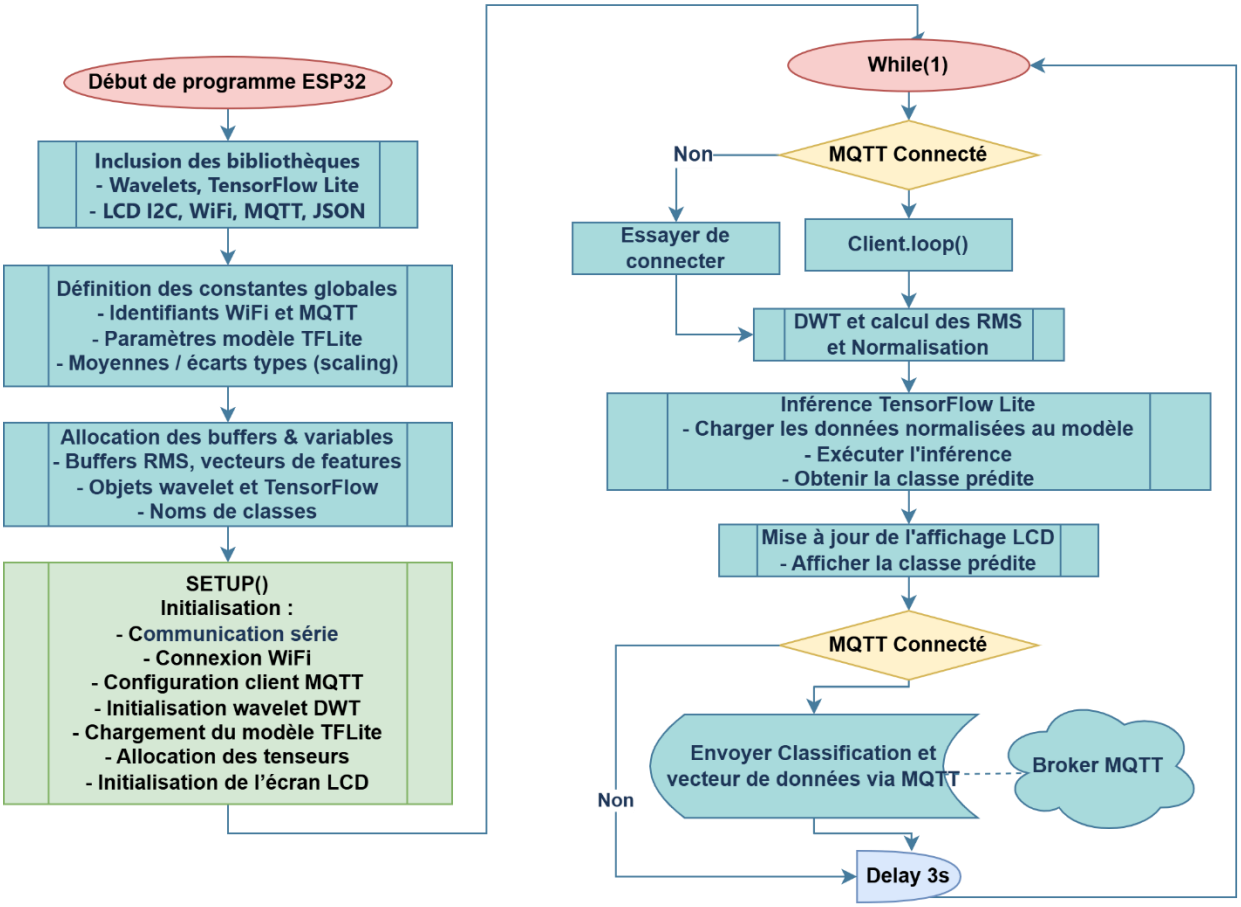


Figure III-19 : diagramme de fonctionnement du code implémenté ESP32

Le microcontrôleur ESP32 est responsable de la collecte de données, du traitement du signal, de la classification locale et de la transmission des résultats. Voici les étapes de son fonctionnement :

1. Au démarrage, l'ESP32 inclut les bibliothèques nécessaires (TensorFlow Lite, DWT, WiFi, MQTT, LCD, etc.) et définit les constantes utiles (identifiants WiFi/MQTT, paramètres du modèle, valeurs de normalisation).
2. Le microcontrôleur alloue les buffers pour le traitement des signaux, initialise les objets pour les calculs DWT et le modèle TFLite, et charge les noms des classes.

3. Configuration dans la fonction Setup : ll établit la communication série, se connecte au WiFi, configure le client MQTT, initialise les modules DWT et TensorFlow Lite, puis prépare l'écran LCD pour afficher les résultats.

   Dans la boucle principale, le système fait le programme suivant :

4. Vérifie la connexion MQTT, s'il n'est pas connecté, il tente de se reconnecter.
5. Prétraitement du signal : lorsque des données sont disponibles, le système applique une transformée en ondelettes (DWT), calcule la valeur RMS, puis normalise le vecteur résultant.
6. Classification locale avec TensorFlow Lite : le vecteur normalisé est envoyé au modèle TFLite pour inférence. Le modèle retourne une classe prédite, correspondant à un état diagnostiqué.
7. Affichage du résultat localement : la classe prédite est affichée sur l'écran LCD intégré à l'ESP32 pour un retour immédiat à l'utilisateur.
8. Transmission des résultats via MQTT : Si la connexion MQTT est active, la classe prédite ainsi que le vecteur de caractéristiques normalisé sont envoyés à un broker MQTT, en vue d'un traitement distant.

7.6.2 Fonctionnement du code Node-Red

Le diagramme de fonctionnement du code Node-Red est illustré dans la figure suivante :

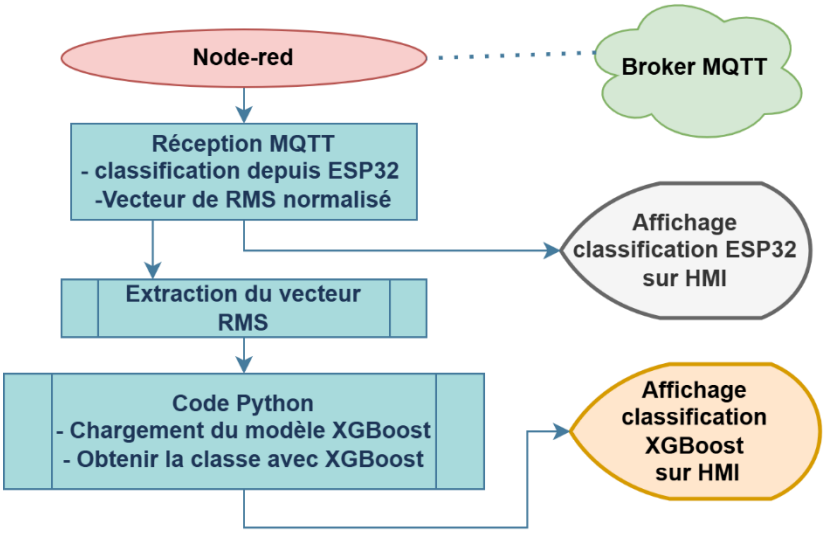


Figure III-20 : diagramme de fonctionnement du code Node-Red

Le système Node-RED joue le rôle d'interface distante et de système de classification secondaire. Il permet une visualisation et un diagnostic complémentaire à celui effectué localement par l'ESP32.

1. Réception des données MQTT : Node-RED intercepte les messages envoyés par l'ESP32 via le broker MQTT. Ces messages contiennent la classe prédite et le vecteur RMS normalisé.
2. Affichage des résultats sur l'HMI : La classe prédite par l'ESP32 est immédiatement affichée sur une interface homme-machine (HMI), facilitant le suivi en temps réel.
3. Préparation du traitement Python : Le vecteur RMS est extrait et transmis à un module Python intégré dans Node-RED, qui permet d'effectuer une classification secondaire.
4. Classification avancée avec XGBoost : Un modèle XGBoost est chargé. Le vecteur RMS est soumis à ce modèle pour obtenir une classification secondaire.
5. Affichage du résultat XGBoost La classification obtenue via XGBoost est affichée sur l'HMI, offrant un second avis ou une confirmation de la prédiction locale.

7.7 Tests et validation

La performance du modèle ANN embarqué a été évaluée à travers plusieurs critères, notamment la fidélité du comportement du modèle par rapport à son équivalent sur PC, le traitement des données, ainsi que la fiabilité de la communication.

- **Exactitude du modèle ANN embarqué** : pour confirmer que l'exécution du modèle sur microcontrôleur ne compromet pas sa précision, un ensemble d'échantillons de test, constitués de vecteurs RMS préalablement utilisés sur PC avec leurs étiquettes de classe correspondantes, a été chargé dans la mémoire de l'ESP32. Pour chaque vecteur, une inférence a été réalisée localement à l'aide du modèle ANN embarqué. En comparant les prédictions du modèle embarqué avec les classes réelles, l'exactitude s'est avérée identique à celle obtenue sur PC avec TensorFlow (**92.16%**), prouvant que la conversion du modèle en tableau C n'a induit aucune perte de performance.

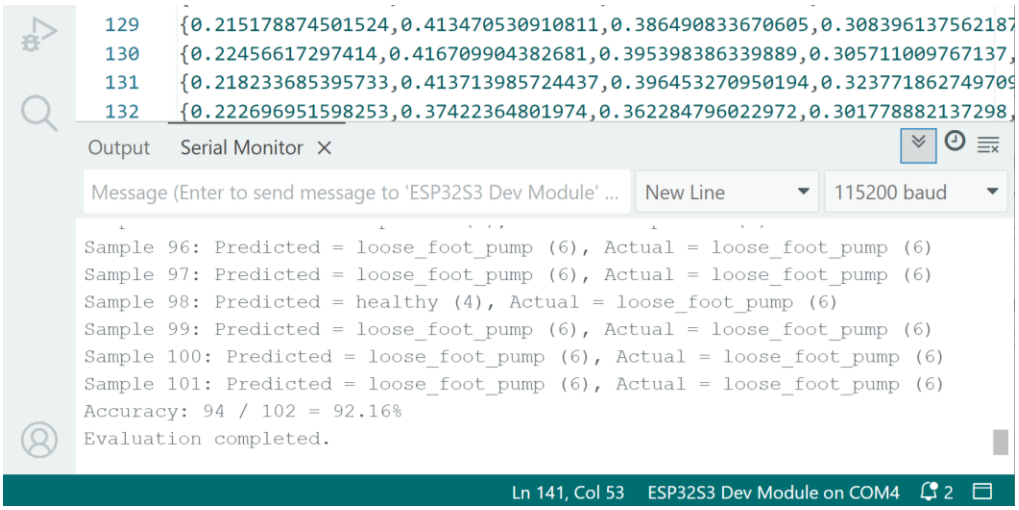


Figure III-21: Validation du modèle ANN embarqué

- **Prétraitement et normalisation** : les étapes de décomposition par transformée en ondelettes discrète (DWT) et de calcul des caractéristiques (notamment la valeur RMS) ont été exécutées sur l'ESP32 avec succès. Afin de valider l'exactitude des traitements embarqués, les résultats obtenus ont été comparés à ceux calculés sous MATLAB pour les mêmes signaux. La correspondance entre les deux jeux de résultats a confirmé que l'implémentation du traitement sur ESP32 est fidèle et conforme aux attentes théoriques.
- **Transmission MQTT** : Afin de vérifier l'intégrité des données transmises, l'outil MQTT Explorer a été utilisé. Celui-ci a permis d'inspecter les messages publiés par l'ESP32, confirmant que les données étaient correctement formatées, acheminées sans perte, et reçues avec la bonne fréquence.

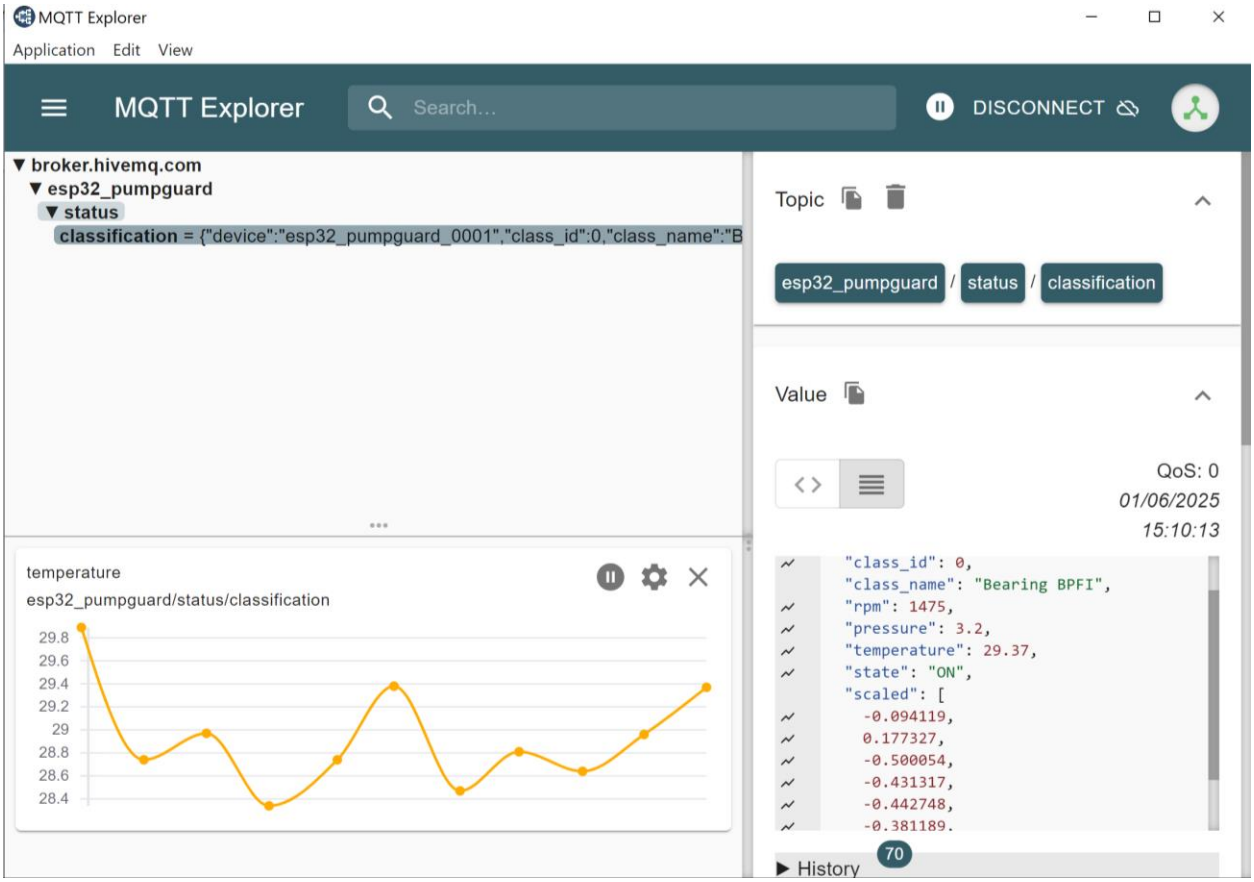


Figure III-22 : Vérification des données transmises avec MQTT explorer

7.8 Prototype

Le premier prototype du système a été réalisé sur une platine de prototypage (breadboard), permettant de valider rapidement le fonctionnement du système. Ce montage a servi aux premiers tests fonctionnels, le traitement embarqué, la classification avec le modèle ANN et la transmission des résultats via MQTT. Le prototype a fonctionné très efficacement, confirmant la fiabilité de l'approche choisie avant l'intégration sur un circuit imprimé ou un support final plus compact.

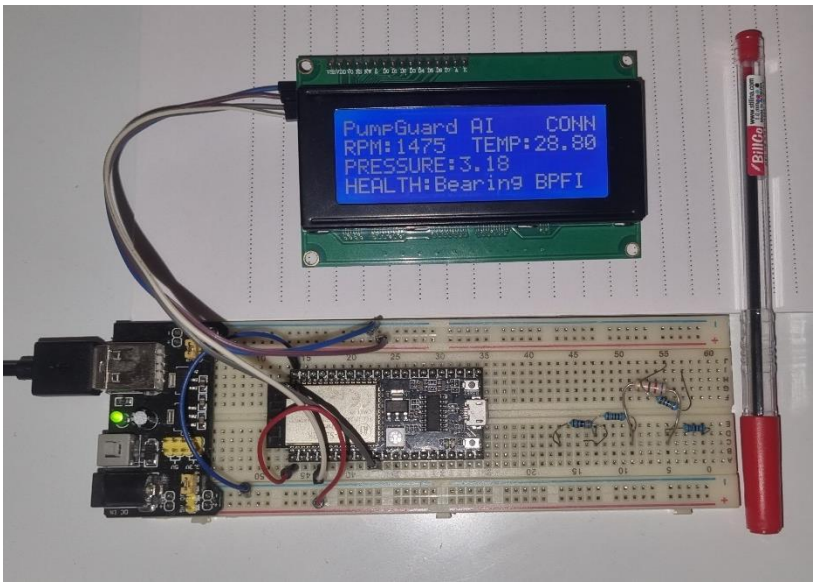


Figure III-23 : Premier prototype réalisé sur platine d'expérimentation

8 Conclusion

Ce chapitre a détaillé la mise en œuvre d'un système embarqué de diagnostic des défauts de pompes centrifuges. Après avoir comparé plusieurs algorithmes d'IA, un réseau de neurones artificiel (ANN) a été sélectionné pour son bon compromis précision-légèreté, atteignant 92% d'exactitude.

Le déploiement sur ESP32 a validé la faisabilité d'une solution autonome : prétraitement des vibrations (DWT, extraction de caractéristiques), classification locale et transmission sans fil des résultats via MQTT vers une interface HMI développée sous Node-RED. Des tests rigoureux ont confirmé la fiabilité du système, avec des performances identiques à la version PC.

Cette expérimentation prouve qu'une surveillance intelligente et embarquée des machines industrielles est réalisable avec des technologies accessibles.

Conclusion Générale

Ce mémoire a exploré de manière approfondie le diagnostic des défauts des pompes centrifuges à travers une approche intégrée combinant l'analyse vibratoire, le traitement avancé du signal et l'intelligence artificielle, jusqu'à la mise en œuvre concrète d'un système embarqué.

Le premier chapitre a établi les bases en mettant en lumière le fonctionnement des pompes centrifuges, les types de défaillances courantes, ainsi que le rôle essentiel de l'analyse vibratoire dans la détection précoce des anomalies. Cette approche permet d'éviter des arrêts coûteux en identifiant avec précision les défauts, grâce à une exploitation ciblée des signatures vibratoires.

Le deuxième chapitre a approfondi les méthodes de traitement du signal vibratoire et l'application des algorithmes d'intelligence artificielle au diagnostic. Il a montré que la qualité d'un système prédictif repose sur une chaîne rigoureuse allant de la collecte et du prétraitement des données à l'utilisation d'algorithmes adaptés et finement réglés, garantissant un diagnostic rapide, fiable et automatisé.

Enfin, le troisième chapitre a concrétisé ces principes à travers l'expérimentation et l'implémentation d'un système embarqué performant. Le choix judicieux d'un réseau de neurones artificiel et son déploiement sur une plateforme ESP32 ont démontré la faisabilité d'une solution autonome et mobile, capable d'effectuer en temps réel la surveillance vibratoire et la classification des défauts, avec une communication efficace vers une interface utilisateur.

En résumé, ce travail illustre parfaitement la convergence des techniques traditionnelles d'analyse vibratoire avec les avancées de l'intelligence artificielle et des systèmes embarqués, ouvrant la voie à une maintenance prédictive accessible, fiable et intelligente pour l'industrie moderne.

Références

[1] J. F. Gülich, *Centrifugal Pumps*, 2nd éd. Springer, 2010.

[2] L. Bachus and A. Custodio, *Know and Understand Centrifugal Pumps.* in Oxford. UK: Elsevier Ltd, 2003.

[3] B. Djellali et B. Djebabla, « Analyse des causes de défaillance des pompes centrifuges », Mémoire de Master en Electromécanique, spécialité Maintenance Industrielle, Faculté des Sciences de l'Ingéniorat, Université de Annaba, Algérie, 2021.

[4] *NF EN 13306*, octobre 2010.

[5] K. Pichler, R. Haas, V. Putz, et C. Kastl, « Degradation detection for internal gear pumps using pressure reduction time maps », *Annu. Conf. PHM Soc.*, vol. 13, nº 1, nov. 2021, doi: 10.36001/phmconf.2021.v13i1.3014.

[6] A. Boulenger and C. Pachaud, *Surveillance des machines par analyse des vibrations*. Paris, France: Dunod, 2009.

[7] B. Badri, M. Thomas et S. Sassi, « Étude et développement d'un système expert basé sur les réseaux de neurones pour le diagnostic des défauts de roulements », *Séminaire sur les vibrations des machines*, Montréal, Canada, p. 386-403, octobre 2006.

[8] *Maintenance - Maintenance governance - Guidelines*, NF EN 17485:2021, septembre 2021.

[9] F. Landolsi, « Techniques de surveillance », Institut Supérieur des Études Technologiques de Nabeul, Support de cours, 2023.

[10] S. Chadli, « Capteurs en instrumentation industrielle », Université de Médéa, Support de cours Master, 2023.

[11] S. E. Ounoughi, « Surveillance et diagnostic des défauts de roulements par analyse spectrale », mémoire de fin d'études pour l'obtention du diplôme d'ingénieur d'État en Génie Mécanique, Ecole Nationale Polytechnique, Algérie, 2020.

[12] M. H. Garousi, M. Karimi, P. Casoli, M. Rundo, et R. Fallahzadeh, « Vibration Analysis of a Centrifugal Pump with Healthy and Defective Impellers and Fault Detection Using Multi-Layer Perceptron », *Eng*, vol. 5, nº 4, p. 2511-2530, oct. 2024, doi: 10.3390/eng5040131.

[13] Y. Li, G. Feng, X. Li, Q. Si, et Z. Zhu, « An experimental study on the cavitation vibration characteristics of a centrifugal pump at normal flow rate », *J. Mech. Sci. Technol.*, vol. 32, nº 10, p. 4711-4720, oct. 2018, doi: 10.1007/s12206-018-0918-x.

[14] A. Al-braik, O. Hamomd, F. Gu, and A. D. Ball, « Diagnosis of Impeller Faults in a Centrifugal Pump Based on Spectrum Analysis of Vibration Signals », *J Vib Eng Technol*, vol. 10, nº 2, p. 123-134, avr. 2022.

[15] A. Salman, A. Osman, et K. Fawzy, « Vibration Signature of Unbalanced Rotors of Centrifugal Pumps », *Egypt. Int. J. Eng. Sci. Technol.*, vol. 26, nº EIJEST, Vol. 26, 2018, p. 45-58, nov. 2018, doi: 10.21608/eijest.2018.97265.

[16] B. Muruganantham, « Introduction to vibration-based condition monitoring », Honeywell Process Solutions Tech. Rep, Pune, India, 2022. [En ligne]. Disponible sur: https://process.honeywell.com/content/dam/process/en/documents/gated/Introduction-to-vibration-based-condition-monitoring-whitepaper.pdf

[17] G. Asch et al, *Acquisition de données - Du capteur à l'ordinateur*, 3e éd. Paris, France: Dunod, 2005.

[18] F. Cottet et COTTET-F., *Traitement des signaux et acquisition de données cours et exercices corrigés*, 3e édition. DUNOD, 2009.

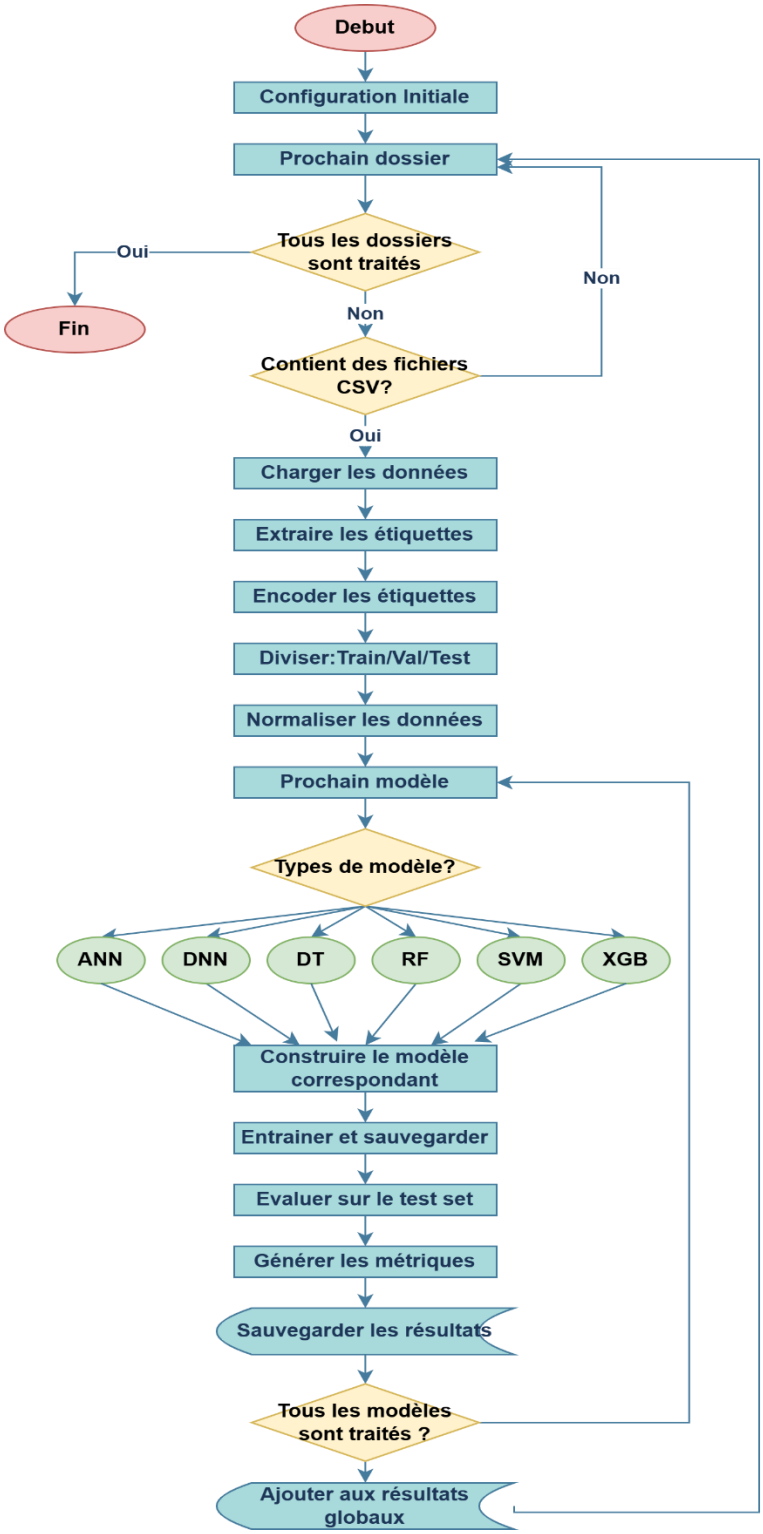
[19] J. C. Goswami, *Fundamentals of Wavelets: Theory, Algorithms, and Applications*, 2nd ed. in Wiley Series in Microwave and Optical Engineering Ser, no. v. 233. Hoboken: John Wiley & Sons, Incorporated, 2011.
[20] Abdelkrim Lallouani, « Débruitage D'un Signal De La Parole Corrompu Par Un Bruit Coloré En Utilisant La Transformée En Ondelettes Et Implantation Sur Un Processeur De Traitement Numérique Des Signaux », Maîtrise En Génie Electrique, Ecole De Technologie Supérieure, Université Du Québec, Montréal, 2004.
[21] Mr. ELMOHRI Mohamed Abdessalem, Mr. TOBBAL Abdelhafid, et Mr. CHADLI Samir, « Implémentation d'une méthode d'extraction des caractéristiques des signaux vibratoires sur une plateforme FPGA », Mémoire de fin d'études de Master, Université de Médéa, Médéa, 2021.
[22] L. Eldén, F. Berntsson, et T. Reginska, « Wavelet and Fourier Methods for Solving the Sideways Heat Equation », *SIAM J. Sci. Comput.*, vol. 21, nº 6, p. 2187-2205, janv. 2000, doi: 10.1137/s1064827597331394.
[23] I. M. Johnstone et B. W. Silverman, « Wavelet Threshold Estimators for Data with Correlated Noise », *J. R. Stat. Soc. Ser. B Stat. Methodol.*, vol. 59, nº 2, p. 319-351, juill. 1997, doi: 10.1111/1467-9868.00071.
[24] C. Fuhrer, « Intelligence Artificielle : que dit la recherche récente ? Une approche combinée bibliométrique et textuelle »:, *Manag. Avenir*, vol. N° 137, nº 5, p. 89-111, oct. 2023, doi: 10.3917/mav.137.0089.
[25] A. M. Turing, « I.—COMPUTING MACHINERY AND INTELLIGENCE », *Mind*, vol. LIX, nº 236, p. 433-460, oct. 1950, doi: 10.1093/mind/LIX.236.433.
[26] John McCarthy, Marvin L. Minsky, Nathaniel Rochester, et Claude E. Shannon, « A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence », 1956.
[27] M. Minsky, *Semantic information processing*, 6. pr. Cambridge, Mass.: MIT Pr, 1988.
[28] Ian Goodfellow, Yoshua Bengio, et Aaron Courville, *Deep learning*. MIT, 2017.
[29] Radhey Shyam, « A Taxonomy of Machine Learning Techniques », *J. Adv. Robot.*.
[30] T. M. Mitchell, *Machine learning*, Nachdr. in McGraw-Hill series in Computer Science. New York: McGraw-Hill, 2013.
[31] C. M. Bishop, *Pattern recognition and machine learning*. in Information science and statistics. New York: Springer, 2006.
[32] E. Alpaydin, *Introduction to machine learning*, 3rd ed. in Adaptive computation and machine learning. Cambridge: MIT press, 2014.
[33] Hastie, T., Tibshirani, R., & Friedman, J., *The Elements of Statistical Learning*. Springer, 2009.
[34] P.-N. Tan, M. Steinbach, et V. Kumar, *Introduction to data mining*, New internat. edition. in Always learning. Harlow: Pearson, 2014.
[35] Richard S. Sutton and Andrew G. Barto, *Reinforcement Learning: An Introduction*, 2e éd. Massachusetts London, England: The MIT Press Cambridge, 2015.
[36] F. Rosenblatt, « The perceptron: A probabilistic model for information storage and organization in the brain. », *Psychol. Rev.*, vol. 65, nº 6, p. 386-408, 1958, doi: 10.1037/h0042519.
[37] W. S. McCulloch et W. Pitts, « A logical calculus of the ideas immanent in nervous activity », *Bull. Math. Biophys.*, vol. 5, nº 4, p. 115-133, déc. 1943, doi: 10.1007/BF02478259.

[38] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*, Second edition. Beijing Boston Farnham Sebastopol Tokyo: O'Reilly, 2019.
[39] J. Fürnkranz, « Decision Tree », in *Encyclopedia of Machine Learning and Data Mining*, C. Sammut et G. I. Webb, Éd., Boston, MA: Springer US, 2017, p. 330-335. doi: 10.1007/978-1-4899-7687-1_66.
[40] T. Chen et C. Guestrin, « XGBoost: A Scalable Tree Boosting System », in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA: ACM, août 2016, p. 785-794. doi: 10.1145/2939672.2939785.
[41] Y. LeCun, Y. Bengio, et G. Hinton, « Deep learning », *Nature*, vol. 521, nº 7553, p. 436-444, mai 2015, doi: 10.1038/nature14539.
[42] S. Hochreiter et J. Schmidhuber, « Long Short-Term Memory », *Neural Comput.*, vol. 9, nº 8, p. 1735-1780, nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
[43] I. Goodfellow *et al.*, « Generative adversarial networks », *Commun. ACM*, vol. 63, nº 11, p. 139-144, oct. 2020, doi: 10.1145/3422622.
[44] F. Pedregosa et al., « Scikit-learn: Machine Learning in Python », *J. Mach. Learn. Res.*, vol. 12, p. 2825-2830, 2011.
[45] S. Bruinsma, R. D. Geertsma, R. Loendersloot, et T. Tinga, « Motor current and vibration monitoring dataset for various faults in an E-motor-driven centrifugal pump », *Data Brief*, vol. 52, p. 109987, févr. 2024, doi: 10.1016/j.dib.2023.109987.
[46] C. Liu et S. Yang, « Personalized Learning Ability Classification Using SVM for Enhanced Education in System Modeling and Simulation Courses », *Front. Digit. Educ.*, vol. 1, nº 4, p. 295-307, déc. 2024, doi: 10.1007/s44366-024-0035-6.
[47] M. C. Calzarossa, P. Giudici, et R. Zieni, « How robust are ensemble machine learning explanations? », *Neurocomputing*, vol. 630, p. 129686, mai 2025, doi: 10.1016/j.neucom.2025.129686.
[48] J. Zhen *et al.*, « Performance of XGBoost Ensemble Learning Algorithm for Mangrove Species Classification with Multisource Spaceborne Remote Sensing Data », *J. Remote Sens.*, vol. 4, p. 0146, janv. 2024, doi: 10.34133/remotesensing.0146.
[49] R. K. Halder, M. N. Uddin, Md. A. Uddin, S. Aryal, et A. Khraisat, « Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications », *J. Big Data*, vol. 11, nº 1, p. 113, août 2024, doi: 10.1186/s40537-024-00973-y.
[50] L. Feng, J. Zhao, T. Liang, S. Sinha, et W. Zhang, « LAMA: Link-Aware Hybrid Management for Memory Accesses in Emerging CPU-FPGA Platforms », in *Proceedings of the 56th Annual Design Automation Conference 2019*, Las Vegas NV USA: ACM, juin 2019, p. 1-6. doi: 10.1145/3316781.3317846.
[51] « ESP32-S3 Series Datasheet Version 2.0 ». espressif.

Annexes

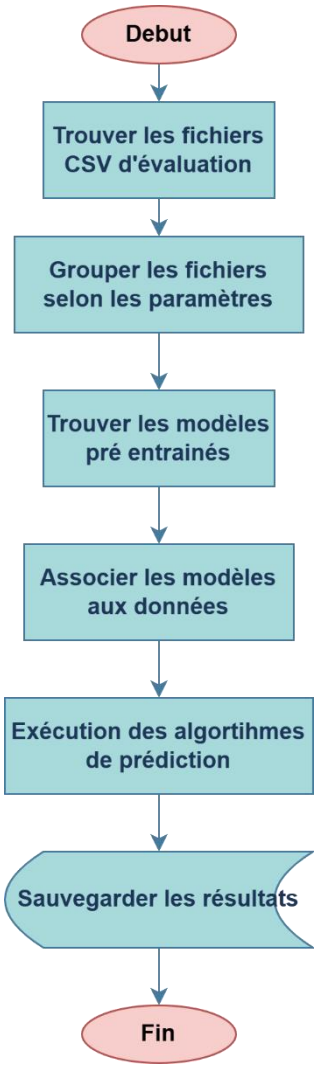
Annexe A

Organigramme d'apprentissage des modèles d'intelligence artificielle sur Jupyter Lab



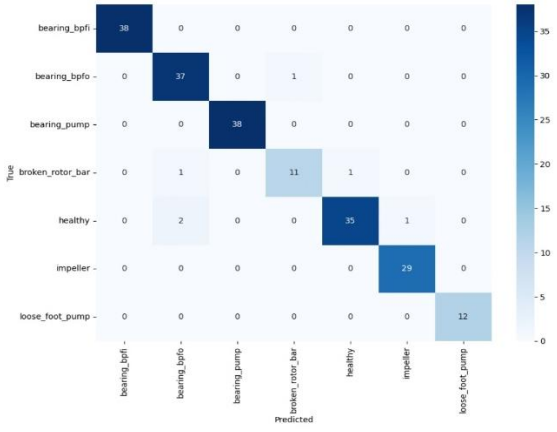
Annexe B

Organigramme d'évaluation des modèles d'intelligence artificielle sur Jupyter Lab

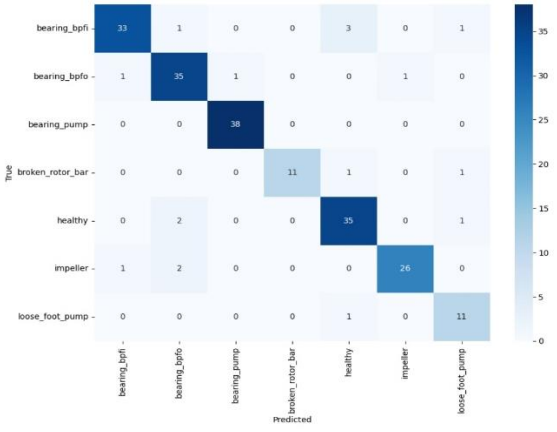


Annexe C

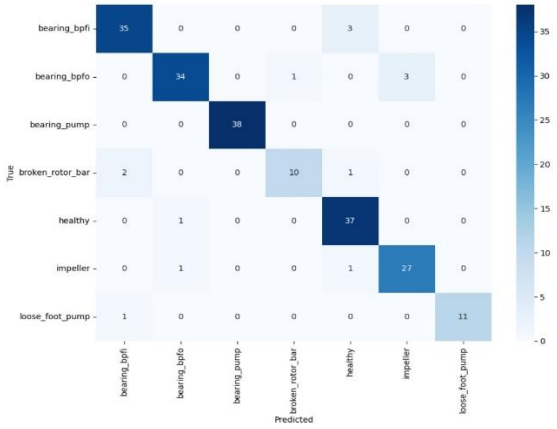
Matrices de confusion des meilleurs modèles de chaque type (Pompe 2)



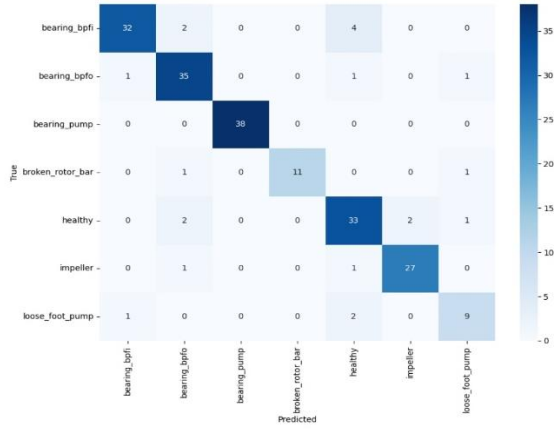
XGBoost 97.09% (2s, DWT8, Energie + kurtosis)



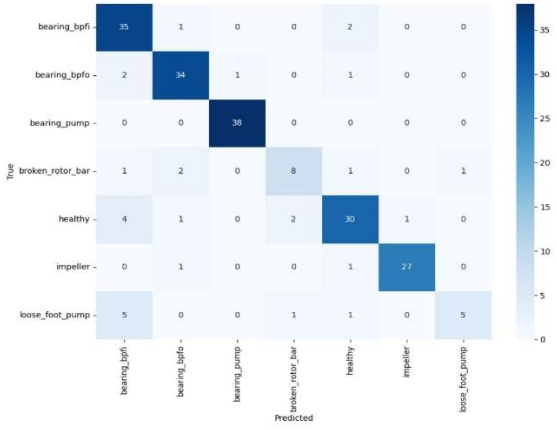
ANN 91.75 % (2s, DWT5, RMS)



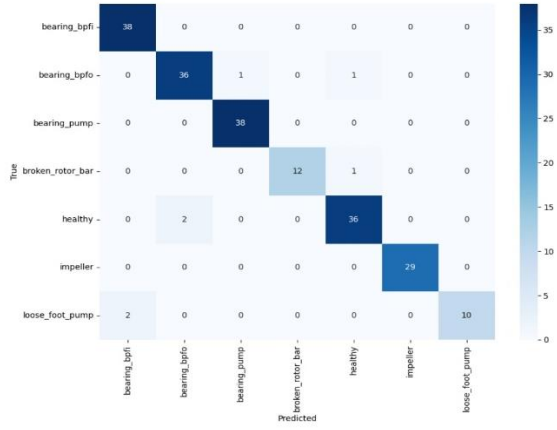
DNN 93.20% (2s, DWT6, Energie + RMS)



Decision Tree 89.81 % (2s, DWT7, Energie + Kurtosis)



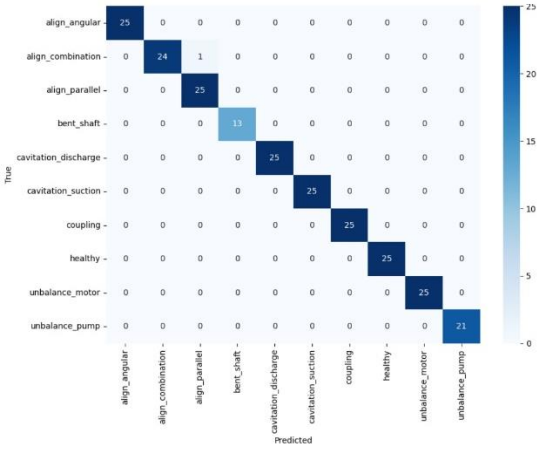
SVM 85.92% (2s, DWT7, RMS)



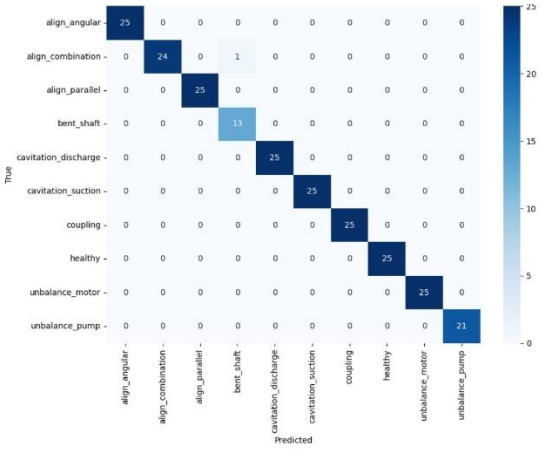
Random Forest 89.81 % (2s, DWT8, Energie + Kurtosis)

Annexe D

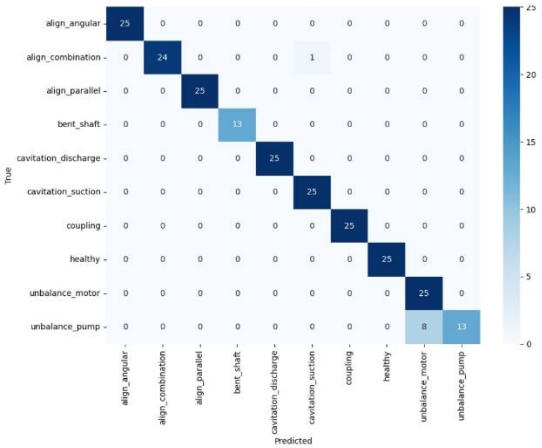
Matrices de confusion des meilleurs modèles de chaque type (Pompe 4)



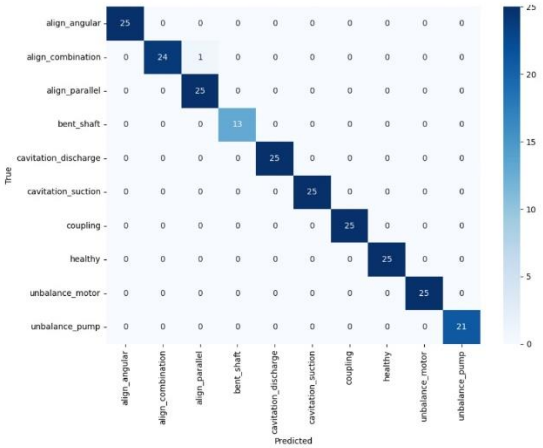
XGBoost 99.57% (2s, DWT8, RMS)



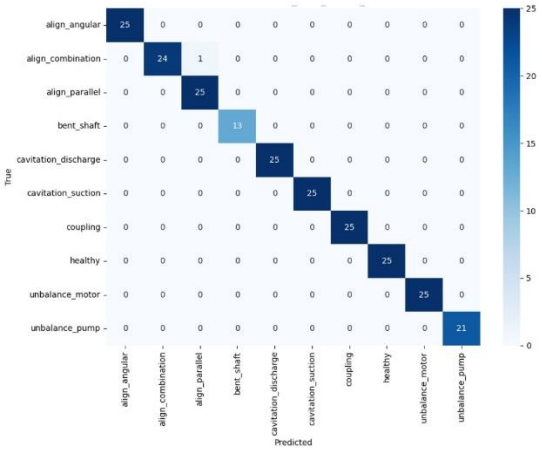
DNN 99.57% (2s, DWT8, Energie)



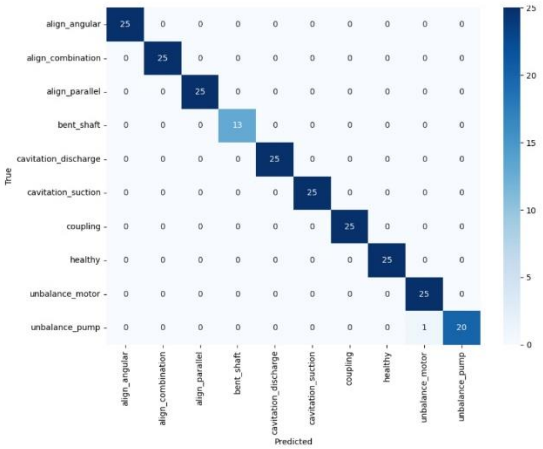
SVM 99.57% (2s, DWT7, Energie)



Random Forest 99.57% (2s, DWT7, Energie)



Decision Tree 99.57% (2s, DWT7, RMS)



ADNN 99.57% (2s, DWT7, Energie)

Annexe E

Résultats d'exactitude de la pompe 2, obtenus avec énergie

Segment	DWT Level	Model	Accuracy
2000ms	dwt7	RF	0,9563
2000ms	dwt8	RF	0,9563
2000ms	dwt5	RF	0,9515
2000ms	dwt7	XGB	0,9466
2000ms	dwt8	XGB	0,9466
2000ms	dwt4	RF	0,9272
2000ms	dwt6	RF	0,9272
2000ms	dwt4	XGB	0,9223
1000ms	dwt7	RF	0,9148
1000ms	dwt8	XGB	0,9148
1000ms	dwt7	XGB	0,9124
1000ms	dwt8	RF	0,91
2000ms	dwt5	XGB	0,9029
2000ms	dwt6	XGB	0,9029
2000ms	dwt3	RF	0,8981
1000ms	dwt6	RF	0,8905
2000ms	dwt3	DNN	0,8835
2000ms	dwt3	XGB	0,8786
2000ms	dwt4	DNN	0,8786
2000ms	dwt7	ANN	0,8738
1000ms	dwt6	XGB	0,871
2000ms	dwt8	DT	0,8689
2000ms	dwt8	DNN	0,8689
1000ms	dwt5	RF	0,8662
1000ms	dwt5	XGB	0,8662
1000ms	dwt4	RF	0,8613
2000ms	dwt7	DT	0,8592
1000ms	dwt7	DNN	0,8564
2000ms	dwt5	DT	0,8544
1000ms	dwt4	DNN	0,854
1000ms	dwt8	DNN	0,854
1000ms	dwt3	DNN	0,8516
2000ms	dwt7	DNN	0,8495
2000ms	dwt3	DT	0,8447
1000ms	dwt7	DT	0,8443
1000ms	dwt8	DT	0,8443
1000ms	dwt3	RF	0,8418
2000ms	dwt8	ANN	0,8398
1000ms	dwt6	DNN	0,837
500ms	dwt8	DNN	0,8368
500ms	dwt8	RF	0,8368
500ms	dwt7	RF	0,8356
1000ms	dwt4	XGB	0,8345
500ms	dwt8	XGB	0,8307
1000ms	dwt5	DNN	0,8273
500ms	dwt7	XGB	0,827
1000ms	dwt8	ANN	0,8224
2000ms	dwt6	DT	0,8204
2000ms	dwt8	svm	0,8155
2000ms	dwt4	ANN	0,8107
2000ms	dwt4	DT	0,8107
500ms	dwt6	XGB	0,81
500ms	dwt7	DNN	0,8076
2000ms	dwt6	DNN	0,8058
1000ms	dwt3	XGB	0,8054
500ms	dwt6	RF	0,8051
1000ms	dwt7	ANN	0,8029
2000ms	dwt7	svm	0,801
1000ms	dwt3	ANN	0,8005
1000ms	dwt4	ANN	0,7908
1000ms	dwt6	ANN	0,7883
2000ms	dwt6	ANN	0,7864
500ms	dwt5	RF	0,7856
1000ms	dwt3	DT	0,7786
1000ms	dwt5	DT	0,7786
500ms	dwt5	XGB	0,7722
1000ms	dwt6	DT	0,7713
1000ms	dwt8	svm	0,7713
1000ms	dwt4	DT	0,7664
1000ms	dwt5	ANN	0,7664
500ms	dwt3	DNN	0,7625
500ms	dwt4	RF	0,76
500ms	dwt3	RF	0,7576
500ms	dwt5	DNN	0,7552
1000ms	dwt7	svm	0,7494
500ms	dwt4	XGB	0,7479
500ms	dwt7	ANN	0,7442
500ms	dwt3	XGB	0,7333
500ms	dwt8	ANN	0,732
500ms	dwt6	DNN	0,7296
500ms	dwt6	ANN	0,7272
500ms	dwt5	ANN	0,7211
500ms	dwt8	DT	0,6991
500ms	dwt3	ANN	0,6943
2000ms	dwt5	ANN	0,6845
500ms	dwt6	DT	0,6833
500ms	dwt7	DT	0,6797
500ms	dwt4	ANN	0,6784
2000ms	dwt6	svm	0,6699
500ms	dwt7	svm	0,6687
2000ms	dwt3	ANN	0,665
1000ms	dwt6	svm	0,6642
500ms	dwt4	DNN	0,6638
500ms	dwt8	svm	0,6577
500ms	dwt5	DT	0,6529
500ms	dwt4	DT	0,648
500ms	dwt3	DT	0,6443
2000ms	dwt5	DNN	0,6311
1000ms	dwt3	svm	0,618
2000ms	dwt5	svm	0,5971
500ms	dwt6	svm	0,5968
1000ms	dwt5	svm	0,5888
500ms	dwt4	svm	0,5749
500ms	dwt5	svm	0,5713
500ms	dwt3	svm	0,5652
1000ms	dwt4	svm	0,5645
2000ms	dwt3	svm	0,5437
2000ms	dwt4	svm	0,5243

Annexe F

Résultats d'exactitude de la pompe 2, obtenus avec la valeur efficace (RMS)

Segment	DWT Level	Model	Accuracy
2000ms	dwt8	RF	0,9612
2000ms	dwt8	XGB	0,9612
2000ms	dwt6	RF	0,9563
2000ms	dwt7	RF	0,9563
2000ms	dwt7	XGB	0,9563
2000ms	dwt5	RF	0,9466
1000ms	dwt8	RF	0,9392
1000ms	dwt8	XGB	0,9367
1000ms	dwt7	RF	0,9246
2000ms	dwt6	XGB	0,9223
1000ms	dwt6	XGB	0,9197
2000ms	dwt5	ANN	0,9175
2000ms	dwt5	XGB	0,9175
2000ms	dwt8	DNN	0,9175
1000ms	dwt6	RF	0,9173
2000ms	dwt4	RF	0,9126
1000ms	dwt7	XGB	0,9124
1000ms	dwt7	DNN	0,91
2000ms	dwt3	DNN	0,9078
2000ms	dwt5	DNN	0,9078
2000ms	dwt6	DNN	0,9078
2000ms	dwt7	DNN	0,9078
1000ms	dwt8	DNN	0,9051
2000ms	dwt8	ANN	0,9029
1000ms	dwt7	ANN	0,9027
2000ms	dwt4	XGB	0,8981
1000ms	dwt5	XGB	0,8978
2000ms	dwt3	RF	0,8932
2000ms	dwt4	DNN	0,8932
2000ms	dwt7	DT	0,8932
2000ms	dwt8	DT	0,8932
1000ms	dwt5	RF	0,8929
1000ms	dwt6	DNN	0,8929
2000ms	dwt3	XGB	0,8883
2000ms	dwt6	DT	0,8835
2000ms	dwt7	ANN	0,8835
1000ms	dwt6	ANN	0,8832
1000ms	dwt7	DT	0,8759
2000ms	dwt5	DT	0,8738
500ms	dwt8	DNN	0,8733
1000ms	dwt8	ANN	0,871
1000ms	dwt8	DT	0,871
2000ms	dwt3	DT	0,8689
2000ms	dwt7	SVM	0,8592
1000ms	dwt5	DNN	0,8589
1000ms	dwt6	DT	0,8564
500ms	dwt8	RF	0,8563
1000ms	dwt4	RF	0,854
2000ms	dwt6	ANN	0,8495
2000ms	dwt8	SVM	0,8495
1000ms	dwt4	XGB	0,8491
500ms	dwt6	DNN	0,8477
1000ms	dwt3	DNN	0,8467
500ms	dwt8	XGB	0,8465
1000ms	dwt3	ANN	0,8443
1000ms	dwt4	DNN	0,8418
500ms	dwt7	DNN	0,8404
1000ms	dwt3	RF	0,8394
500ms	dwt7	RF	0,8392
500ms	dwt7	XGB	0,8368
500ms	dwt6	RF	0,8356
1000ms	dwt3	XGB	0,8297
1000ms	dwt5	ANN	0,8297
500ms	dwt6	XGB	0,8283
1000ms	dwt5	DT	0,8273
500ms	dwt6	ANN	0,8246
1000ms	dwt4	ANN	0,82
500ms	dwt5	RF	0,8161
2000ms	dwt4	DT	0,8107
500ms	dwt7	ANN	0,8088
500ms	dwt8	ANN	0,8088
500ms	dwt5	DNN	0,8076
500ms	dwt5	XGB	0,799
2000ms	dwt4	ANN	0,7961
2000ms	dwt6	SVM	0,7913
1000ms	dwt4	DT	0,7883
1000ms	dwt8	SVM	0,7859
1000ms	dwt6	SVM	0,7786
1000ms	dwt7	SVM	0,7737
500ms	dwt4	RF	0,7686
500ms	dwt4	DNN	0,7661
500ms	dwt5	ANN	0,7649
1000ms	dwt3	DT	0,7567
500ms	dwt6	DT	0,754
500ms	dwt3	DNN	0,7527
500ms	dwt3	RF	0,7515
500ms	dwt8	SVM	0,7503
500ms	dwt8	DT	0,7491
500ms	dwt4	XGB	0,7467
2000ms	dwt3	ANN	0,7427
500ms	dwt3	ANN	0,7418
500ms	dwt4	ANN	0,7418
500ms	dwt7	SVM	0,7369
500ms	dwt7	DT	0,7333
1000ms	dwt5	SVM	0,7251
500ms	dwt6	SVM	0,7247
500ms	dwt3	XGB	0,7186
500ms	dwt5	DT	0,7065
1000ms	dwt4	SVM	0,7056
2000ms	dwt5	SVM	0,6942
500ms	dwt5	SVM	0,676
1000ms	dwt3	SVM	0,674
500ms	dwt4	DT	0,6736
2000ms	dwt4	SVM	0,6456
500ms	dwt4	SVM	0,6456
500ms	dwt3	SVM	0,6322
500ms	dwt3	DT	0,6309
2000ms	dwt3	SVM	0,5922

Annexe G

Résultats d'exactitude de la pompe 2, obtenus avec l'énergie combinée avec la valeur efficace (RMS)

Segment	DWT Level	Model	Accuracy
2000ms	dwt8	RF	0,9612
2000ms	dwt8	XGB	0,9612
2000ms	dwt7	RF	0,9563
2000ms	dwt7	XGB	0,9563
2000ms	dwt5	RF	0,9515
2000ms	dwt6	RF	0,9515
1000ms	dwt8	XGB	0,9367
2000ms	dwt6	DNN	0,932
1000ms	dwt8	RF	0,9319
2000ms	dwt8	DNN	0,9272
1000ms	dwt7	RF	0,9246
2000ms	dwt4	RF	0,9223
2000ms	dwt6	XGB	0,9223
1000ms	dwt6	XGB	0,9197
2000ms	dwt5	XGB	0,9175
1000ms	dwt6	RF	0,9124
1000ms	dwt7	XGB	0,9124
1000ms	dwt8	DNN	0,91
2000ms	dwt8	ANN	0,9078
1000ms	dwt5	RF	0,9002
2000ms	dwt3	RF	0,8981
2000ms	dwt4	XGB	0,8981
2000ms	dwt5	DNN	0,8981
2000ms	dwt7	DNN	0,8981
1000ms	dwt5	XGB	0,8978
1000ms	dwt6	DNN	0,8954
1000ms	dwt7	DNN	0,8954
2000ms	dwt4	DNN	0,8932
2000ms	dwt7	ANN	0,8932
2000ms	dwt8	DT	0,8932
2000ms	dwt3	XGB	0,8883
2000ms	dwt6	DT	0,8835
2000ms	dwt5	DT	0,8786
1000ms	dwt6	ANN	0,8759
2000ms	dwt6	ANN	0,8738
2000ms	dwt7	DT	0,8738
1000ms	dwt5	DNN	0,8735
1000ms	dwt5	ANN	0,871
2000ms	dwt5	ANN	0,8689
1000ms	dwt7	DT	0,8686
1000ms	dwt8	ANN	0,8686
1000ms	dwt7	ANN	0,8662
1000ms	dwt8	DT	0,8637
1000ms	dwt4	RF	0,8613
500ms	dwt8	DNN	0,8587
500ms	dwt7	DNN	0,8563
2000ms	dwt3	DT	0,8544
1000ms	dwt6	DT	0,854
500ms	dwt8	RF	0,8526
1000ms	dwt3	DNN	0,8516
2000ms	dwt8	SVM	0,8495
1000ms	dwt4	XGB	0,8491
1000ms	dwt4	DNN	0,8467
500ms	dwt8	XGB	0,8465
2000ms	dwt7	SVM	0,8447
500ms	dwt6	RF	0,8429
1000ms	dwt3	RF	0,8418
500ms	dwt6	DNN	0,8417
500ms	dwt7	RF	0,8392
500ms	dwt7	XGB	0,8368
2000ms	dwt4	ANN	0,835
1000ms	dwt3	XGB	0,8297
500ms	dwt6	XGB	0,8283
1000ms	dwt3	ANN	0,8273
1000ms	dwt5	DT	0,8273
2000ms	dwt3	DNN	0,8204
1000ms	dwt4	ANN	0,8175
2000ms	dwt4	DT	0,8155
500ms	dwt5	RF	0,8063
500ms	dwt5	DNN	0,8051
500ms	dwt6	ANN	0,8027
500ms	dwt5	XGB	0,799
500ms	dwt7	ANN	0,7978
500ms	dwt8	ANN	0,7868
1000ms	dwt4	DT	0,7835
1000ms	dwt8	SVM	0,7762
1000ms	dwt7	SVM	0,764
500ms	dwt4	RF	0,7637
2000ms	dwt6	SVM	0,7621
1000ms	dwt3	DT	0,7616
500ms	dwt4	DNN	0,7564
500ms	dwt5	ANN	0,7552
1000ms	dwt6	SVM	0,7543
500ms	dwt6	DT	0,7491
500ms	dwt3	RF	0,7467
500ms	dwt4	XGB	0,7467
500ms	dwt3	DNN	0,7442
2000ms	dwt3	ANN	0,7379
500ms	dwt8	DT	0,7357
500ms	dwt7	DT	0,7308
500ms	dwt8	SVM	0,7296
500ms	dwt3	XGB	0,7186
500ms	dwt5	DT	0,7138
500ms	dwt7	SVM	0,7138
500ms	dwt4	ANN	0,7028
500ms	dwt3	ANN	0,7004
500ms	dwt6	SVM	0,6943
1000ms	dwt5	SVM	0,6788
500ms	dwt4	DT	0,6736
1000ms	dwt4	SVM	0,6715
2000ms	dwt5	SVM	0,6505
500ms	dwt3	DT	0,6431
500ms	dwt5	SVM	0,6431
1000ms	dwt3	SVM	0,6375
500ms	dwt4	SVM	0,6188
2000ms	dwt4	SVM	0,6068
500ms	dwt3	SVM	0,6041
2000ms	dwt3	SVM	0,5874

Annexe H

Résultats d'exactitude de la pompe 2, obtenus avec l'énergie combinée avec Kurtosis

Segment	DWT Level	Model	Accuracy
2000ms	dwt8	XGB	0,9709
2000ms	dwt8	RF	0,966
2000ms	dwt7	RF	0,9612
2000ms	dwt6	RF	0,9563
2000ms	dwt6	XGB	0,9466
2000ms	dwt7	XGB	0,9466
2000ms	dwt5	RF	0,9417
1000ms	dwt8	RF	0,9416
1000ms	dwt8	XGB	0,9367
1000ms	dwt7	RF	0,927
1000ms	dwt7	XGB	0,927
2000ms	dwt4	RF	0,9223
2000ms	dwt5	XGB	0,9175
1000ms	dwt6	RF	0,9173
1000ms	dwt6	XGB	0,9148
2000ms	dwt4	XGB	0,9126
2000ms	dwt3	XGB	0,9078
1000ms	dwt5	RF	0,9075
1000ms	dwt5	XGB	0,9027
2000ms	dwt3	RF	0,8981
2000ms	dwt7	DT	0,8981
2000ms	dwt6	DT	0,8786
2000ms	dwt8	DT	0,8786
1000ms	dwt3	RF	0,8686
1000ms	dwt4	XGB	0,8686
1000ms	dwt4	RF	0,8662
1000ms	dwt3	XGB	0,8589
1000ms	dwt8	DT	0,8564
500ms	dwt8	XGB	0,8563
500ms	dwt8	RF	0,8514
1000ms	dwt6	DT	0,8491
500ms	dwt7	XGB	0,8465
500ms	dwt7	RF	0,8404
2000ms	dwt5	DT	0,8398
500ms	dwt6	XGB	0,8368
500ms	dwt6	RF	0,8356
2000ms	dwt8	ANN	0,835
1000ms	dwt7	DT	0,8345
2000ms	dwt4	DT	0,8252
500ms	dwt6	DNN	0,8234
1000ms	dwt5	DT	0,82
1000ms	dwt8	ANN	0,8175
1000ms	dwt3	DNN	0,8151
500ms	dwt5	RF	0,8112
1000ms	dwt8	DNN	0,8029
500ms	dwt5	XGB	0,8015
2000ms	dwt7	ANN	0,801
1000ms	dwt6	ANN	0,8005
2000ms	dwt3	DNN	0,7961
2000ms	dwt8	DNN	0,7961
2000ms	dwt8	SVM	0,7961
2000ms	dwt3	DT	0,7913
2000ms	dwt7	DNN	0,7913
1000ms	dwt7	ANN	0,7908
1000ms	dwt5	DNN	0,7859
1000ms	dwt7	DNN	0,7859
1000ms	dwt4	DNN	0,7835
500ms	dwt4	RF	0,782
500ms	dwt4	XGB	0,7808
1000ms	dwt5	ANN	0,7786
1000ms	dwt4	ANN	0,7737
500ms	dwt5	DNN	0,7734
1000ms	dwt4	DT	0,7689
500ms	dwt7	DNN	0,76
2000ms	dwt4	DNN	0,7573
500ms	dwt3	RF	0,7503
500ms	dwt4	DNN	0,7503
2000ms	dwt7	SVM	0,7476
1000ms	dwt3	DT	0,7421
500ms	dwt3	XGB	0,7406
1000ms	dwt6	DNN	0,7397
1000ms	dwt8	SVM	0,7397
1000ms	dwt7	SVM	0,7348
500ms	dwt6	DT	0,7345
500ms	dwt7	DT	0,7272
500ms	dwt8	DNN	0,7235
2000ms	dwt6	DNN	0,7233
500ms	dwt8	DT	0,7162
1000ms	dwt3	ANN	0,7056
500ms	dwt8	ANN	0,7028
500ms	dwt3	DNN	0,7016
2000ms	dwt3	ANN	0,699
500ms	dwt5	DT	0,6906
2000ms	dwt6	ANN	0,6845
2000ms	dwt4	ANN	0,665
500ms	dwt7	ANN	0,665
500ms	dwt8	SVM	0,6626
2000ms	dwt5	DNN	0,6602
500ms	dwt4	ANN	0,6602
500ms	dwt7	SVM	0,6577
500ms	dwt3	ANN	0,6553
500ms	dwt4	DT	0,6516
2000ms	dwt6	SVM	0,6505
500ms	dwt5	ANN	0,6456
500ms	dwt3	DT	0,6395
1000ms	dwt6	SVM	0,6277
500ms	dwt6	ANN	0,6029
1000ms	dwt5	SVM	0,5766
2000ms	dwt5	ANN	0,5728
500ms	dwt6	SVM	0,57
2000ms	dwt5	SVM	0,5534
1000ms	dwt3	SVM	0,5426
500ms	dwt3	SVM	0,542
500ms	dwt4	SVM	0,5347
500ms	dwt5	SVM	0,5347
1000ms	dwt4	SVM	0,5328
2000ms	dwt3	SVM	0,5243
2000ms	dwt4	SVM	0,5097

Annexe I

Résultats d'exactitude de la pompe 2, obtenus avec l'énergie combinée avec Crest Factor

Segment	DWT Level	Model	Accuracy
2000ms	dwt8	XGB	0,966
2000ms	dwt7	RF	0,9612
2000ms	dwt7	XGB	0,9612
2000ms	dwt8	RF	0,9612
2000ms	dwt5	RF	0,9515
2000ms	dwt6	RF	0,9466
1000ms	dwt8	XGB	0,944
2000ms	dwt6	XGB	0,9417
1000ms	dwt7	XGB	0,9392
1000ms	dwt8	RF	0,9367
1000ms	dwt7	RF	0,927
1000ms	dwt6	RF	0,9221
2000ms	dwt5	XGB	0,9126
1000ms	dwt6	XGB	0,91
2000ms	dwt4	XGB	0,9078
1000ms	dwt5	XGB	0,9075
2000ms	dwt4	RF	0,9029
1000ms	dwt5	RF	0,8978
2000ms	dwt3	XGB	0,8932
2000ms	dwt3	RF	0,8835
2000ms	dwt8	DT	0,8835
2000ms	dwt6	DT	0,8786
2000ms	dwt7	DT	0,8689
1000ms	dwt3	RF	0,8662
1000ms	dwt3	XGB	0,8637
2000ms	dwt5	DT	0,8592
500ms	dwt8	XGB	0,8575
1000ms	dwt4	XGB	0,8564
500ms	dwt8	RF	0,8526
1000ms	dwt4	RF	0,8491
500ms	dwt7	RF	0,8453
500ms	dwt6	XGB	0,8429
1000ms	dwt8	DT	0,8418
500ms	dwt7	XGB	0,8392
1000ms	dwt7	DT	0,8345
1000ms	dwt6	DT	0,8321
500ms	dwt6	RF	0,8319
1000ms	dwt8	ANN	0,8127
2000ms	dwt4	DT	0,8107
1000ms	dwt5	DT	0,8078
2000ms	dwt8	DNN	0,8058
2000ms	dwt8	SVM	0,8058
1000ms	dwt8	DNN	0,8029
500ms	dwt5	RF	0,8027
2000ms	dwt7	ANN	0,801
2000ms	dwt7	DNN	0,801
500ms	dwt5	XGB	0,799
2000ms	dwt8	ANN	0,7913
500ms	dwt7	DNN	0,7893
1000ms	dwt7	DNN	0,7835
1000ms	dwt8	SVM	0,781
1000ms	dwt3	DNN	0,7786
500ms	dwt6	DNN	0,7771
1000ms	dwt4	DNN	0,7737
500ms	dwt5	DNN	0,7734
2000ms	dwt3	DT	0,7718
1000ms	dwt4	DT	0,7713
500ms	dwt4	RF	0,771
2000ms	dwt7	SVM	0,7621
500ms	dwt4	XGB	0,76
500ms	dwt3	RF	0,7576
1000ms	dwt7	ANN	0,7567
1000ms	dwt7	SVM	0,7567
2000ms	dwt6	DNN	0,7524
500ms	dwt8	DNN	0,7491
1000ms	dwt4	ANN	0,7445
500ms	dwt3	XGB	0,743
2000ms	dwt3	DNN	0,7427
1000ms	dwt6	ANN	0,7397
1000ms	dwt3	DT	0,7324
1000ms	dwt5	DNN	0,7324
500ms	dwt7	DT	0,732
500ms	dwt6	DT	0,7284
1000ms	dwt3	ANN	0,7226
1000ms	dwt5	ANN	0,7202
500ms	dwt4	DNN	0,7174
500ms	dwt8	DT	0,7138
1000ms	dwt6	DNN	0,7105
500ms	dwt7	ANN	0,7101
500ms	dwt3	DNN	0,7089
500ms	dwt5	DT	0,7052
500ms	dwt8	ANN	0,7016
2000ms	dwt4	ANN	0,699
2000ms	dwt4	DNN	0,6796
2000ms	dwt6	ANN	0,6796
500ms	dwt8	SVM	0,6748
500ms	dwt7	SVM	0,6687
500ms	dwt5	ANN	0,6602
2000ms	dwt6	SVM	0,6505
500ms	dwt6	ANN	0,6504
500ms	dwt4	ANN	0,6468
1000ms	dwt6	SVM	0,6423
500ms	dwt4	DT	0,6395
500ms	dwt3	DT	0,637
2000ms	dwt3	ANN	0,6359
2000ms	dwt5	ANN	0,6068
2000ms	dwt5	SVM	0,6068
1000ms	dwt5	SVM	0,5985
500ms	dwt6	SVM	0,5859
2000ms	dwt5	DNN	0,5728
500ms	dwt5	SVM	0,5676
500ms	dwt3	ANN	0,5664
500ms	dwt3	SVM	0,553
1000ms	dwt4	SVM	0,5499
500ms	dwt4	SVM	0,5396
1000ms	dwt3	SVM	0,5377
2000ms	dwt3	SVM	0,534
2000ms	dwt4	SVM	0,5243

Annexe J

Résultats d'exactitude de la pompe 4, obtenus avec l'énergie

Segment	DWT Level	Model	Accuracy
2000ms	dwt7	ANN	0,9957
2000ms	dwt7	RF	0,9957
2000ms	dwt8	ANN	0,9957
2000ms	dwt8	DNN	0,9957
2000ms	dwt8	RF	0,9957
2000ms	dwt8	SVM	0,9957
2000ms	dwt8	XGB	0,9957
500ms	dwt8	RF	0,9947
500ms	dwt8	XGB	0,9947
1000ms	dwt7	XGB	0,9936
1000ms	dwt8	XGB	0,9936
500ms	dwt7	XGB	0,9925
500ms	dwt7	RF	0,9904
500ms	dwt8	ANN	0,9904
1000ms	dwt7	RF	0,9893
1000ms	dwt8	RF	0,9893
500ms	dwt8	DNN	0,9893
500ms	dwt8	SVM	0,9882
1000ms	dwt8	ANN	0,9872
1000ms	dwt8	SVM	0,9872
2000ms	dwt6	RF	0,9872
2000ms	dwt6	XGB	0,9872
2000ms	dwt7	DNN	0,9872
2000ms	dwt7	XGB	0,9872
2000ms	dwt8	DT	0,9872
500ms	dwt7	DNN	0,9872
500ms	dwt7	ANN	0,985
500ms	dwt8	DT	0,985
1000ms	dwt6	RF	0,9829
1000ms	dwt7	ANN	0,9829
2000ms	dwt6	DNN	0,9829
2000ms	dwt7	DT	0,9829
1000ms	dwt6	XGB	0,9808
1000ms	dwt8	DNN	0,9808
1000ms	dwt7	DT	0,9786
1000ms	dwt7	DNN	0,9786
1000ms	dwt7	SVM	0,9786
2000ms	dwt3	DNN	0,9786
2000ms	dwt5	ANN	0,9786
2000ms	dwt5	RF	0,9786
2000ms	dwt5	XGB	0,9786
2000ms	dwt6	ANN	0,9786
500ms	dwt7	SVM	0,9786
1000ms	dwt5	XGB	0,9765
1000ms	dwt8	DT	0,9765
2000ms	dwt4	RF	0,9744
2000ms	dwt5	DNN	0,9744
1000ms	dwt6	DNN	0,9722
2000ms	dwt5	DT	0,9701
500ms	dwt6	XGB	0,9701
500ms	dwt7	DT	0,9679
500ms	dwt6	RF	0,9669
1000ms	dwt5	RF	0,9658
2000ms	dwt4	ANN	0,9658
2000ms	dwt3	RF	0,9615
2000ms	dwt3	XGB	0,9615
2000ms	dwt6	DT	0,9615
2000ms	dwt7	SVM	0,9615
1000ms	dwt4	RF	0,9573
2000ms	dwt4	DNN	0,9573
2000ms	dwt4	XGB	0,9573
500ms	dwt5	DNN	0,9562
2000ms	dwt3	ANN	0,953
500ms	dwt6	DNN	0,953
500ms	dwt5	RF	0,9509
500ms	dwt5	XGB	0,9487
2000ms	dwt4	DT	0,9444
1000ms	dwt4	XGB	0,9423
1000ms	dwt6	ANN	0,9423
1000ms	dwt5	DNN	0,9402
1000ms	dwt6	SVM	0,9402
1000ms	dwt3	RF	0,938
1000ms	dwt6	DT	0,938
1000ms	dwt3	XGB	0,9359
2000ms	dwt3	DT	0,9359
500ms	dwt6	ANN	0,9359
500ms	dwt6	DT	0,9359
1000ms	dwt5	DT	0,9295
500ms	dwt4	DNN	0,9263
500ms	dwt5	ANN	0,9231
500ms	dwt4	RF	0,922
500ms	dwt4	XGB	0,922
1000ms	dwt5	SVM	0,9209
2000ms	dwt6	SVM	0,9188
500ms	dwt6	SVM	0,9177
1000ms	dwt4	DNN	0,9145
500ms	dwt5	DT	0,9124
1000ms	dwt3	DT	0,9103
1000ms	dwt3	DNN	0,9103
500ms	dwt3	RF	0,9028
500ms	dwt3	XGB	0,9028
1000ms	dwt4	DT	0,9017
1000ms	dwt5	ANN	0,8996
1000ms	dwt4	ANN	0,8953
500ms	dwt3	DNN	0,8953
2000ms	dwt5	SVM	0,8932
500ms	dwt4	DT	0,8889
500ms	dwt4	ANN	0,8868
500ms	dwt5	SVM	0,8868
1000ms	dwt4	SVM	0,8846
2000ms	dwt4	SVM	0,8718
500ms	dwt3	ANN	0,8622
500ms	dwt3	DT	0,86
2000ms	dwt3	SVM	0,8547
1000ms	dwt3	SVM	0,8526
500ms	dwt4	SVM	0,8462
500ms	dwt3	SVM	0,8184
1000ms	dwt3	ANN	0,7821

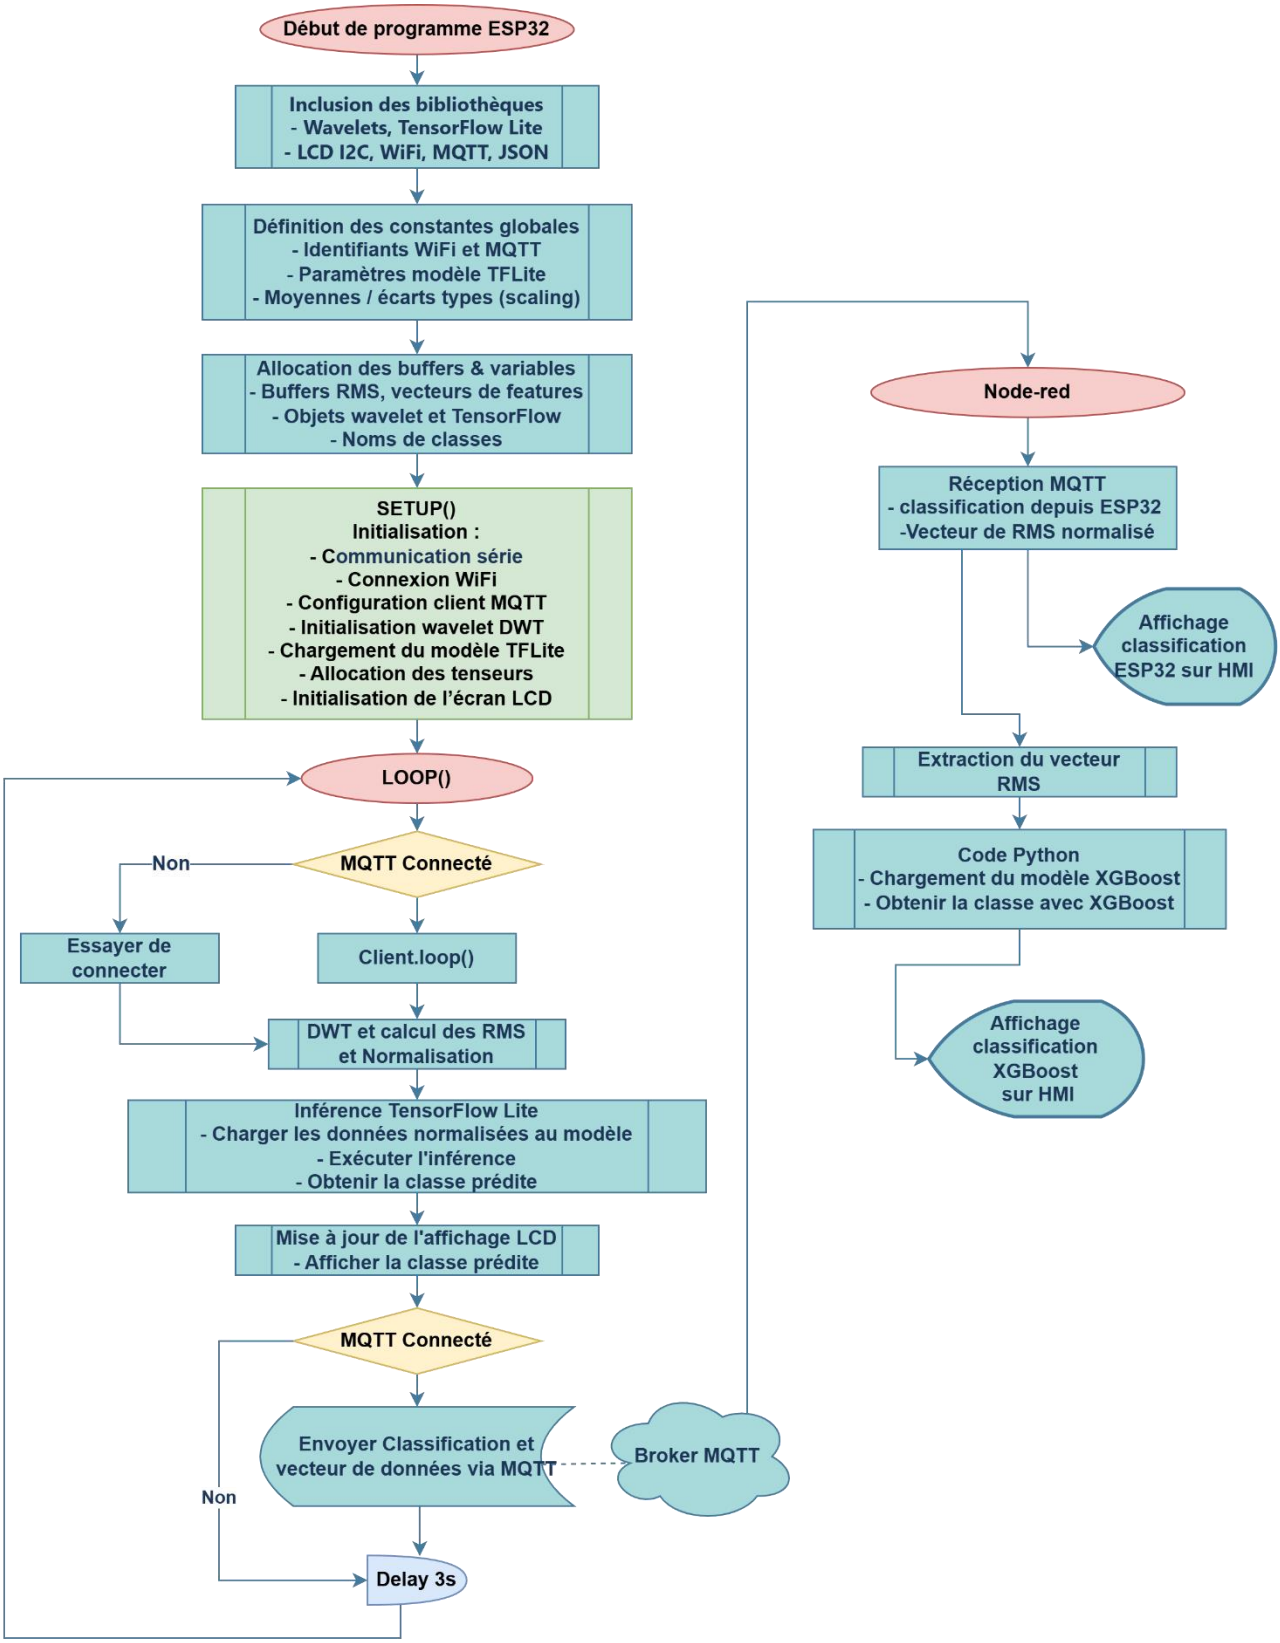
Annexe K

Résultats d'exactitude de la pompe 4, obtenus avec la valeur efficace (RMS)

Segment	DWT Level	Model	Accuracy
2000ms	dwt7	DT	0,9957
2000ms	dwt7	RF	0,9957
2000ms	dwt8	DNN	0,9957
2000ms	dwt8	RF	0,9957
2000ms	dwt8	XGB	0,9957
2000ms	dwt7	ANN	0,9915
2000ms	dwt7	DNN	0,9915
2000ms	dwt7	XGB	0,9915
2000ms	dwt8	ANN	0,9915
2000ms	dwt8	DT	0,9915
1000ms	dwt7	RF	0,9893
1000ms	dwt7	XGB	0,9893
1000ms	dwt8	RF	0,9893
1000ms	dwt8	XGB	0,9893
1000ms	dwt7	DNN	0,9872
2000ms	dwt8	SVM	0,9872
2000ms	dwt5	RF	0,9829
2000ms	dwt7	SVM	0,9829
1000ms	dwt8	ANN	0,9808
2000ms	dwt3	DNN	0,9786
2000ms	dwt4	RF	0,9786
2000ms	dwt5	DNN	0,9786
1000ms	dwt8	DNN	0,9765
2000ms	dwt3	ANN	0,9744
2000ms	dwt3	RF	0,9744
2000ms	dwt3	XGB	0,9744
2000ms	dwt4	DNN	0,9744
2000ms	dwt6	RF	0,9744
500ms	dwt8	DNN	0,9733
1000ms	dwt7	ANN	0,9722
1000ms	dwt7	DT	0,9722
1000ms	dwt8	SVM	0,9701
2000ms	dwt5	ANN	0,9701
2000ms	dwt5	XGB	0,9701
2000ms	dwt6	ANN	0,9701
2000ms	dwt6	DNN	0,9701
500ms	dwt8	XGB	0,9701
500ms	dwt8	ANN	0,969
1000ms	dwt7	SVM	0,9658
1000ms	dwt8	DT	0,9658
2000ms	dwt4	ANN	0,9658
2000ms	dwt6	XGB	0,9658
500ms	dwt7	XGB	0,9658
500ms	dwt7	ANN	0,9647
500ms	dwt7	DNN	0,9647
1000ms	dwt4	RF	0,9637
1000ms	dwt5	XGB	0,9637
1000ms	dwt5	RF	0,9615
1000ms	dwt6	XGB	0,9615
2000ms	dwt5	DT	0,9615
500ms	dwt8	RF	0,9605
1000ms	dwt4	XGB	0,9594
1000ms	dwt6	RF	0,9594
2000ms	dwt4	XGB	0,9573
500ms	dwt7	RF	0,9562
1000ms	dwt5	DNN	0,9551
500ms	dwt8	SVM	0,953
2000ms	dwt3	DT	0,9487
500ms	dwt7	SVM	0,9466
2000ms	dwt6	DT	0,9444
1000ms	dwt3	XGB	0,9423
1000ms	dwt3	RF	0,9402
1000ms	dwt4	DNN	0,938
2000ms	dwt4	DT	0,9359
1000ms	dwt5	DT	0,9338
1000ms	dwt4	DT	0,9316
500ms	dwt4	DNN	0,9295
1000ms	dwt6	DNN	0,9252
500ms	dwt7	DT	0,9241
1000ms	dwt6	DT	0,9209
500ms	dwt8	DT	0,9209
500ms	dwt4	ANN	0,9199
2000ms	dwt6	SVM	0,9188
500ms	dwt5	RF	0,9188
500ms	dwt5	ANN	0,9177
500ms	dwt4	XGB	0,9167
500ms	dwt6	RF	0,9156
500ms	dwt6	XGB	0,9156
1000ms	dwt4	ANN	0,9145
500ms	dwt5	DNN	0,9145
500ms	dwt5	XGB	0,9135
500ms	dwt4	RF	0,9113
1000ms	dwt3	DNN	0,9103
2000ms	dwt5	SVM	0,9103
1000ms	dwt6	ANN	0,906
2000ms	dwt4	SVM	0,906
500ms	dwt6	ANN	0,906
500ms	dwt3	DNN	0,9038
1000ms	dwt5	SVM	0,8996
500ms	dwt3	ANN	0,8953
500ms	dwt6	DNN	0,8942
2000ms	dwt3	SVM	0,8932
500ms	dwt3	RF	0,8921
1000ms	dwt4	SVM	0,891
500ms	dwt3	XGB	0,89
1000ms	dwt6	SVM	0,8868
1000ms	dwt3	ANN	0,8846
1000ms	dwt3	DT	0,8825
500ms	dwt4	DT	0,8782
500ms	dwt5	SVM	0,8718
500ms	dwt4	SVM	0,8707
500ms	dwt6	SVM	0,8707
1000ms	dwt3	SVM	0,8675
1000ms	dwt5	ANN	0,8654
500ms	dwt3	DT	0,8558
500ms	dwt6	DT	0,8536
500ms	dwt5	DT	0,8526
500ms	dwt3	SVM	0,8365

Annexe L

Diagramme de fonctionnement du système complet



RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITÉ YAHIA FARÈS DE MÉDÉA



Faculté de Technologie
Département de Génie Électrique
Mémoire de Master
Domaine : Electronique
Spécialité : Instrumentation



PumpGuard AI

Présenté par :

SAIDI Madani Amine

LEBOUKH Aboubakr

Encadré par:

Dr. Bengherbia Billel

Mr. Tobbal Abdelhafid

Promotion 2025

Fiche d'information :

À propos de l'équipe de gestion du groupe de travail

1- Équipe de gestion :

Équipe de gestion	
Encadrant principal : Dr.Bengherbia Billel	Spécialité : Electronique
Co-encadrant : Mr. Tobbal Abdelhafid	Spécialité : Electronique



2- Équipe de projet :

Équipe de projet	Département	Spécialité
Étudiant 01 : SAIDI Madani Amine	Technologie	Instumentation
Étudiant 02 : LEBOUKH Aboubakr	Technologie	Instumentation



Table des Matières



Table des matières

1. Introduction 5
2. Présentation du projet 7
   2.1. Idée du projet (Solution Proposer) 7
   2.2. Valeurs proposées 8
   2.3. Équipe de travail 8
   2.4. Tâches de chaque membre de l'équipe : 9
   2.5. Objectives du Project 10
   2.6. Planning de Lancement du Projet 11
3. Aspects innovants 13
4. Les segments de clients: 15
   4.1. Mesure de l'Intensité Concurrentielle 16
5. Plan d'Organisation et de Production 21
   5.1. Structure Organisationnelle 21
   5.2. Processus de Production (chaîne de valeur) 22
   5.3. Ressources Matérielles & Logistiques 22
   5.4. Plan de Déploiement & Lancement (année 1) 23
   5.5. Évolution à Moyen Terme (année 2 et +) 23
6. Plan Financier 25
   6.1. Hypothèses de base 25
   6.2. Prévisions de revenus (sur 3 ans) 25
   6.3. Estimation des dépenses annuelles 26
   6.4. Seuil de rentabilité 26
   6.5. Sources de financement envisagées 26
   6.6. Retour sur investissement (ROI) 26
7. Prototype Expérimental 28
8. Annexes 310

Introduction

1. Introduction

Avec l'évolution des technologies industrielles et l'émergence de l'industrie 4.0, la maintenance prédictive s'impose aujourd'hui comme une solution incontournable pour garantir la performance, la sécurité et la disponibilité des équipements critiques. Les pompes centrifuges, largement utilisées dans de nombreux secteurs (pétrochimie, hydraulique, agroalimentaire, etc.), sont souvent soumises à des conditions de fonctionnement intenses qui peuvent engendrer des défaillances imprévues et coûteuses.

Le projet PumpGuard AI s'inscrit dans cette logique de modernisation. Il propose une solution innovante de maintenance prédictive basée sur l'intelligence artificielle et l'analyse avancée de signaux vibratoires. Grâce à l'intégration de capteurs de vibration, d'un traitement de signal avancé, et de modèles d'intelligence artificiel avec apprentissage automatique, PumpGuard AI permet de prédire les défaillances des pompes avant qu'elles ne surviennent, tout en offrant une interface intuitive de surveillance en temps réel.

Ce projet vise non seulement à améliorer la gestion de la maintenance industrielle, mais aussi à encourager l'adoption de technologies intelligentes dans les entreprises algériennes, dans le cadre de la dynamique nationale de soutien à l'innovation et de l'entrepreneuriat universitaire promue par l'Arrêté Ministériel 1275.

Le premier axe
Présentation
Du projet



Le premier axe :

Présentation du projet

2. Présentation du projet

2.1. Idée du projet (Solution Proposer)

PumpGuard AI est une solution de maintenance prédictive dédiée aux pompes centrifuges industrielles. Le système anticipe les pannes avant qu'elles ne se produisent en analysant les données issues de capteurs de vibration, traitées via des techniques de traitement du signal et d'intelligence artificielle.

PumpGuard AI se décline en trois versions :

1. PumpGuard Essential

- Public cible : PME, ateliers de maintenance, techniciens indépendants.
- Positionnement : Solution d'entrée de gamme, simple et abordable.
- Fonctionnalités clés :

  Détection basique : Vibrations, cavitation, désalignement (seuils prédéfinis).

  Matériel : Capteurs économiques + boîtier de collecte USB.

  Logiciel : App mobile/web avec alertes et historique simplifié.

2. PumpGuard Pro

- Public cible : Industries (agroalimentaire, traitement des eaux, HVAC).
- Positionnement : Outil professionnel pour la maintenance prédictive.
- Fonctionnalités clés :

  Analyse avancée : IA légère pour classer les défauts (roulements, usure).

  Capteurs intelligents : Vibrations + température + courant moteur.

  Dashboard : Rapports PDF/Excel, recommandations personnalisées.

  Connectivité : Cloud sécurisé (accès multi-utilisateurs).

3. PumpGuard Industrial AI

- Public cible : Secteurs critiques (pétrochimie, énergie, offshore).
- Positionnement : Solution tout-en-un pour les environnements exigeants.
- Fonctionnalités clés :

  Supervision temps réel : Réseau de capteurs IoT + edge computing.

  IA hybride : Modèles physiques + deep learning (détection précoce).

  Intégration : API vers ERP/CMMS, alertes SMS/email.

  Services : Audit sur site + formation dédiée.

2.2. Valeurs proposées

Les valeurs proposées ou livrées aux clients peuvent être identifiées conformément aux éléments suivants :

- Surveillance en temps réel : Les données des capteurs sont traitées localement, permettant un retour immédiat sur l'état de la pompe.
- Modularité du produit : Trois versions (Essential, Pro et Industrial), pour s'adapter aux différents besoins industriels et budgets.
- Simplicité d'intégration : Compatible avec les installations existantes sans besoin de modifications majeures.
- Renforcement de la sécurité : Réduction des risques de panne critique, protégeant les équipements et le personnel.
- Valorisation des données : Historique des anomalies et des diagnostics exploitables pour la maintenance préventive à long terme.

2.3. Équipe de travail

L'équipe de travail est composée de quatre membres :

1.3.1. **Dr. Bengherbia Billel :**

- Domaine d'expérience : Conception et réalisation de matériel électronique
- Qualification : Maître de conférences

- Formation : Accréditation universitaire

1.3.2. M. Tobbal Abdelhafid :

- Domaine d'expérience : Traitement du signal, réseaux de capteurs sans fil, conception de systèmes embarqués et apprentissage automatique
- Qualification : Doctorant en Génie Électronique
- Formation : Électronique et systèmes embarqués

1.3.3. M. SAIDI Madani Amine :

- Domaine d'expérience : Traitement du signal, réseaux de capteurs sans fil, conception des cartes électroniques, apprentissage automatique.
- Qualification : Licence en Télécommunications, Master en Systèmes de Télécommunications et Master en Instrumentation à l'Université de Médéa
- Formation : Electronique et Systèmes de télécommunications, instrumentation

1.3.4. M. LEBOUKH Aboubakr :

- Domaine d'expérience : Traitement du signal, réseaux de capteurs sans fil, conception des cartes électroniques, apprentissage automatique.
- Qualification : Licence en Télécommunications, Master en Systèmes de Télécommunications et Master en Instrumentation à l'Université de Médéa
- Formation : Electronique et Systèmes de télécommunications, instrumentation

2.4. Tâches de chaque membre de l'équipe :

1.4.1. Dr. Bengherbia Billel :

- Idée et développement du projet
- Contribution à la rédaction et à la correction des documents relatifs au projet
- Tests du projet

1.4.2. M. Tobbal Abdelhafid :

- Idée et développement du projet
- Contribution à la rédaction et à la correction des documents relatifs au projet

- Tests du projet

1.4.3. M. SAIDI Madani Amine & M. LEBOUKH Aboubakr :

- Outils logiciels et matériels utilisés
- Développement électronique
- Développement de l'application
- Rédaction des documents relatifs au projet.

2.5. Objectives du project

- **Court terme (1-2 ans)** :
  - Concevoir un prototype fonctionnel pour chaque version.
  - Installer et tester le prototype dans une station de pompage locale.
  - Collecter et analyser les premières données vibratoires réelles.
  - Créer une première interface de diagnostic simple sur écran LCD et application PC.

- **Moyen terme (3-5 ans) :**
  - Optimiser les modèles d'IA pour augmenter la précision des prédictions.
  - Ajouter un système de notification automatique pour les alertes critiques.
  - Nouer des partenariats avec au moins 3 entreprises industrielles pour l'intégration pilote.
  - Démarrer une petite série de production locale avec retour client.

- **Long terme (5+ ans) :**
  - Étendre l'utilisation à d'autres types de machines tournantes (compresseurs, moteurs).
  - Lancer une plateforme cloud pour la gestion centralisée de l'état des équipements.
  - Obtenir une certification industrielle (ISO, etc.) pour la fiabilité du système.
  - Cibler les grands groupes industriels et proposer des contrats de maintenance intelligents.

2.6. Planning de lancement du projet

Mois	Tâches
1	Étude de faisabilité technique, choix des capteurs adaptés.
2	Conception de la carte électronique (ESP32 + modules capteurs).
3	Développement du code embarqué pour la collecte et le traitement des signaux.
4	Acquisition des données de vibration réelles sur site industriel.
5	Prétraitement des signaux (fenêtrage, filtrage) et application de la transformée en ondelettes (DWT).
6	Entraînement et validation des modèles IA (ANN, DNN).
7	Conception du boîtier (3D) et intégration des composants.
8	Développement de l'interface utilisateur (application web ou PC).
9	Intégration finale et assemblage du prototype complet.
10	Phase de tests sur terrain et collecte des retours utilisateurs.
11	Optimisation du système sur base des retours.
12	Préparation à la production pilote et rédaction du dossier de valorisation.

Deuxième axe

Aspects Innovants



Deuxième axe :

Aspects innovants

3. Aspects innovants

- **Première solution embarquée en Algérie :** PumpGuard AI est la première solution locale de maintenance prédictive intégrée, dédiée spécifiquement aux pompes centrifuges, réduisant ainsi la dépendance aux technologies importées.
- **Approche modulaire et évolutive :** Trois versions distinctes permettent une adaptation fine selon la criticité de l'équipement, le budget du client et les conditions de fonctionnement sur site.
- **Fusion du traitement de signal et de l'intelligence artificielle :** Intégration du traitement du signal avancé pour l'extraction de caractéristiques et de modèles d'IA pour un diagnostic fiable et automatisé.
- **Diagnostic local en temps réel :** Traitement embarqué avec affichage instantané des résultats sur écran LCD, éliminant le besoin de serveurs externes pour les analyses.
- **Interface intuitive multi-support :** Accès aux données et à l'état de la machine via écran LCD, application PC ou future interface cloud, facilitant la prise de décision rapide.
- **Orientation vers la maintenance 4.0** : Le système s'inscrit dans la logique de digitalisation industrielle, apportant une couche intelligente aux processus de surveillance prédictive traditionnels.

Troisième axe
Analyse Stratégique Du Marché



Troisième axe :

Analyse stratégique du marché

4. Les segments de clients:

- **Segments cibles** : PumpGuard AI s'adresse aux secteurs utilisant massivement des équipements tournants, notamment :
  - **Sonatrach** : leader dans le domaine du pétrole et du gaz, où la fiabilité des pompes est essentielle.
  - **POVAL** : Entreprise spécialisée dans la production et la commercialisation de pompes, vannes, matériel de voirie, accessoires de tuyauterie et pièces brutes de fonderie, intervenant dans des secteurs industriels où la fiabilité des équipements, comme les pompes, est cruciale dans des environnements sévères.
  - **ADE** (Algérienne des Eaux) : exploitant de réseaux de pompage pour l'eau potable, nécessitant une supervision continue.
  - **Cevital** (ou autre entreprise agroalimentaire) : grand utilisateur de systèmes de pompage pour la production industrielle.
  - Entreprises de maintenance industrielle sous-traitante.
  - **Centres de dessalement** : où la surveillance continue des pompes est cruciale pour assurer la disponibilité de l'eau.
  - **Fermes agricoles modernes** : utilisant des systèmes de pompage pour l'irrigation, souvent éloignés et difficiles à surveiller manuellement.

Ces segments sont caractérisés par leur besoin critique de continuité opérationnelle, leur sensibilité aux pannes et l'intérêt croissant pour les solutions de maintenance intelligente.

- **Analyse concurrentielle :**
  - **Concurrence directe** : Entreprises locales de maintenance préventive qui n'utilisent pas encore d'outils d'IA ou d'analyse vibratoire avancée.

- **Concurrence indirecte** : Solutions étrangères de maintenance conditionnelle avec capteurs importés, souvent coûteuses et non adaptées aux contraintes locales (langue, climat, accessibilité technique).
- **Avantage compétitif** : PumpGuard AI propose une solution flexible, évolutive, et plus accessible financièrement, avec un accompagnement local et une intégration personnalisée.

- **Stratégie d'accès au marché :**
  - Lancement de prototypes dans des environnements industriels réels à travers des démonstrations pilotes gratuites.
  - Participation à des salons industriels, séminaires techniques et foires universitaires.
  - Collaboration avec des incubateurs et des pôles technologiques pour renforcer la visibilité académique et entrepreneuriale.
  - Mise en place d'un modèle économique freemium ou à faible côut.

4.1.Mesure de l'intensité concurrentielle

3.1.1. Identification des concurrents

A. Concurrents directs :

- Startups/PME Locales :
  - Exemple : Algérie Maintenance Tech (solution basique de surveillance IoT).
  - Forces : Connaissance du marché local, coûts réduits.
  - Faiblesses : Limites technologiques (modèles d'IA peu avancés).

- Entreprises Internationales :
  - Siemens Prédictive Maintenance, Schneider Electric EcoStruxure.
  - Forces : Solutions complètes, réputation mondiale.
  - Faiblesses : Prix élevés, support local limité en Algérie.

B. Concurrents indirects :

- Maintenance Traditionnelle :

- Sociétés sous-traitantes de Sonatrach/ADE utilisant des méthodes réactives.
- Forces : Habitudes des clients, infrastructures existantes.
- Faiblesses : Coûts élevés des pannes imprévues.

- Solutions Génériques d'IA :
  - Plateformes comme IBM Maximo (non spécialisées pour les pompes).

3.1.2. Analyse des forces et faiblesses

Critère	Votre Solution (PumpGuard)	Concurrents Locaux	Concurrents Internationaux
Prix	Coût modéré (adapté au marché local)	Bas	Très élevé
Technologie (IA)	Modèles avancés	Modèles simples	Très avancés
Support Local	Équipe locale, réactive	Fort	Limité
Personnalisation	Adapté aux besoins spécifiques des industries algériennes	Générique	Peu flexible
Intégration IoT	Capteurs compatibles avec les infrastructures existantes	Limité	Hautement standardisé

3.1.3. Stratégie pour surpasser la soncurrence

- Avantage Clé :
  - Combinaison IA + Expertise Locale.
  - Modèles entraînés sur des données locales (conditions climatiques, types de pompes utilisées en Algérie).
  - Collaboration avec Sonatrach/ADE pour des cas d'usage concrets.

- Stratégies :
  - Prix : Offre hybride (abonnement mensuel + coût par pompe surveillée).
  - Marketing : Mise en avant des économies réalisables (ROI calculé pour les clients).
  - Partenariats : Collaboration avec les universités algériennes pour R&D.

3.1.4. Barrières à l'entrée

- Technologiques :
  - Nécessité d'accès à des données historiques de pannes (partenariat avec les industriels).

- Réglementaires :
  - Certification des systèmes IoT/IA par les autorités algériennes (ex : ARP).
- Financières :
  - Investissement initial en hardware (capteurs) et cloud computing.

3.1.5. Indicateurs clés de suivi

- Part de Marché : Nombre de pompes surveillées dans les 2 premières années.
- Feedback Clients : Taux de réduction des pannes imprévues.
- Avance Technologique : Publications/brevets déposés sur les modèles d'IA.

3.1.6. Exemple de tableau synthétique

Facteur Concurrentiel	PumpGuard AI	Concurrent Principal	Commentaire
Coût Total pour le Client	1.2M DZD/an	3M DZD/an	Économie de 60%
Précision des Prédictions	95%	88%	Meilleure optimisation
Temps de Déploiement	2 semaines	6 semaines	Rapidité d'installation

3.1.7. Points clés à mettre en avant :

- Notre solution est plus précise que les startups locales (grâce à notre Précision) et plus accessible que Siemens.
- Argument choc : "Réduisez les pannes de 70% pour 30% du coût des solutions internationales".

3.1.8. Stratégies pour dominer le marché

A. Différenciation

- Fonction unique :

"Notre système prédit aussi les pannes électriques (moteurs) grâce à l'analyse harmonique, absente chez les concurrents."

B. Le Coût

- Modèle économique :
  - Location : 10 000 DZD/mois/pompe (au lieu de l'achat à 500 000 DZD).
  - Forfait pour les petites usines (<10 pompes).

C. Collaboration

- Partenariat gagnant-gagnant :

"Formez vos techniciens gratuitement à notre outil, et payez seulement si les prédictions réduisent vos pannes de 40%."

Exemple de Pitch

"Contrairement à Siemens, PumpGuard est conçu par et pour les industriels algériens :

- 30% moins cher car développé à Médéa, pas à Munich.
- Précision de 95% grâce à l'entraînement sur des données locales.
- Pas besoin de changer vos pompes : nos capteurs s'adaptent à l'existant."

Quatriemme axe
Plan d'Organisation
Et de Production



Quatriemme axe :

Plan d'Organisation et de Production

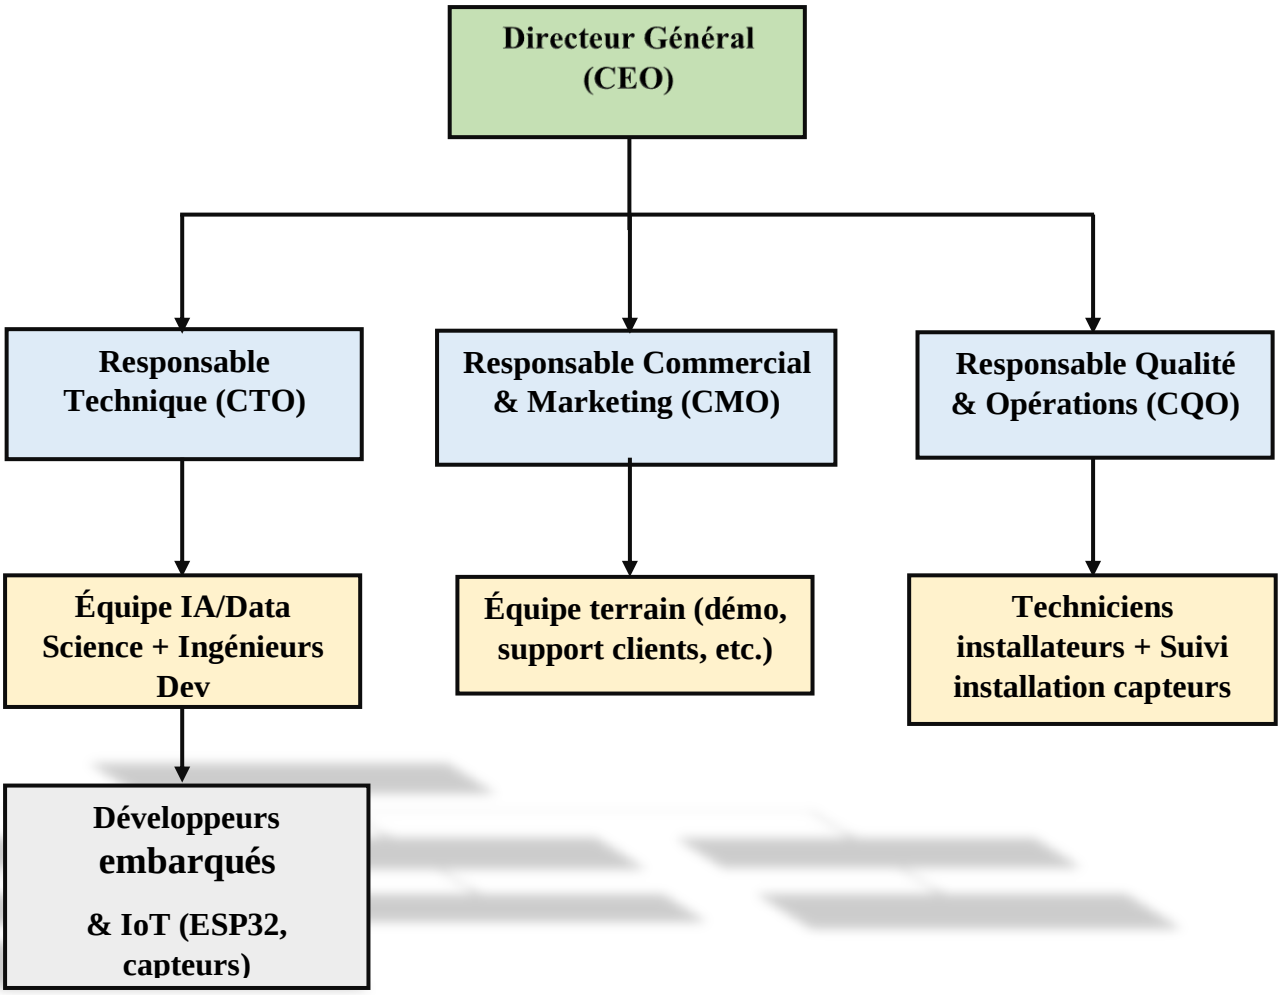
5. Plan d'Organisation et de Production

5.1. Structure Organisationnelle

A. Forme Juridique

- Type : SARL (Société à Responsabilité Limitée), adaptée pour les startups à plusieurs associés.
- Localisation du siège : Médéa, zone industrielle ou technoparc si disponible.
- Capital de départ estimé : 2 à 4 millions DZD (peut être modulé selon les aides publiques, incubateurs, ou fonds de soutien à l'innovation).

B. Organigramme Fonctionnel



5.2. Processus de Production (chaîne de valeur)

PumpGuard AI proposé un système hybride matériel + logiciel. Voici le workflow technique:

A. Phase 1 – Acquisition et transmission des données

Étape	Description
Capteurs	Capteurs de vibration (accéléromètres piezo), capteurs de courant, température
Microcontrôleur	ESP32 collecte les données.
Transmission	Envoi via Wi-Fi ou Réseaux cellulaires, ou autre système sans fils sécurisé vers une plateforme cloud sécurisée

B. Phase 2 – Traitement et analyse des données

Étape	Outils/Technos	Objectif
Prétraitement	Filtrage, normalisation	Nettoyage des signaux
Analyse vibratoire	DWT (Discrete Wavelet Transform)	Extraction de features (bandes d'énergie)
Intelligence Artificielle	Modèles : DNN, Random Forest, XGBoost	Prédiction de défauts

C. Phase 3 – Restitution & Actions

Sortie	Format	Utilisation client
Interface Web (Dashboard)	Python/Streamlit ou React	Visualisation des alertes, état des pompes
Écran LCD local	16x2 ou OLED ou HMI	Indication rapide sur site
Alertes automatisées	Email/SMS	Notifications en cas de défaillance

5.3.Ressources Matérielles & Logistiques

Ressource	Rôle	Coût estimé (par unité ou initial)
ESP32	Module principal IoT	4000 DZD
Capteur vibration (piezo) industriel	Détection des défauts mécaniques	40000 – 80000 DZD
Serveur cloud (AWS ou local)	Hébergement de la plateforme IA	6000 – 10000 DZD/mois
PC industriel (optionnel)	En cas de déploiement offline	120 000 –200 000 DZD

5.4.Plan de Déploiement & Lancement (année 1)

Mois	Objectif principal	Actions
M1	Finalisation prototype	Test de transmission, IA, boîtier
M2-M3	Déploiement pilote (2 à 3 sites)	ADE ou entreprise agroalimentaire locale
M4-M5	Recueil feedback & ajustement technique	Ajout interface utilisateur, documentation simplifiée
M6	Début du modèle freemium	1 pompe gratuite / 3 mois
M7-M9	Prospection commerciale active	Appels téléphoniques, salons professionnels
M10-M12	Premiers abonnements & industrialisation légère	Formation clients, création de kits standards

5.5.Évolution à Moyen Terme (année 2 et +)

- Automatisation complète de la chaîne IA (intégration avec bases de données clients)
- Plateforme web professionnelle multi-sites
- Application mobile client (suivi et alertes)
- Partenariat technique pour production en série locale (via un sous-traitant électronique en Algérie)
- Conformité ISO 9001 et/ou certification ATEX (si secteurs pétroliers)

Cinquième axe

Plan Financier



Cinquième axe :

Plan Financier

6. Plan Financier

6.1. Hypothèses de base

- **Tarif moyen** par pompe surveillée : 10 000 DZD par mois.
- **Objectif initial** : 10 clients pilotes, chacun avec 5 pompes.

  - Principaux postes de coût :
  - Achat de capteurs et microcontrôleurs (comme l'ESP32),
  - Hébergement cloud et infrastructure pour les modèles d'intelligence artificielle,
  - Salaires des ingénieurs, développeurs et commerciaux,
  - Budget marketing (salons, communication, démonstrations),
  - Développement logiciel (application web/mobile, interfaces IA).

6.2. Prévisions de revenus (sur 3 ans)

Année	Nombre de clients	Pompes surveillées	Revenu mensuel (DZD)	Revenu annuel (DZD)
1re année	10	50	500 000	6 000 000
2e année	30	200	2 000 000	24 000 000
3e année	60	500	5 000 000	60 000 000

6.3. Estimation des dépenses annuelles

Poste de dépense	1re année (DZD)	2e année (DZD)	3e année (DZD)
Capteurs et matériel IoT	3 000 000	4 500 000	7 500 000
Cloud & traitement IA	1 200 000	2 400 000	3 600 000
Développement logiciel	1 500 000	1 000 000	1 000 000
Salaires (tech/commerciaux)	3 600 000	4 800 000	6 000 000
Marketing & prospection	1 000 000	1 500 000	2 000 000
Divers (logistique, tests)	500 000	500 000	700 000
Total	10 800 000	14 700 000	20 800 000

6.4. Seuil de rentabilité

- Coût moyen mensuel la 1re année : environ 900 000 DZD.
- Nombre de pompes à surveiller pour être rentable : environ 90.
- Seuil de rentabilité prévu : vers la fin de la 2e année.

6.5. Sources de financement envisagées

- Apport personnel des fondateurs,
- Programmes d'innovation (ex. : Fonds algérien des startups, ANPT),
- Co-financement industriel (partenariat avec Sonatrach, ADE ou POVAL),
- Soutien d'incubateurs ou accélérateurs technologiques,

6.6. Retour sur investissement (ROI)

- Pour les clients : réduction de 40 à 60 % des coûts liés aux arrêts imprévus.
- ROI client : généralement obtenu en 3 à 6 mois selon le nombre de pompes.
- ROI pour PumpGuard : rentabilité atteinte à partir de la 3e année.

Sixième axe

Prototype Expérimental



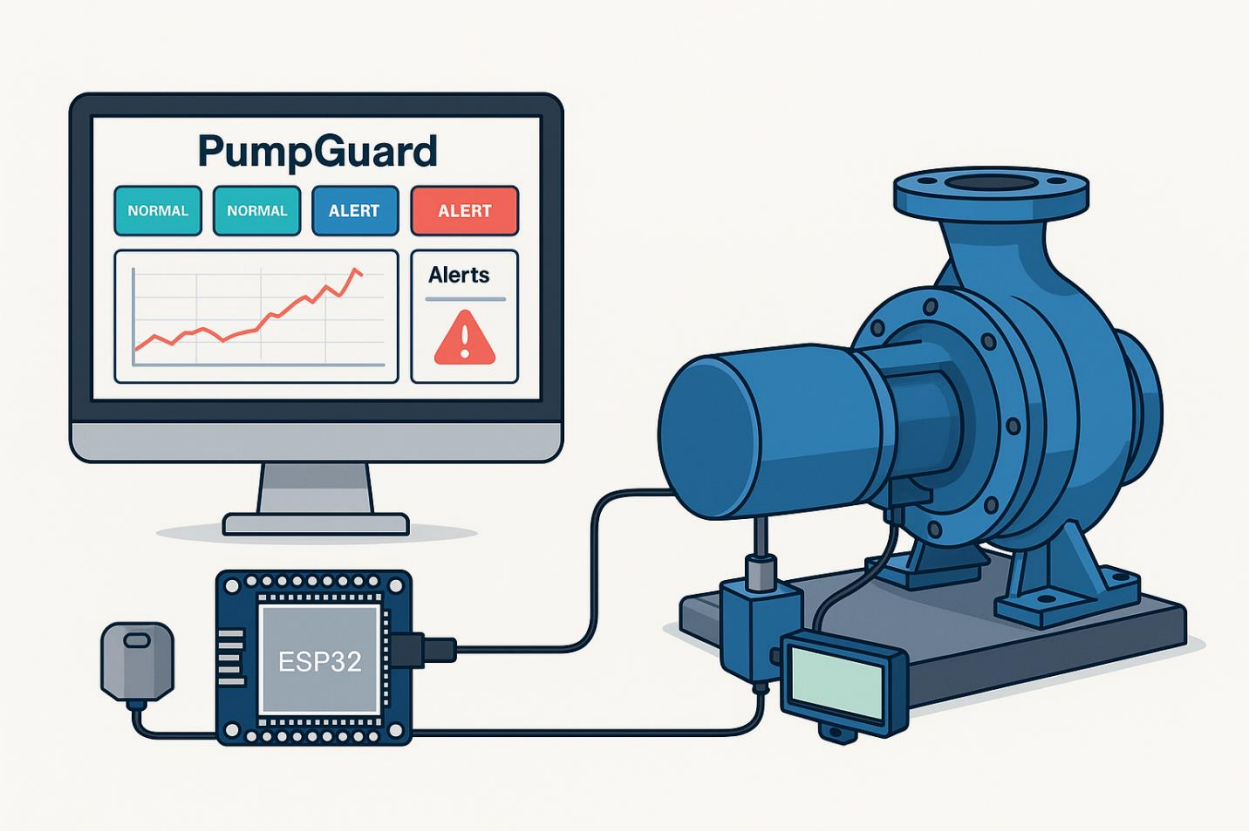


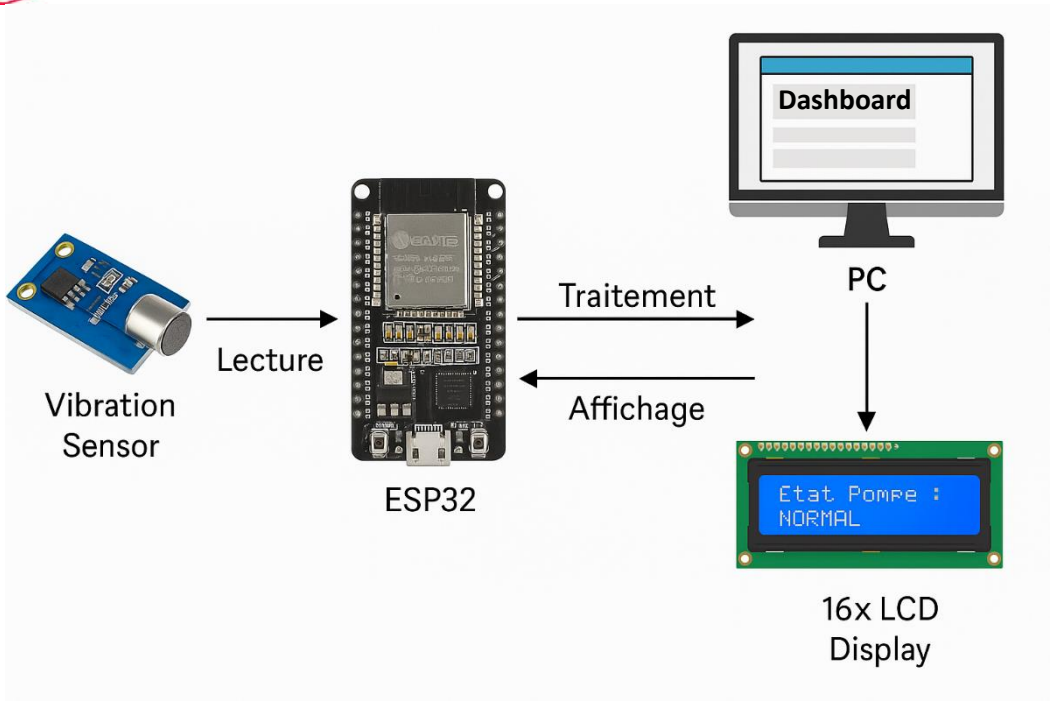
Sixième axe :

Prototype Expérimental

7. Prototype Expérimental

Une vue générale sur le système





Le fonctionnement du système

Les images suivantes représentent plusieurs prototypes en 3D générer par l'intelligence artificiel :





Liste des Annexes



Annexes

8. Annexe

Partenaires Clés	Activités Clés	Proposition de Valeur	Relation Client	Segments Clients
- POVAL. - ADE. - Sonatrach.	- Développements des modèles IA - Fabrication de cartes électroniques - Tests industriels - Formation technique des utilisateurs	- Anticipation des pannes (70% évitées) - Interface simple et modulaire - Solution locale fiable à coût réduit - Données en temps réel	- Formation gratuite - SAV technique - Notifications et rapports automatiques	- Sonatrach . - POVAL. - ADE - Grandes entreprises industrielles - Fermes et centres de dessalement
	Ressources Clés - Base de données de pannes - Équipe IA et électronique - Capteurs industriels, ESP32 - Infrastructure cloud		Canaux - Démos sur sites clients - Foires industrielles - Site web. - application mobile	
Structure de Coûts - Achat composants IoT - Dépenses cloud/IA - Marketing, développement logiciel - Salaires, logistique		Flux de revenus - Abonnement mensuel/pompe - Kits standards à l'achat - Contrats d'accompagnement/maintenance		