

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Ibn Khaldoun de Tiaret
Faculté des Sciences Appliquées
Département de Génie Mécanique



MÉMOIRE DE FIN D'ETUDES

Pour l'obtention du diplôme de Master

Domaine : Sciences et Technologie
Filière : Electromécanique
Parcours : Master
Spécialité : Maintenance Industrielle

Thème

Prédiction des pannes d'un système
mécanique par apprentissage automatique

Préparés par :

MAACHI Hadil
ZOURAGH Anis

Soutenu publiquement le : 20 / 06 / 2024, devant le jury composé de :

| | | |
|-----------------------|--|--------------|
| M. GUEMMOUR Mohamed.B | Maître de Conférences "B" (Univ. Ibn Khaldoun) | Président |
| M. MAKHFI Souad | Maître de Conférences "A" (Univ. Ibn Khaldoun) | Examineur |
| M. ABOSHIGHIBA Hicham | Maître de Conférences "B" (Univ. Ibn Khaldoun) | Examineur |
| M. SAAD Mohamed | Maître de Conférences "A" (Univ. Ibn Khaldoun) | Encadrant |
| M. MEKROUSSI Said | Professeur | Co-Encadrant |

Année universitaire : 2023 - 2024

REMERCIEMENTS

Nous tenons tout d'abord à exprimer notre profonde gratitude à ALLAH, dont l'aide et la bienveillance nous ont permis de mener à bien ce modeste travail avec succès. Sa insufflé la patience et le courage nécessaires tout au long de ce parcours.

Nos sincères remerciements vont également à nos familles respectives. Leur soutien indéfectible, leur compréhension sans faille et leurs encouragements constants ont été essentiels pour surmonter les défis rencontrés.

*Nous tenons à exprimer notre gratitude à notre encadrant, **M. SAAD Mohamed**, Maître de conférences « A » à l'Université Ibn Khaldoun de Tiaret et à notre co-encadrant, **M. MAKROSSI Saïd**, Professeur à l'Université Ibn Khaldoun de Tiaret, pour leur soutien, leurs conseils avisés et leur encadrement. nous sommes profondément reconnaissants .*

*Nos remerciements chaleureux s'adressent également aux professeurs du département d'informatique : **M. MOSTEFAOUI Sid Ahmed Mokhtar**, Maître de conférences « A » à l'Université Ibn Khaldoun de Tiaret , **M. MEGHAZI Hadj Madani**, conférences « B » à l'Université Ibn Khaldoun de Tiaret et **M. MEBAREK Bendaoued**, Professeur à l'Université Ibn Khaldoun de Tiaret, Leur enseignement de qualité, leur disponibilité et leurs précieux conseils nous ont fourni les bases solides nécessaires à cette nouvelle spécialité. Leur dévouement et leur engagement envers notre formation ont été des piliers essentiels à l'aboutissement de ce projet.*

*Nous remercions les membres du jury, **M. GUEMMOUR Mohamed Boutkhal**, maître de conférences « B » à l'université Ibn Khaldoun de Tiaret qui a accepté de présider ce jury, **M. ABOSHIGHIBA Hicham**, maître de conférences « B » à l'université Ibn Khaldoun de Tiaret, Madame **MAKFI Souad**, maître de conférences « A » à l'université Ibn Khaldoun de Tiaret, qui ont bien voulu examiner notre travail et participer au jury.*

À tous, nous exprimons notre profonde reconnaissance pour l'aide et le soutien apportés, ayant permis de faire de ce mémoire une réussite

DEDICACE

Je tiens tout d'abord à dédier ce travail à mes chers parents, véritables piliers de mon parcours, dont le soutien inconditionnel et les prières ont été une source constante d'inspiration et d'encouragement.

Leur amour et leur dévouement ont été le moteur de mes réussites, et je ne saurais jamais assez les remercier pour tout ce qu'ils ont fait pour moi.

À ma chère tante, dont la présence bienveillante et le soutien indéfectible ont été des sources de réconfort et de motivation tout au long de mon parcours académique, je suis profondément reconnaissant.

Enfin, je souhaite exprimer ma gratitude envers ma famille élargie et mes amis, qui ont contribué de près ou de loin à mon épanouissement.

MAACHI Hadil

DEDICACE

Je dédie ce travail

À mes chers parents, véritables piliers de mon parcours, dont le soutien et les prières ont été une source constante d'inspiration et d'encouragement. Je prie Dieu de les bénir.

À mes très chers frères.

À mes encadreurs et à tous les enseignants du département de génie mécanique et du département d'informatique.

À tous mes amis qui m'ont toujours encouragé.

À tous ceux qui m'ont aidé durant mes années d'étude.

ZOURAGH Anis

TABLE DES MATIÈRES

| | |
|---|------|
| REMERCIEMENTS | I |
| DEDICACE | II |
| DEDICACE | III |
| LISTE DES FIGURES | VII |
| LISTE DES TABLEAUX | VIII |
| LISTE DES ABRÉVIATIONS | IX |
| INTRODUCTION GENERALE | 1 |
| CHAPITRE I : MAINTENANCE PREDICTIVE DANS L'INDUSTRIE 4.0 | |
| I.1 INTRODUCTION | 5 |
| I.2 L'INDUSTRIE 4.0 | 5 |
| I.2.1 INTERNET DES OBJETS (IOT) | 7 |
| I.2.2 L'INTELLIGENCE ARTIFICIELLE | 8 |
| I.2.3 CYBER PHYSIQUE | 9 |
| I.2.4 BIG DATA | 10 |
| I.2.5 LE CLOUD COMPUTING | 11 |
| I.2.6 TECHNOLOGIES DE SIMULATION | 11 |
| I.2.7 REALITE AUGMENTEE/REALITE VIRTUELLE | 12 |
| I.2.8 ROBOTIQUE | 12 |
| I.2.9 FABRICATION ADDITIVE | 13 |
| I.3 ENJEUX DE DE LA MAINTENANCE PREDICTIVE DANS L'INDUSTRIE 4 .0 .. | 13 |
| I.4 DEVELOPPEMENT DE LA MAINTENANCE | 14 |
| I.5 LA MAINTENANCE PRÉDICTIVE (PRÉVISIONNELLE) | 16 |
| I.5.1 DEFINITION | 16 |
| I.5.2 LES APPROCHES DE LA MAINTENANCE PREDICTIVE | 16 |
| I.5.2.1 LES APPROCHES FONDEES SUR LES CONNAISSANCES ET LES EXPERIENCES | 17 |
| I.5.2.2 LES APPROCHES BASEES SUR DES MODELES PHYSIQUES | 17 |
| I.5.2.3 LES APPROCHES BASEES SUR LES DONNEES | 17 |
| I.5.3 LES TECHNIQUES DE LA SURVEILLANCE POUR LA MAINTENANCE PREDICTIVE | 20 |
| I.5.3.1 ANALYSE VIBRATOIRE | 20 |
| I.5.3.2 ANALYSE ACOUSTIQUE | 20 |
| I.5.3.3 ANALYSE THERMOGRAPHIE INFRAROUGE | 21 |
| I.5.3.4 ANALYSE DES HUILES | 21 |
| I.6 LA MAINTENANCE PREDICTIVE ET L'INTELLIGENCE ARTIFICIEL | 22 |

| | | |
|--|---|----|
| I.7 | CONCLUSION | 23 |
| CHAPITRE II : MODELISATION PAR APPRENTISSAGE AUTOMATIQUE | | |
| II.1 | INTRODUCTION | 25 |
| II.2 | L'INTELLIGENCE ARTIFICIELLE | 25 |
| II.3 | APPRENTISSAGE AUTOMATIQUE (ML) | 26 |
| II.3.1 | DEFINITION | 26 |
| II.3.2 | TYPES APPRENTISSAGE AUTOMATIQUE | 27 |
| II.3.2.1 | APPRENTISSAGE SUPERVISE | 28 |
| II.3.2.2 | APPRENTISSAGE NON SUPERVISE | 30 |
| II.3.2.3 | APPRENTISSAGE PAR RENFORCEMENT | 31 |
| II.4 | APPRENTISSAGE PROFOND (DEEP LEARNING) | 32 |
| II.5 | LES ALGORITHMES D'APPRENTISSAGE SUPERVISE | 33 |
| II.5.1 | L'ARBRE DECISION (DECISION TREE) | 33 |
| II.5.2 | LES k-PLUS PROCHES VOISINS (K-NN) | 34 |
| II.5.3 | MACHINES A VECTEURS SUPPORTS (SVM) | 36 |
| II.5.3.1 | NOTION DE BASE | 36 |
| II.5.3.2 | PRINCIPES FONDAMENTAUX | 38 |
| II.5.3.3 | TRANSFORMATION A UN ESPACE A HAUTE DIMENSION | 40 |
| II.5.4 | RESEAUX NEURONES | 41 |
| II.5.4.1 | L'ORIGINE DE RESEAUX DE NEURONES | 41 |
| II.5.4.2 | DEFINITION DE RESEAUX NEURONES ARTIFICIEL (RNA) | 42 |
| II.5.4.3 | MODÉLISATION GÉNÉRALE | 43 |
| II.5.4.4 | LE PERCEPTRON | 45 |
| II.5.4.5 | L'ARCHITECTURE DE RESEAUX DE NEURONES | 46 |
| II.6 | CONCLUSION | 48 |
| CHAPITRE III : ETUDE DE CAS | | |
| III.1 | INTRODUCTION | 50 |
| III.2 | SYSTEME TECHNIQUE ETUDIE | 50 |
| III.3 | LES OUTILS DE DÉVELOPPEMENT | 51 |
| III.3.1 | ANACONDA | 51 |
| III.3.2 | PYTHON | 51 |
| III.3.3 | JUPYTER | 51 |
| III.4 | LES MEUSURES DE PERFORMANCES | 52 |
| III.5 | PARTIE EXPRIMENTALE | 53 |
| III.5.1 | DESCRIPTION DE LA BASE DONNEES | 53 |
| III.5.2 | PRETRAITEMENT DES DONNEES | 55 |

| | | |
|-----------|--|----|
| III.5.3 | CREATION DU MODELE | 57 |
| III.5.3.1 | MODELE MACHINE A VECTEURS DE SUPPORT (SVM) | 57 |
| III.5.3.2 | MODELE RESEAU NEURONES (ANN) | 59 |
| III.5.4 | EVALUATION DES MODELES | 61 |
| III.5.5 | VALIDATION DU MODELES | 62 |
| III.5.6 | MISE EN ŒUVRE | 63 |
| III.6 | CONCLUSION | 67 |
| | CONCLUSION GENERALE | 68 |
| | BIBLIOGRAPHIE | |
| | RESUME | |

LISTE DES FIGURES

| | |
|--|----|
| Figure I.1 : La révolution industrielle | 6 |
| Figure I.2 : Les technologies clés de l'industrie 4.0..... | 7 |
| Figure I.3 : Internet des Objets (IoT)..... | 8 |
| Figure I.4 : Schématisation simplifiée d'un système cyber-physique industriel | 10 |
| Figure I.5 : La théorie des 3V | 11 |
| Figure I.6 : L'évolution de la maintenance..... | 15 |
| Figure I.7 : Les étapes de création d'un modèle de prédiction | 19 |
| Figure II.1 : Schéma de décomposition du domaine de l'intelligence artificielle | 26 |
| Figure II.2 : Définir les composants d'un algorithme d'apprentissage..... | 27 |
| Figure II.3 : Les types d'apprentissage automatique | 28 |
| Figure II.4 : Illustration de l'apprentissage supervisé | 29 |
| Figure II.5 : Illustration de l'apprentissage non supervisé..... | 30 |
| Figure II.6 : Schéma descriptive de l'apprentissage par renforcement..... | 32 |
| Figure II.7 : Exemple d'illustration d'un arbre de décision..... | 34 |
| Figure II.8 : Principe de l'algorithme KNN..... | 35 |
| Figure II.9 : Hyperplan séparant deux classes | 37 |
| Figure II.10 : Les vecteurs de support | 37 |
| Figure II.11 : La marge | 38 |
| Figure II.12 : a) Hyperplan avec faible marge, b) Meilleur hyperplan séparateur..... | 38 |
| Figure II.13 : Séparation non linéaire dans l'espace..... | 39 |
| Figure II.14 : Transformation de l'espace en utilisant un noyau (cas RBF)..... | 41 |
| Figure II.15 : Mise en correspondance neurone biologique / neurone artificiel..... | 42 |
| Figure II.16 : La géométrie du neurone artificiel..... | 44 |
| Figure II.17 : Le réseau monocouche | 46 |
| Figure II.18 : Schéma d'un réseau de neurones non bouclé (Perceptron multicouches) | 47 |
| Figure II.19 : Architecture d'un réseau de neurones bouclé(récurrents) | 48 |
| Figure III.1 : Fraiseuse verticale 380 V EMILGH-632 | 50 |
| Figure III.2 : Les étapes de prétraitement des données | 55 |
| Figure III.3 : Nombre d'instances par classe avant et après utilisation de la technique Smote ... | 56 |
| Figure III.4 : Construction du modèle | 57 |
| Figure III.5 : Matrice de confusion pour le classificateur SVM..... | 58 |
| Figure III.6 : Matrice de confusion pour le classificateur ANN..... | 60 |
| Figure III.7 : Interface de l'application de prédiction des défaillances de la fraiseuse..... | 65 |

LISTE DES TABLEAUX

| | |
|--|----|
| Tableau II.1 : Mise en correspondance neurone biologique / neurone artificiel | 42 |
| Tableau II.2 : Différentes fonctions d'activations utilisées dans les RNA..... | 45 |
| Tableau III.1 : Échantillon de données de la base sur la fraiseuse verticale | 54 |
| Tableau III.2 : Codage des données..... | 56 |
| Tableau III.3 : Performance de classification par classe pour le modèle SVM | 59 |
| Tableau III.4 : Mesures des performances du modèle SVM | 59 |
| Tableau III.5 : Performance de classification par classe pour le modèle ANN | 61 |
| Tableau III.6 : Mesures des performances du modèle ANN | 61 |
| Tableau III.7 : Tableau comparatif entre les deux modèles | 62 |
| Tableau III.8 : Les scores de validation croisée pour les modèles ANN et SVM | 63 |
| Tableau III.9 : Résultats de test | 65 |

LISTE DES ABRÉVIATIONS

IoT/IIoT : Internet Of Things/ Industrial Internet Of Things

IDO : Internet Des Objets

RFID : Radio-Frequency Identification

IA : Intelligence Artificiel

CPS : Cyber-Physical Systems

AR : Augmented Reality / La Réalité Augmentée

VR : Virtual Reality/ Réalité Virtuelle

PME : Petites et Moyennes Entreprises

PMI : Petites et Moyennes Industries

AMR : Autonomous Mobile Robots

RUL : Remaining Useful Life

PHM: Prognostics and Health Management

ML: Machine Learning

KNN : K Nearst Neighbors

SVM : Support Vector Machines

RBF : Radial Basis Function

ANN : Artificial Neural Network

MAC : Multiplication and Accumulation

SLP: Single-Layer Perceptron

PMC : Le Perceptron Multicouches

SMOTE : Synthetic Minority Over-sampling Technique

MLP : Multilayer Perceptron

INTRODUCTION
GENERALE

Notre travail s'inscrit dans le contexte de l'industrie manufacturière moderne, qui se transforme actuellement avec l'avènement de l'Industrie 4.0. Ce concept repose sur l'intégration de technologies avancées telles que l'Internet des objets (IoT), l'intelligence artificielle (IA), et le big data pour créer des usines intelligentes et interconnectées. Au sein d'une entreprise industrielle, cette transformation vise à améliorer l'efficacité, la productivité et la flexibilité des systèmes de production, lesquels sont fondés sur des équipements industriels critiques devant posséder une disponibilité élevée, assurée par la fonction maintenance.

Traditionnellement, les actions de maintenance des équipements industriels étaient réactives, c'est-à-dire qu'elles n'avaient lieu qu'après l'apparition d'une panne. Cette approche entraîne souvent des arrêts de production coûteux et des pertes de productivité. La maintenance préventive systématique, bien qu'étant une amélioration par rapport à la maintenance réactive, repose sur des calendriers fixes et ne prend pas toujours en compte l'état réel des équipements. La maintenance préventive conditionnelle, quant à elle, repose sur la détection d'une défaillance fonctionnelle révélatrice de l'état de dégradation de l'équipement à travers un rapport d'analyse. Avec l'avènement de l'Industrie 4.0, la maintenance prédictive est apparue comme une nouvelle approche.

Notre travail se concentre sur la maintenance prédictive, qui utilise les données collectées en temps réel par des capteurs intelligents implantés sur les équipements critiques, combinées à des techniques d'intelligence artificielle et d'apprentissage automatique pour anticiper les défaillances avant qu'elles ne surviennent. Cette approche permet non seulement de réduire les temps d'arrêt et les coûts de maintenance, mais aussi d'améliorer la durée de vie et la fiabilité des équipements. Ce mémoire explore en particulier le rôle de l'apprentissage automatique dans la mise en œuvre de la maintenance prédictive, en examinant ses enjeux et opportunités à travers des études de cas et des analyses quantitatives, démontrant comment cette approche révolutionne la maintenance industrielle.

L'objectif de ce mémoire est d'intégrer les techniques d'apprentissage automatique à la maintenance industrielle pour obtenir une approche prédictive, s'appuyant sur les technologies de l'Industrie 4.0 telles que l'intelligence artificielle et le big data. Pour atteindre cet objectif, cette recherche comporte plusieurs sous-objectifs tels que l'identification et l'analyse des technologies pertinentes de l'Industrie 4.0, en mettant en lumière leur potentiel pour améliorer la maintenance prédictive; évaluer les différentes techniques d'apprentissage automatique, notamment les algorithmes tels que les réseaux neuronaux et les machines à vecteurs de support (SVM); développer et tester des modèles prédictifs sur un cas pratique, en utilisant les données collectées sur une fraiseuse verticale, un équipement crucial dans l'industrie manufacturière; optimiser les

stratégies de maintenance à partir des résultats des modèles prédictifs pour minimiser les arrêts de production et maximiser la productivité et la fiabilité des équipements.

La problématique de ce mémoire est de déterminer comment les techniques d'apprentissage automatique peuvent être utilisées pour anticiper les défaillances des équipements industriels et optimiser la maintenance prédictive. L'étude se focalise sur l'application de ces techniques à un cas pratique, la fraiseuse verticale, un équipement critique dans l'industrie manufacturière. Le défi réside dans la collecte et l'analyse des données opérationnelles en temps réel et la création de modèles prédictifs efficaces.

Pour répondre à la problématique et atteindre les objectifs fixés, une méthodologie rigoureuse et structurée est adoptée. Elle comprend plusieurs étapes clés : une revue de la littérature sur les concepts de l'Industrie 4.0 et de la maintenance prédictive, ainsi que l'analyse des technologies comme l'IoT, l'IA et le big data appliquées à la maintenance industrielle. Ensuite, la modélisation par l'apprentissage automatique explore divers algorithmes pour prédire les défaillances. La collecte et la préparation des données impliquent l'importation, le nettoyage, la normalisation et le prétraitement des données de fonctionnement de la fraiseuse verticale. La création des modèles prédictifs inclut la sélection d'algorithmes pertinents (réseaux neuronaux et machines à vecteurs de support), leur entraînement et test, ainsi que l'interprétation des résultats. L'évaluation et la validation des modèles utilisent des mesures de performance comme la précision, le rappel et le F1-score. Enfin, La mise en œuvre et le test de l'application comprennent le développement d'une application avec une interface utilisateur intuitive pour prédire les défaillances des fraiseuses verticales, l'intégration du modèle prédictif dans l'application, permettant la saisie de données et la visualisation des résultats, la réalisation de tests pour vérifier la performance et la fiabilité de l'application, et l'analyse des résultats des tests.

Le mémoire est structuré en trois chapitres principaux. Le premier chapitre introduit les concepts de l'Industrie 4.0 et de la maintenance prédictive. Il couvre les technologies essentielles telles que l'IoT, l'IA, et le big data, et décrit comment elles peuvent transformer la maintenance industrielle en passant d'une approche réactive à une approche prédictive. Le second chapitre se concentre sur les différentes méthodes et algorithmes d'apprentissage automatique appliqués à la maintenance industrielle. Il décrit les types d'apprentissage automatique et explore les algorithmes comme les réseaux neuronaux et les machines à vecteurs de support (SVM). Le dernier chapitre présente une application pratique des techniques étudiées sur une fraiseuse verticale. Il détaille le processus de collecte de données, la création de modèles prédictifs, et l'évaluation des performances des modèles, ainsi que leur validation et mise en œuvre pour améliorer la fiabilité et la disponibilité de l'équipement.

CHAPITRE I
MAINTENANCE PREDICTIVE DANS
L'INDUSTRIE 4.0

I.1 INTRODUCTION

L'évolution rapide de la technologie et de la connectivité a donné naissance à une ère nouvelle dans le monde industriel, souvent désignée sous le terme d'Industrie 4.0. Au cœur de cette révolution se trouve la nécessité de repenser fondamentalement la manière dont nous abordons la maintenance industrielle. Traditionnellement perçue comme une fonction réactive, la maintenance évolue désormais vers une approche prédictive, tirant parti des avancées de l'Industrie 4.0 pour anticiper les défaillances des équipements.

Ce chapitre expose les fondements de la maintenance prédictive, dont l'objectif est d'anticiper le moment où une défaillance surviendra afin de mettre en œuvre des mesures appropriées pour la prévenir. Il propose une analyse des concepts inhérents à l'Industrie 4.0, également désignée sous l'appellation d'"industrie du futur", qui émerge dans le cadre de la transformation numérique des entreprises.

I.2 L'INDUSTRIE 4.0

Le terme "Industrie 4.0", abrégé en I4.0 ou simplement I4, est né en 2011 d'un projet dans la stratégie high-tech du gouvernement allemand, qui favorise l'informatisation de la fabrication. Le terme "Industrie 4.0" a été introduit publiquement la même année au salon de Hanovre.[1]

Industrie 4.0 signifie la quatrième révolution industrielle. Cette étape du processus d'industrialisation est tout comme les trois étapes précédentes, dominée par les innovations techniques,[2] peut être définie comme l'intégration de technologies numériques intelligentes dans les processus de production et industriels. Il couvre une gamme de technologies telles que les réseaux IoT industriels, l'intelligence artificielle, le big data, la robotique et l'automatisation. L'Industrie 4.0 permet la création d'une production intelligente et d'usines intelligentes. Il est conçu pour augmenter la productivité, l'efficacité et la flexibilité tout en permettant une prise de décision et une personnalisation plus intelligente des opérations de production.

Précédemment, trois transformations modernes ont eu lieu : La première révolution industrielle a été initiée dans les années 1780 par l'émergence des premières usines de production mécanisées, largement rendue possible grâce à l'invention de la machine à vapeur. La deuxième révolution industrielle a débuté en 1870 avec la découverte de l'électricité et l'essor de la production de masse qui en a découlé. Dans les années 1970, avec l'avènement de la technologie électronique et le commencement de l'automatisation et de l'informatique industrielle, la troisième révolution industrielle a marqué le début de l'ère de la production automatisée (figure I.1).

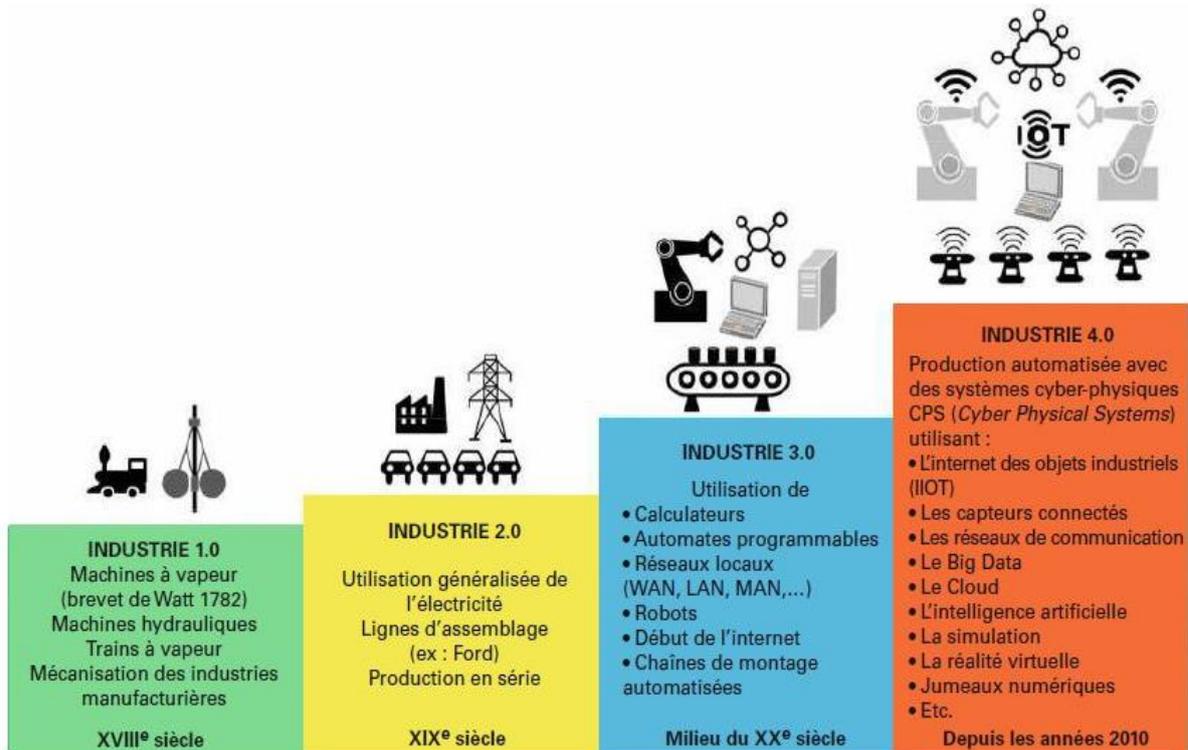


Figure I.1 : La révolution industrielle [3]

L'avènement de l'industrie 4.0 est intimement lié à l'introduction de nouvelles technologies qui offrent un éventail de possibilités inédites dans le domaine de la production. Ces nouveaux instruments sont à la base du changement de paradigme annoncé par cette quatrième révolution industrielle.

Ces dernières années ont été marquées par une prolifération de recherches scientifiques portant sur les nouvelles technologies et leur impact potentiel sur l'écosystème industriel. En effet, le nombre de publications traitant de l'industrie 4.0 a connu une croissance exponentielle.

Grâce à une recherche documentaire, nous avons identifié les technologies clés associées à l'Industrie 4.0, comme illustré dans la figure I.2.

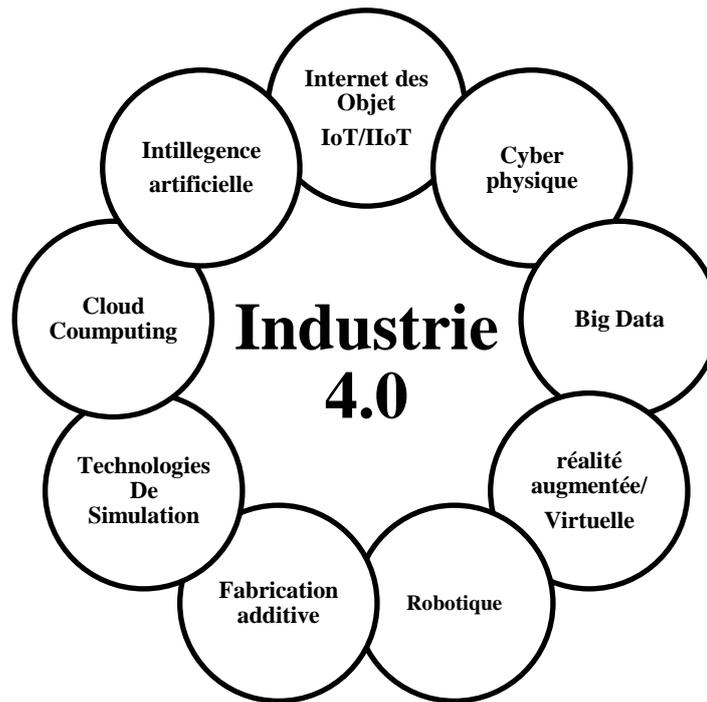


Figure I.2 : Les technologies clés de l'industrie 4.0

I.2.1 INTERNET DES OBJETS (IOT)

L'IoT a été introduit pour la première fois en 1999 par un membre de l'association professionnelle d'identification par radiofréquence (RFID). Ensuite, il a commencé à attirer l'attention sur les applications du monde réel en raison de l'essor continu des appareils électroniques, des services de Cloud Computing et de l'analyse de données. [4]

Il n'existe pas de définition unique de l'Internet des objets qui soit acceptable par la communauté mondiale des utilisateurs. La meilleure définition de l'Internet des objets serait :

Un réseau ouvert et complet d'objets intelligents qui ont la capacité de s'autoorganiser, de partager des informations, des données et des ressources, de réagir et d'agir face à des situations et des changements dans l'environnement.[5]

Le terme "Internet des objets" (ou IDO) désigne de manière générale l'extension de la connectivité, d'internet et des possibilités des technologies informatiques à des objets, des dispositifs, des capteurs et des choses qui ne sont pas habituellement considérés comme des ordinateurs [6]. Ces "objets intelligents" nécessitent une intervention humaine minimale pour générer et échanger des données ; ils sont souvent connectés à des capacités de collecte, d'analyse et de gestion des données à distance.[7]

Chaque dispositif télécommandable est associé à une carte d'identité unique, généralement exprimée par une adresse IP. Cette empreinte numérique spécifique facilite la localisation précise du dispositif, ainsi que l'établissement d'une connexion à distance pour l'envoi d'instructions et de

commandes. En plus de son utilisation auprès du grand public, l'IoT se développe également très rapidement dans les industries notamment avec la Quatrième Révolution Industrielle (I 4.0). On parle dans ces cas d'Internet Industriel des Objets (IIoT).

L'IIoT consiste à connecter tous les actifs industriels [8], y compris les machines et les systèmes de contrôle, aux systèmes d'information et aux processus d'entreprise. Cela va provoquer la création d'une quantité massive de données, qui pourront être collectées, et ainsi alimenter des solutions analytiques ou conduire à des opérations industrielles optimales.[9]

Ainsi, l'utilisation de l'internet des objets industriels pourrait permettre une optimisation des ressources et des process techniques, mais aussi permettre aux entreprises de mieux gérer les échanges d'informations, d'améliorer la communication, d'optimiser le contrôle et la gestion des systèmes. Le monde virtuel et le monde réel se rejoignent pour que les entreprises puissent bénéficier d'une plus grande efficacité, réaliser des optimisations de process et de ressources ainsi qu'effectuer des réductions de coûts.[9]

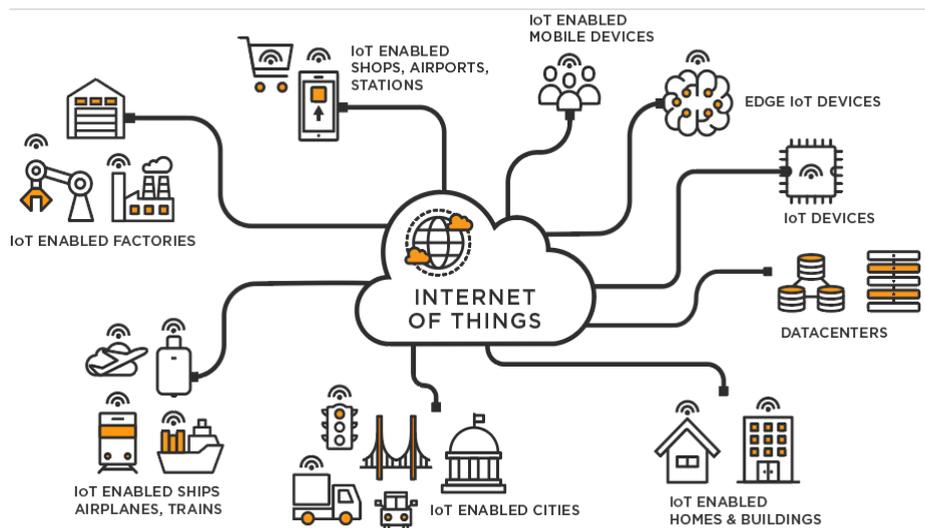


Figure I.3 : Internet des Objets (IoT) [10]

I.2.2 L'INTELLIGENCE ARTIFICIELLE

Le terme « intelligence artificielle » a été inventé lors de la conférence de Dartmouth en 1956, au surplus, on peut dire qu'il est réellement apparu avec l'avènement des premiers ordinateurs dans les années 1950.

On peut définir l'intelligence artificielle comme la programmation informatique qui donne aux machines la capacité de répondre aux compétences humaines adéquates : le raisonnement, la compréhension, la perception, l'expression et l'exécution.

L'intelligence artificielle joue un rôle très important dans l'industrie 4.0. Néanmoins, l'IA n'est pas seulement qu'un effet de mode, elle est une réalité et accompagne la transformation numérique de l'industrie.

Puisque le monde industriel actuel nécessite toujours plus d'échanges de données et d'informations à traiter, c'est donc ce qui nous pousse à exploiter toutes ces données afin d'avoir toujours un temps d'avance : analyser, prévoir, comprendre et établir des rapports en temps réel.

I.2.3 CYBER PHYSIQUE

Les systèmes industriels cyber-physiques consistent en des éléments physiques dotés de leurs systèmes de pilotage, offrant et consommant des services tout au long d'une chaîne de valeur, intégrés à des systèmes numériques disposant de moyens d'analyse et de reconfiguration en ligne de ces éléments. Ces éléments présentent divers degrés d'autonomie, se connectent et coopèrent entre eux et avec l'homme en fonction de la situation, via des systèmes d'information. [11]

Les recherches sur le CPS se sont multipliées et la compréhension du concept s'est améliorée. Aujourd'hui, le CPS est considéré comme l'un des principaux aspects de l'Industrie 4.0.

De manière générale, un CPS ou système cyber-physique correspond à un système coopérant et réactif, car il est continuellement dépendant des contraintes imposées par l'environnement physique et virtuel. Ils sont composés d'une partie électronique et logicielle, ainsi que de capteurs et d'actionneurs dotés de capacités de communication. Un CPS interagit avec son environnement dans lequel il collecte des données, les traite et, par une boucle de rétroaction, il contrôle ou influence le processus auquel il est associé.

Grâce à ses capacités de communication, un CPS peut agir en collaboration avec d'autres systèmes et/ou échanger des données avec des systèmes distants. La communication peut être soit câblée ou sans fil.

Un CPS est caractérisé par un haut degré de complexité qui est principalement dû à l'interconnexion et aux interactions dynamiques avec d'autres systèmes.

Les deux principales composantes des CPS sont les dispositifs informatiques collaboratifs et les objets physiques contrôlés par ces dispositifs informatiques. Ils facilitent la transformation systématique de données massives en informations, ce qui permet par exemple de mettre en place une maintenance préventive, d'améliorer les prises de décision et d'optimiser les processus.[9]

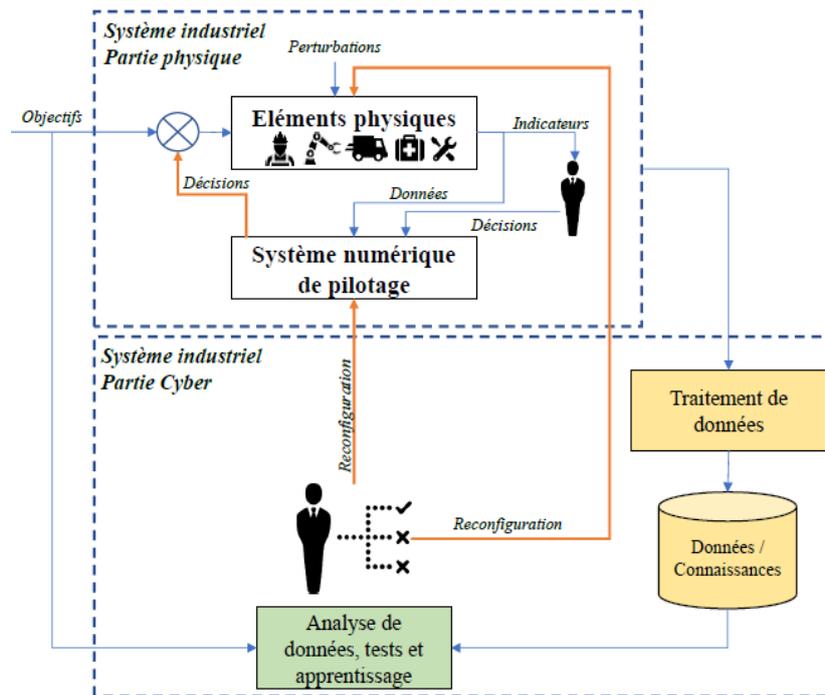


Figure I.4 : Schématisation simplifiée d'un système cyber-physique industriel [12]

I.2.4 BIG DATA

Le Big Data peut-être défini comme un vaste ensemble de données qui dépasse les capacités d'analyse des données des humains et des méthodes informatiques traditionnelles. Au cœur de l'Industrie 4.0, le Big Data est considéré comme la clé essentielle dans le traitement des grandes quantités d'informations qui composent les systèmes d'information de l'industrie.

L'expression « Big Data » fait référence aux technologies, processus et techniques permettant à une organisation de créer, manipuler et gérer des données à grande échelle [13], le concept de Big Data se définit à travers la théorie des 3V (Volume, Variété et Vitesse des données) présentée par la figure I.4. Le volume correspond à la taille des flux de données qui proviennent en continu dans une taille exponentielle allant du pétaoctet à l'exaoctet. Ces flux sont variés et émanent de sources protéiformes entre données internes à l'entreprise et données externes, données structurées (documents, images...) ou non structurées (données GPS, capteurs...) et difficilement manipulables à travers les outils classiques de traitement de données. Enfin la troisième caractéristique est la vitesse qui correspond à la rapidité de production des données. La véritable richesse d'un projet Big Data est de croiser des données hétérogènes en temps réel et d'imaginer des combinaisons et corrélations possibles. Ceci permet d'une part d'affiner la connaissance de la situation, d'autre part de délivrer des connaissances Jusque-là inaccessibles et d'en tirer profit. Ces avancées analytiques qui prennent en considération toutes les données disponibles permettent de

mieux appréhender les événements à venir à travers des modèles prédictifs. Il est désormais possible de prédire des scénarios et ajuster en conséquent les actions.[14]

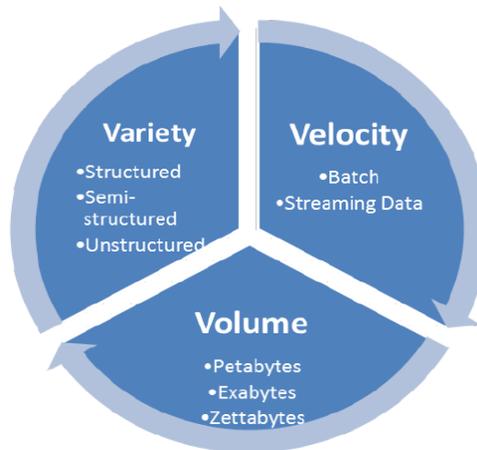


Figure I.5 : La théorie des 3V

I.2.5 LE CLOUD COMPUTING

Le Cloud computing est « un modèle d'accès à travers le réseau internet à un ensemble de ressources numériques, pouvant être allouées et libérées à la demande et pour lesquelles le fournisseur du service assure l'ensemble des activités de maintenance, de support et d'exploitation ». [15]

En technologie, le cloud computing ou « informatique en nuage » ou « infonuage » ou « Nébulique », est décrit, avec aisance par les professionnels de l'informatique en nuage, comme « un accès via un réseau de télécommunications, à la demande et en libre-service, à des ressources informatiques partagées et stockées dans des serveurs ». Il s'agit, ainsi, d'une technologie qui exploite la puissance de calcul ou de stockage de serveurs informatiques, lesquels sont distants et connectés entre eux par un réseau internet. Concrètement, cette technologie permet aux utilisateurs d'accéder à des ressources stockées dans un serveur « distant » par le biais de l'utilisation d'un terminal (un ordinateur, un téléphone portable, une tablette) et de mutualiser, ainsi, une infrastructure informatique.[16]

I.2.6 TECHNOLOGIES DE SIMULATION

À mesure que l'industrie évolue, il est désormais possible de créer des simulations numériques de processus, de produits ou de services en analysant les données collectées à différents niveaux. Ce jumeau numérique peut détecter des problèmes, tester et simuler des scénarios sans affecter le modèle physique. Cette technologie est très pratique pour les industries qui doivent régulièrement repenser l'ensemble de leur chaîne de production.

En générant des avatars numériques, les entreprises sont capables de prédire les problèmes qui pourraient survenir sur les nouvelles lignes de production (retards, problèmes de qualité, aléas, etc.).

I.2.7 REALITE AUGMENTEE/REALITE VIRTUELLE

La réalité augmentée AR et la réalité virtuelle VR sont toutes deux des technologies visuelles avancées avec différents niveaux d'immersion. Le premier est la RA, qui permet la réalité augmentée en ajoutant des informations virtuelles à la vision physique réelle. La seconde est la réalité virtuelle, qui crée une nouvelle apparence de la réalité et donne aux utilisateurs le sentiment d'y être. En AR et VR, il existe différentes catégories en fonction des critères de segmentation utilisés. Par exemple, par type de composant matériel-logiciel, type d'appareil ou support électronique. La technologie AR, la plus couramment utilisée dans les systèmes de fabrication, est considérée comme l'une des technologies piliers de l'Industrie 4.0 du point de vue de son application directe dans les environnements industriels.[17]

La technologie de réalité augmentée AR est une interaction homme-machine qui intègre la perception visuelle naturelle d'un humain avec des informations générées par ordinateur (modèles 3D, annotations de simulation et texte). Une technologie permettant la communication, la conception et la formation, ainsi qu'un environnement immersif, permettent à des experts non spécialisés de fournir une contribution précieuse. Il conduit également à la simplification des tâches de maintenance et des procédures d'assemblage visant à réduire les temps d'exploitation et les coûts de formation. Une autre fonction de la RA est la visualisation de données et d'informations en temps réel ainsi que des liens enregistrés pour la documentation et le contrôle qualité [18]. L'intégration de la RA dans les processus de fabrication lorsque cela est nécessaire constitue une valeur ajoutée, qui améliore les processus de fabrication ainsi que le produit, réduisant les coûts et les délais de production et améliorant la qualité.[17]

I.2.8 ROBOTIQUE

Parmi les axes technologiques cités autour de l'usine intelligente, qui amèneront rapidement les machines à apprendre, prédire et s'adapter à la production, on trouve la robotique collaborative. Après l'amélioration de la robotique, celle-ci est devenue un outil indispensable dans tous les domaines. Les nouveaux robots se distinguent des anciens en termes de précision et de capacité multitâche.

Au sein d'une entreprise 4.0, les cobots (contraction de "collaborative robots") ont pour objectif de soulager les travailleurs des tâches fatigantes et répétitives pouvant causer des troubles physiques. Cette pratique, appelée cobotique, consiste à utiliser de petits robots légers qui

travaillent en collaboration directe avec l'opérateur, lui permettant ainsi de se décharger des tâches les plus pénibles. Cette technologie, déjà très populaire dans les usines 4.0, augmente la productivité de l'opérateur tout en ne présentant aucun risque pour sa sécurité sur le lieu de travail. Elle ouvre également de nouvelles possibilités pour l'utilisation de robots dans les PME et PMI. Parmi les nouvelles mises à jour de l'industrie 4.0, on trouve les robots mobiles, ou AMR (Autonomous Mobile Robots), qui facilitent le déplacement des chariots et des produits, rationalisant ainsi les ressources et la chaîne de production. L'inclusion d'AMR est l'une des activités de ROBAUT Conception.

I.2.9 FABRICATION ADDITIVE

L'impression 3D ou fabrication additive comprend un ensemble de technologies et de processus permettant de produire, en se basant sur un fichier numérique, un objet physique par ajout en couches successives d'un ou plusieurs matériaux (céramiques, polymères...). Pendant longtemps, dans l'industrie, et notamment l'industrie aéronautique ou du luxe, la fabrication additive était cantonnée dans son rôle d'outil de prototypage. Mais depuis quelques années, on remarque une ouverture de l'impression 3D vers de nouvelles applications, avec une fabrication de pièces industrielles plus complexes et plus rapidement qu'auparavant.[9]

I.3 ENJEUX DE LA MAINTENANCE PREDICTIVE DANS L'INDUSTRIE 4.0

La maintenance prédictive est une porte d'entrée privilégiée dans l'industrie 4.0 pour les industriels dans le processus de production, Même si la maintenance corrective reste inévitable en raison du caractère aléatoire des défaillances, la priorité est aujourd'hui accordée à la maintenance prédictive.

Depuis plusieurs années, l'industrie a adopté une évolution de façon continue aux nouvelles technologies et techniques qui lui permettent l'automatisation et l'optimisation des procédés de fabrication et de production.

L'Industrie 4.0 englobe un ensemble d'innovations technologiques qui modernisent les équipements de production, Elle est caractérisée par une automatisation intelligente des processus mécaniques et l'utilisation de logiciels, rendue possible par la numérisation et Cette transformation inclut l'utilisation de notions telles que : le big data, le cloud computing, les capteurs connectés, l'Internet des objets, l'intelligence artificielle, et la réalité augmentée, ce qui a révolutionné dans les entreprises manufacturières les systèmes, la maintenance et les machines.

Les techniques et les technologies de l'Industrie 4.0 peuvent également apporter des changements significatifs et importants dans le domaine de la maintenance, qui joue un rôle crucial

dans le maintien de la sûreté de fonctionnement, avec une évolution significative vers la maintenance dite prédictive intelligente.

Cette approche privilégie la détection précoce des défaillances grâce à des techniques d'intelligence artificielle et à l'exploitation du big data. Bien que ce concept ne soit pas encore normalisé internationalement, il gagne en popularité dans le secteur industriel.

La mise en œuvre de la maintenance prédictive intelligente nécessite une compréhension approfondie des spécificités de l'Industrie 4.0 ainsi que des technologies et des techniques de maintenance prédictive.

Bien que cette transition puisse être lente en raison du besoin de compétences numériques spécialisées, elle est essentielle pour estimer avec précision le moment des défaillances et prendre des mesures de maintenance appropriées.

I.4 DEVELOPPEMENT DE LA MAINTENANCE

Au cours des sept dernières décennies, la pratique de la maintenance a évolué de manière significative, largement attribuable à une prise de conscience croissante de l'importance de la gestion de la maintenance.

Dans les années 1950, les stratégies de maintenance étaient principalement axées sur la maintenance corrective ou réactive en cas de défaillance ("run-to-failure"), où les machines étaient utilisées jusqu'à leur panne sans grande considération pour les temps d'arrêt. La prévention des défaillances n'était pas une priorité pour la plupart des gestionnaires, car les équipements étaient généralement plus simples et fiables, nécessitant des activités de maintenance basiques telles que le nettoyage et la lubrification.

Dans les années 1960, avec l'émergence de machines plus complexes, la nécessité de maintenir ou d'améliorer leurs performances a conduit à l'introduction de la maintenance préventive et de la maintenance basée sur le temps. Dans le but de prévenir toute défaillance potentielle, on prévoyait des remplacements réguliers de composants. Malgré tout, le temps d'utilisation d'une machine unique ne suffit pas à évaluer son état, car la détérioration est influencée par divers facteurs environnementaux et opérationnels.

Il peut arriver que la maintenance basée uniquement sur le temps entraîne des interventions inutiles perturbant les opérations.

Dans la seconde moitié des années 1980, l'introduction de systèmes de surveillance fournissant en temps réel des informations plus détaillées sur l'état actuel du système allant au-delà des seules données de panne et l'utilisation de technologies diagnostiques ont ouvert la voie à des stratégies de maintenance préventive plus efficaces. C'est de cette manière que la maintenance conditionnelle

a émergé. Ne déclenchant des actions de maintenance préventive que lorsqu'il y a des signes de détérioration ou de comportements anormaux du système, les stratégies de maintenance conditionnelle permettent d'éviter les interventions inutiles et, par conséquent, de réduire les coûts de maintenance superflus.

Au cours de la dernière décennie, la technique du pronostic, qui consiste à prédire le moment où une entité ne sera plus en mesure de remplir sa fonction requise, a été intégrée dans le processus de prise de décisions en matière de maintenance, avec l'inclusion de technologies avancées telles que des capteurs et des systèmes d'information. Grâce à cette approche, il est possible de collecter et d'analyser de manière plus efficace les données de production, en utilisant à la fois la puissance du Big Data et de l'intelligence artificielle pour prédire les pannes. C'est ce qu'on désigne sous le nom de maintenance prédictive.

La maintenance prédictive permet ainsi de réduire les coûts directs de maintenance grâce à un suivi plus précis des dégradations et à une meilleure facilité de maintenance par rapport à la maintenance conditionnelle. De plus, elle permet d'augmenter la disponibilité du système grâce à des interventions anticipées, de réduire les temps d'arrêt, d'optimiser les conditions d'approvisionnement en pièces de rechange (achat juste à temps).

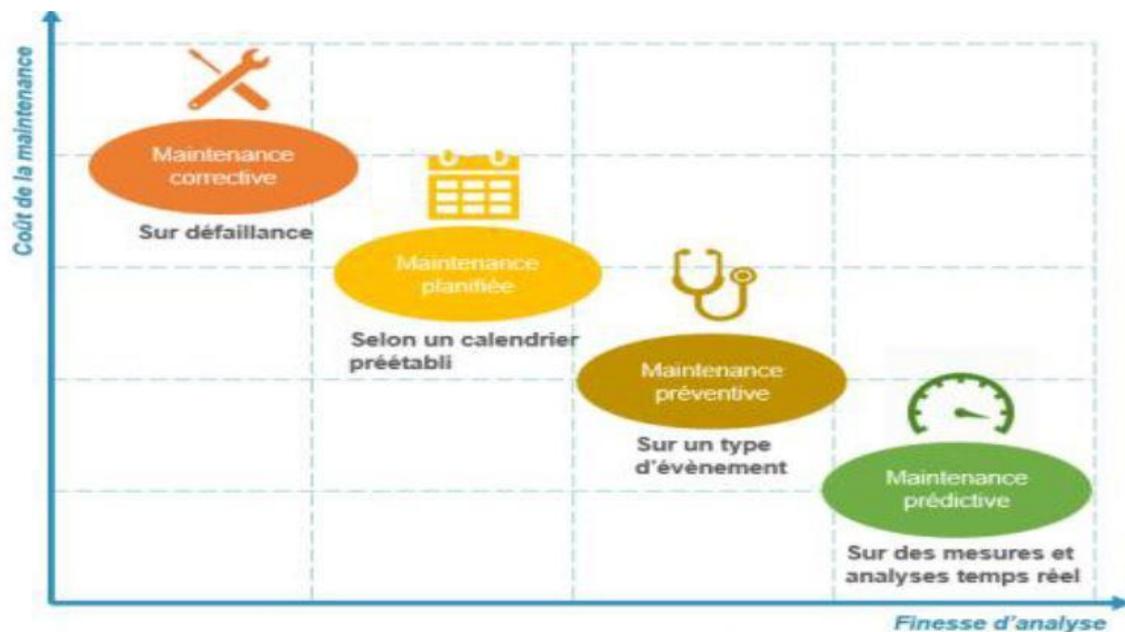


Figure I.6 : L'évolution de la maintenance [19]

I.5 LA MAINTENANCE PRÉDICTIVE (PRÉVISIONNELLE)**I.5.1 DEFINITION**

La maintenance prévisionnelle est une maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien (norme NF EN 13306).

La maintenance prédictive, également appelée maintenance préventive conditionnelle, implique l'ajustement des prévisions d'interventions de maintenance en fonction du temps ou de l'utilisation des équipements, grâce à une analyse continue ou périodique de leur état.

Cette approche repose sur l'utilisation de techniques de prédiction de pannes basées sur des données observables et enregistrables, telles que des relevés de mesures périodiques ou des capteurs spécialisés, qui révèlent l'état de dégradation des équipements. En conséquence, elle permet de remplacer les composants d'un système ou d'un processus juste avant leur défaillance.

Grâce aux méthodes employées dans la maintenance conditionnelle, il est possible d'estimer la durée de vie restante avant la défaillance, car la vitesse de dégradation est connue.

Cette approche est largement utilisée dans divers domaines, notamment ceux présentant des risques élevés tels que les centrales nucléaires, le transport ferroviaire et le transport aérien, où les lois de développement des défaillances sont bien comprises. Cela permet une planification plus efficace des mesures et des interventions nécessaires.

I.5.2 LES APPROCHES DE LA MAINTENANCE PREDICTIVE

La maintenance prédictive englobe un ensemble de méthodes visant à anticiper les états futurs et les dommages potentiels des systèmes industriels. La discipline qui prédit l'état de santé et la durée de vie utile restante (RUL, Remaining Useful Life) en fonction des conditions d'exploitation antérieures et actuelles est souvent appelée Pronostics et gestion de la santé (PHM, Pronostics and Health Management). [20]. Elle se concentre non seulement sur la prédiction des différentes évolutions possibles d'un système, mais également sur la prévention des défaillances avant qu'elles ne surviennent. L'objectif principal de la maintenance prédictive est d'optimiser les décisions concernant les actions à entreprendre en recommandant un ordonnancement efficace des tâches de maintenance, tout en réduisant les coûts associés. Les approches de pronostic, qu'elles soient basées sur des modèles physiques, des données ou l'expérience, reposent sur la connaissance et les données disponibles sur le système à maintenir.

Dans cette analyse, nous explorerons les différentes méthodes de maintenance prédictive, en particulier en soulignant les approches basées sur des modèles de données.

I.5.2.1 LES APPROCHES FONDEES SUR LES CONNAISSANCES ET LES EXPERIENCES

On retrouve les méthodes basées sur des règles, les méthodes basées sur les cas et les méthodes basées sur les connaissances.

Les approches basées sur les connaissances se présentent sous la forme de « Si-Alors » et elles sont obtenues à partir d'expériences antérieures ou de situations problématiques concrètes et s'appuient principalement sur les fiabilistes, sur des modélisations de processus stochastiques ou sur des systèmes experts. [21]. Les inconvénients de cette approche sont la difficulté d'obtenir des connaissances précises à partir de l'expérience et un accès limité à des experts ayant des connaissances. Par conséquent, il en résulte une faible précision de prédiction. Cependant, cette approche est actuellement utilisée dans les techniques d'exploration de données pour extraire les connaissances requises de la base de données.[22]

I.5.2.2 LES APPROCHES BASEES SUR DES MODELES PHYSIQUES

Ces modèles se caractérisent principalement par la modélisation mathématique avec des réflexes dans l'état d'un composant, nécessitant la précision de l'état et la mesure de la défaillance, et des méthodes statistiques pour limiter ces indices [20] [23]. Bien que l'approche basée sur un modèle physique puisse mettre en évidence la logique des défauts du système sans nécessiter une volumineuse quantité de données, elle dépend fortement de l'expertise pour la conception et l'établissement du modèle, ainsi que d'une compréhension approfondie des phénomènes physiques sous-jacents qui mènent aux défaillances du système. Étant donné que la plupart des équipements sont des systèmes mécaniques et électriques complexes, la précision de l'établissement des modèles de dégradation correspondants est souvent compromise en raison de l'incertitude entourant les mécanismes de dégradation.

I.5.2.3 LES APPROCHES BASEES SUR LES DONNEES

Ces approches, les plus courantes dans le développement actuel de solutions de maintenance prédictive, s'appuient sur des méthodes statistiques, de reconnaissance ou d'intelligence artificielle (IA) et des algorithmes d'apprentissage automatique. Sous cet aspect, Baptista et al. (2018) comparent un certain nombre d'approches de l'intelligence artificielle à une approche statistique pour prédire quand un équipement risque de tomber en panne à l'avenir et les résultats suggèrent que les approches d'intelligence artificielle surpassent les approches statistiques [24].

De nombreux chercheurs estiment que les approches basées sur les données sont mieux utilisées lorsque les modèles de système ne sont pas disponibles mais que les données de surveillance du système sont disponibles.

L'apprentissage automatique (ML) en intelligence artificielle est également devenu un outil puissant pour développer des algorithmes prédictifs intelligents dans de nombreuses applications. Ils sont capables de traiter des données de grande dimension et multivariées et d'extraire des relations cachées dans les données dans des environnements complexes et dynamiques, tels que les environnements industriels. Par conséquent, l'apprentissage automatique constitue une méthode prédictive puissante pour les applications de maintenance prédictive. Dans cette approche, les données peuvent être collectées à partir des équipements en fonctionnement et aucun modèle précis d'évolution des pannes ou processus de dégradation des performances n'est requis. Les récents progrès technologiques spectaculaires en matière de puissance de calcul et de traitement, de capacité de stockage et d'interconnexion des différentes technologies de l'information ont créé des quantités de données numériques sans précédent. C'est devenu un domaine interdisciplinaire en pleine croissance en informatique. La technologie d'exploration de données a été largement utilisée pour résoudre des problèmes dans les domaines de l'industrie, de la science et de l'ingénierie, ce qui prouve que l'exploration de données aura un impact profond sur le domaine industriel et la maintenance, notamment en améliorant la sûreté de fonctionnement des équipements.

Afin de mettre en œuvre une stratégie de maintenance prédictive, certaines étapes doivent être respectées. Les équipements existants doivent d'abord être audités, puis des capteurs intelligents connectés déployés pour mesurer en permanence les paramètres de fonctionnement de l'équipement concerné. Il faut ensuite procéder à l'analyse des données collectées pour pouvoir écrire des modèles permettant de prédire les pannes et les dysfonctionnements.

À ce point, l'intelligence artificielle et l'apprentissage automatique sont en tête. À partir de là, nous pouvons structurer une stratégie de maintenance prédictive intelligente en quatre étapes essentielles.

- **Première étape :** Elle consiste à collecter les données relatives aux équipements. Elles doivent être collectées avant que toute analyse puisse être mise en œuvre. Puis consiste à traiter les données et extraire les caractéristiques nécessaires à la phase d'apprentissage. Cette phase de prétraitement traite et transforme les données afin qu'elles puissent être traitées efficacement par le modèle ML. Elle comprend la transformation des données par exemple, la normalisation, le nettoyage des données, le traitement des données manquantes, la suppression des valeurs aberrantes et la réduction des données. Par la suite,

une phase d'analyse des données est nécessaire Pour les classer en état normal et état non normal.

- **Deuxième étape :** Elle implique la création d'un modèle basé sur des données historiques et à l'aide des algorithmes pour identifier les trajectoires comportementales passées de l'installation dans différentes situations.
- **Troisième étape :** Dépendamment du type des données disponibles pendant la phase de création du modèle, l'apprentissage machine est qualifié de différentes manières. En effet, après avoir s'être familiarisé avec les données, Cette étape consiste à appliquer un modèle pour prédire les défauts probable et développé le modèle prédictif en l'apprenant à reconnaître les nouveaux événements et défaillances lorsqu'ils surviennent. Si, par exemple, un modèle prédisant les défauts est souhaité, il est nécessaire d'apprendre au modèle à détecter les défauts à la fois des données de fonctionnement sans défaut et de fonctionnement défectueux. Le modèle peut ensuite être entraîné avec les données et détecter l'état actuel du dispositif [22].
- **Quatrième étape :** Dans cette étape, il serait intéressant de pouvoir régler le système afin qu'il puisse mettre à jour sa base de données en fonction des nouvelles informations collectées sur le matériel, ces nouvelles informations peuvent être utilisées pour entraîner des modèles d'apprentissage automatique. Il devient plus adaptable, efficace et fiable, ce qui permet de prendre de meilleures décisions et d'améliorer les résultats globaux.

Après avoir obtenu les résultats des modèles algorithmiques, les techniques basées sur les données sont combinées avec des techniques basées sur les connaissances pour formuler de meilleures décisions et stratégies.

Des experts expérimentés du secteur examinent les modèles et les résultats pour améliorer les procédures d'exploitation, de maintenance, de surveillance, de test et d'audit afin de garantir des opérations plus sûres et plus efficaces. La création d'un modèle prédictif peut être divisé en cinq (5) étapes comme le montre le diagramme de la figure I.5.

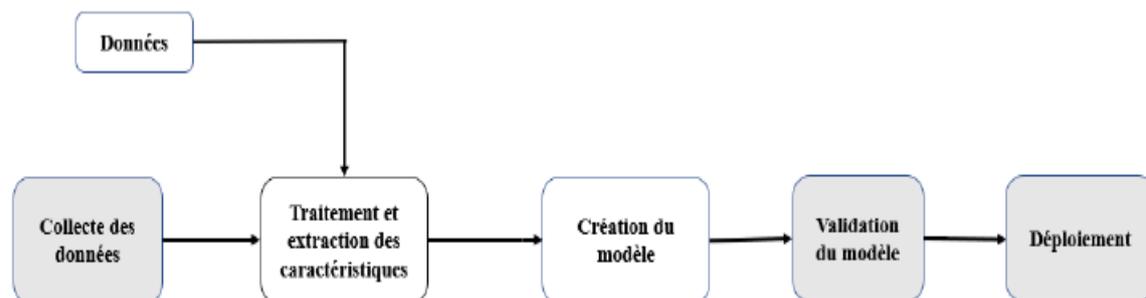


Figure I.7 : Les étapes de création d'un modèle de prédiction [22]

I.5.3 LES TECHNIQUES DE LA SURVEILLANCE POUR LA MAINTENANCE PREDICTIVE

La surveillance d'une machine implique la sélection préalable d'un ensemble d'indicateurs. Ces indicateurs proviennent de paramètres ou de grandeurs mesurés aussi fréquemment que possible pendant le fonctionnement. Ils doivent permettre de caractériser l'état ou les performances de la machine. Leur évolution temporelle doit refléter de manière significative l'apparition ou l'aggravation d'un défaut. Le niveau vibratoire, La température, le niveau sonore, le spectre ou la forme du courant d'alimentation sont autant d'indicateurs capables de représenter l'état d'une machine et de suivre son évolution dans le temps.

I.5.3.1 ANALYSE VIBRATOIRE

La plupart des usines étant constituées de systèmes électromécaniques, la surveillance des vibrations est un élément clé pour la maintenance prédictive. Elle est utilisée principalement pour les équipements rotatifs ou alternatifs, soit de façon continue soit sur des intervalles programmés. La nature des vibrations peut indiquer un déséquilibre ou un désalignement. Les niveaux de vibrations concentrés sur des multiples de la vitesse de rotation peuvent indiquer des problèmes imminents au niveau des roulements. Cependant les vibrations ne sont pas toujours simples à interpréter, surtout pour les machines à courant alternatif. Elles peuvent être analysées avec des techniques d'apprentissage automatique.[25] [26]

Les instruments utilisés dans le cadre de la surveillance vibratoire comprennent les capteurs de déplacement, les capteurs de vitesse et les accéléromètres. Ces derniers sont le meilleur choix pour la plupart des équipements rotatifs industriels car ils sont simples, faciles à intégrer et très sensibles aux différentes vibrations.[26]

I.5.3.2 ANALYSE ACOUSTIQUE

L'étude de l'émission acoustique est une technique de surveillance qui tend à se généraliser, surtout avec l'apport de techniques avancées pour le traitement et le dé-bruitage des signaux.[27] La plupart des machines créent des modèles sonores stables dans des conditions normales de fonctionnement. Si ces modèles sonores sont enregistrés comme références, les modifications des motifs de références permettent donc d'indiquer plusieurs types de détérioration des composants. Comme la surveillance vibratoire, le son est un sous-domaine de l'analyse du bruit. La différence entre les deux est la bande de fréquence à surveiller. Dans le cas de l'analyse des vibrations, la plage surveillée est comprise entre 1 Hz et 30 000 Hz ; les capteurs d'ultrasons mesurent les fréquences de bruit supérieures à 30 000 Hz. L'analyse des ultrasons permet de surveiller la santé

du moteur dans des actifs complexes, en présence d'un bruit audible accru.[26] Cette méthode permet également au contrôleur de déterminer les conditions de fonctionnement de l'équipement, telles que :

- les conditions de lubrification (trop de graisse, pas assez, sale...),
- le degré d'usure,
- les vibrations.

Ces informations sont interprétées par le contrôleur et une indication numérique et converties en instructions de maintenance (urgence) par une base de données.

I.5.3.3 ANALYSE THERMOGRAPHIE INFRAROUGE

Tout corps dont la température est supérieure à zéro degré absolu émet un rayonnement électromagnétique. Et on est capable de détecter ce rayonnement sous la forme de sensations de chaleur. [28]

La thermographie infrarouge (TIR) est la technique qui permet de mesurer et d'analyser des informations thermiques de la puissance du rayonnement électromagnétique dans le spectre des infrarouges à l'aide de dispositifs d'imagerie thermique à distance. La technologie de détection par imagerie thermique infrarouge est l'un des moyens irremplaçables pour assurer la sécurité des conditions de production industrielle. Son utilisation est courante dans le secteur industriel. [29]

La caméra infrarouge capte au travers d'un milieu transmetteur les rayonnements émis par une scène thermique. Le système radiométrique convertit la puissance de rayonnement en signaux numériques ou analogiques : ceux-ci sont transcrits en température par le calculateur et transformés en points lumineux sur un écran. L'image qu'il obtient s'appelle le « thermogramme». [30]

Cette méthode permet d'optimiser la disponibilité des équipements et d'éviter l'arrêt des machines ou les interruptions de production inattendues. En prévoyant les pannes et en organisant les interventions de maintenance de manière anticipée, en diagnostiquant à l'avance les dysfonctionnements latents.

I.5.3.4 ANALYSE DES HUILES

L'analyse des huiles est un pilier essentiel de la maintenance prédictive dans le domaine industriel, au même titre que la thermographie infrarouge et l'analyse vibratoire. Cette technique est pratiquée depuis les années 1950. La fonction principale du lubrifiant est de diminuer le frottement pour garantir la longévité et la sécurité des équipements. Il peut aussi assurer d'autres tâches telles que le refroidissement, la protection contre la rouille et la corrosion, mais aussi le

contrôle non destructif de l'état de fonctionnement de la machine. De plus, sa mise en œuvre est simple, tandis que les niveaux de précision fournis par les données sont également très élevés.

En cas d'apparition d'une défaillance dans un organe de la machine, le suivi des caractéristiques physico-chimiques du lubrifiant peut fournir des informations sur son type et son niveau de dégradation, notamment en cas de dégradation liée à l'oxydation du lubrifiant ou de contamination liée à la présence de débris d'usure. Ces informations peuvent provenir de vérifications et visites quotidiennes, avec des tests simples basés sur des examens visuels, des observations de l'odeur et de la couleur du lubrifiant, ou d'analyses plus poussées en laboratoire telles que la chromatographie, la photométrie ou la spectrométrie. Les principaux inconvénients de l'utilisation de l'analyse des lubrifiants pour le diagnostic des défauts dans les machines sont la difficulté de localisation et d'isolation de l'organe défaillant, ainsi que la lenteur des analyses, réduisant les possibilités de suivi dans le cas d'avaries à progression rapide. [27]

I.6 LA MAINTENANCE PREDICTIVE ET L'INTELLIGENCE ARTIFICIEL

L'arrivée de l'intelligence artificielle (IA) a changé la méthode dont les entreprises font face à la maintenance, offrant des opportunités sans précédent pour augmenter l'efficacité et réduire les coûts. L'IA permet aux entreprises d'automatiser des tâches répétitives, d'optimiser les processus de maintenance et de prévoir les pannes avant qu'elles ne surviennent, réduisant ainsi les interruptions et les dépenses imprévues.

L'un des avantages majeurs de l'utilisation de l'IA dans le domaine de la maintenance industrielle est la puissance d'analyser de fortes quantités de données en temps réel. L'IA peut identifier les pannes et détecter les signes avant-coureurs d'anomalies grâce à un flux continu de données sur l'état des machines et des équipements, fourni par des dispositifs (capteurs) et des systèmes de surveillance connectés. Les entreprises peuvent planifier des interventions de maintenance préventive grâce à cette anticipation, ce qui réduit les temps d'arrêt et les coûts associés.

Plus la détection des pannes, l'IA peut également automatiser des tâches de maintenance chronophages telles que la surveillance des niveaux de lubrifiant, le contrôle des températures et des pressions et la détection des variations de bruit et de vibration. L'utilisation de robots et de drones autonomes pour effectuer ces tâches réduit les risques pour les travailleurs et optimise les coûts opérationnels.

Une expertise approfondie en collecte et en analyse de données ainsi qu'une solide compréhension des modèles et des algorithmes d'apprentissage automatique sont nécessaires pour que l'IA soit utilisée efficacement dans le domaine de la maintenance industrielle.

Pour adapter les interventions aux équipements et aux installations spécifiques, elle exige une connaissance approfondie des opérations de maintenance industrielle.

I.7 CONCLUSION

En conclusion, l'avènement de l'Industrie 4.0 représente un changement fondamental dans le paysage industriel, exigeant une intégration complète des nouvelles technologies plutôt qu'une simple adjonction aux processus existants. Malgré une prise de conscience généralisée des opportunités et des défis qu'elle engendre, sa mise en œuvre est entravée par divers obstacles, notamment la crainte de la cybercriminalité, les lacunes en compétences internes et la résistance au changement au sein des organisations. Un exemple emblématique de cette évolution est la stratégie de maintenance prédictive intelligente, qui tire parti des avancées technologiques pour anticiper les défaillances des équipements. Cependant, son déploiement efficace nécessite une expertise approfondie dans divers domaines, ce qui limite actuellement son adoption principalement aux grandes entreprises disposant de compétences en science des données. Ainsi, bien que les bénéfices potentiels de l'Industrie 4.0 soient indéniables, sa pleine réalisation nécessitera des efforts concertés pour surmonter ces défis et exploiter pleinement son potentiel transformateur.

CHAPITRE II
MODELISATION PAR
APPRENTISSAGE AUTOMATIQUE

II.1 INTRODUCTION

Depuis leur évolution, les humains ont constamment utilisé des outils pour simplifier diverses tâches. L'idée de machines intelligentes existe depuis des siècles, mais a récemment gagné en importance, notamment dans les secteurs industriel et informatique, grâce à l'avènement de l'apprentissage automatique.

L'apprentissage automatique, au cœur de la science des données et de l'intelligence artificielle, joue un rôle clé dans la transformation numérique des entreprises. Ses applications sont variées, s'étendant désormais au domaine de la mécanique et de la maintenance industrielle. Fondamentalement, l'apprentissage automatique concerne la modélisation des données, s'appuyant sur des principes issus des statistiques, de l'intelligence artificielle et du traitement du signal.

Ce chapitre explore les différentes approches de l'apprentissage automatique pour analyser les données en fonction de leurs caractéristiques spécifiques. Nous aborderons la définition, les types et les méthodes de l'apprentissage automatique, avec un focus particulier sur son application à la maintenance industrielle pour améliorer la fiabilité et la performance des équipements.

II.2 L'INTELLIGENCE ARTIFICIELLE

L'intelligence artificielle (IA) est considérée comme un domaine des mathématiques et de l'informatique qui comprend un ensemble de théories et d'algorithmes pour créer des machines qui ressemblent à l'intelligence humaine. Son objectif est de reproduire l'intelligence pour pouvoir résoudre des problèmes complexes.

L'intelligence artificielle évolue et se développe constamment, influencée par les progrès technologiques et le développement scientifique.

L'intelligence artificielle est un domaine qui est divisé en plusieurs sous-domaines imbriqués qui sont montrés dans (Figure II.1).

L'apprentissage automatique est un sous-domaine de l'intelligence artificielle qui utilise l'expérience ou une base de données pour apprendre des règles implicites pour résoudre un problème. Ce domaine s'intéresse principalement à l'analyse statistique des données d'entraînement. Nous verrons qu'il existe de nombreux algorithmes utilisant divers modèles mathématiques dans le domaine de l'apprentissage automatique. Un de ces modèles, probablement le plus utilisé et le plus répandu, est le réseau de neurones. L'apprentissage profond est un ensemble de techniques tirant parti des réseaux de neurones pour résoudre des problèmes complexes. Ces techniques sont très utilisées, notamment dans le domaine du traitement d'image, du traitement de séries temporelles (reconnaissance vocale...). [31]

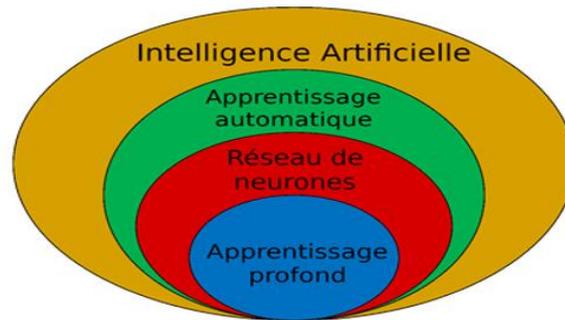


Figure II.1 : Schéma de décomposition du domaine de l'intelligence artificielle [31]

II.3 APPRENTISSAGE AUTOMATIQUE (ML)

II.3.1 DEFINITION

L'apprentissage automatique n'est pas un domaine d'étude récent. En 1959, Arthur Samuel, un pionnier du domaine de l'apprentissage automatique, a fait l'énoncé suivant : « L'apprentissage automatique est le domaine d'étude qui fournit aux ordinateurs la capacité d'apprendre sans être explicitement programmés pour le faire ». [32]

L'idée du Machine Learning est qu'il existera un algorithme d'apprentissage qui aidera la machine à apprendre à partir des données. En 1997, le professeur Tom Mitchell l'a défini comme suit: [33] « A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance at tasks in T , as measured by P , improves with experience E . » [34]

Nous pouvons simplifier la définition comme suit. Le Machine Learning est un domaine qui consiste à apprendre des algorithmes qui :

- Améliorer leurs performances P ;
- Lors de l'exécution d'une tâche T ;
- Au fil du temps avec l'expérience E ;

Si vous considérez notre problème du monde réel rencontré plus tôt, l'une des tâches T pourrait consister à prédire les pannes de notre infrastructure ; l'expérience E serait ce que notre modèle d'apprentissage automatique gagnerait au fil du temps en observant des modèles à partir de divers attributs de données de l'appareil ; et les performances du modèle P pourraient être mesurées de différentes manières, par exemple avec la précision avec laquelle le modèle prédit les pannes.

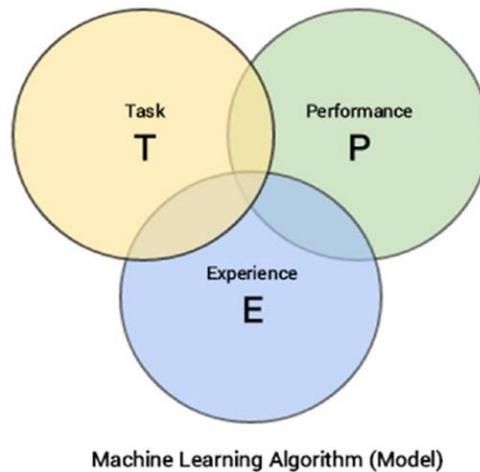


Figure II.2 : Définir les composants d'un algorithme d'apprentissage [33]

L'apprentissage automatique consiste à programmer des ordinateurs pour optimiser un critère de performance en utilisant des données d'exemple ou une expérience passée. Nous avons un modèle défini jusqu'à certains paramètres, et l'apprentissage est l'exécution d'un programme informatique pour optimiser les paramètres du modèle en utilisant les données d'entraînement ou l'expérience passée. Le modèle peut être prédictif pour faire des prédictions dans le futur, ou descriptif pour acquérir des connaissances à partir des données, ou les deux. L'apprentissage automatique utilise la théorie des statistiques dans la construction de modèles mathématiques, car la tâche principale consiste à faire des inférences à partir d'un échantillon. Le rôle de l'informatique est double : d'abord, dans l'entraînement, nous avons besoin d'algorithmes efficaces pour résoudre le problème d'optimisation, ainsi que pour stocker et traiter la quantité massive de données que nous avons généralement. Ensuite, une fois qu'un modèle est appris, sa représentation et sa solution algorithmique pour l'inférence doivent également être efficaces. Dans certaines applications, l'efficacité de l'algorithme d'apprentissage ou d'inférence, à savoir sa complexité en espace et en temps, peut être aussi importante que sa précision prédictive. [35]

II.3.2 TYPES APPRENTISSAGE AUTOMATIQUE

L'apprentissage automatique, également appelé Machine Learning (ML), représente une composante de l'intelligence artificielle. Son objectif est de développer des algorithmes capables d'assimiler des connaissances à partir de données et d'expériences passées ou en interagissant avec leur environnement. Ce qui le distingue, c'est sa capacité à ajuster ses résultats en fonction de nouvelles données, sans nécessiter de programmation préalable.

Il existe diverses approches pour apprendre automatiquement à partir des données, adaptées aux différents problèmes à résoudre et aux types de données disponibles. La figure II.3 offre un aperçu des types les plus courants d'apprentissage automatique.

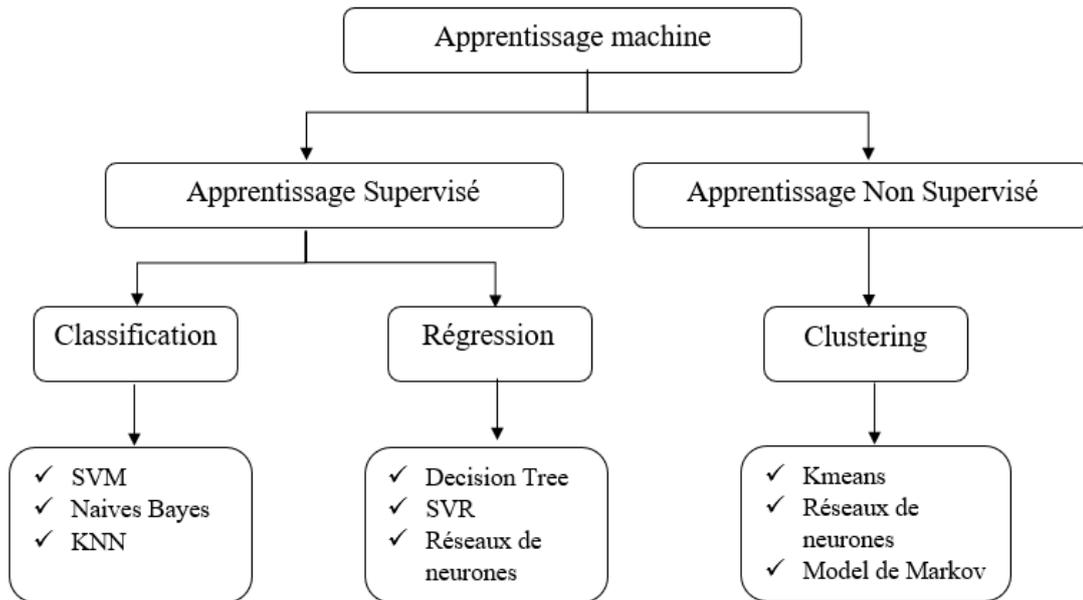


Figure II.3 : Les types d'apprentissage automatique [36]

II.3.2.1 APPRENTISSAGE SUPERVISE

L'apprentissage supervisé est la tâche d'apprentissage automatique la plus simple et la plus connue. Lorsqu'on cite le terme d'apprentissage supervisé, on parle de données d'entraînement étiquetées c'est à dire dont on connaît la sortie voulue. En notant les N entrées x_i et les sorties cibles associées, on dispose de l'ensemble de données

$$D = \{x_i, y_i\}_{i \in [1, N]} \quad (\text{II.1})$$

L'objectif est d'entraîner le modèle choisi pour qu'il puisse prédire correctement la sortie pour des entrées non étiquetées. Il est basé sur un certain nombre d'exemples pré-classifiés, dans lesquels est connue a priori la catégorie à laquelle appartient chacune des entrées utilisées comme exemple souhaité.[37] [31]

La plupart des algorithmes d'apprentissage supervisé partagent une caractéristique, La formation est effectuée par la minimisation d'une fonction de cout, représentant l'erreur de sortie fournie par le système par rapport au résultat possible souhaité, car l'ensemble de la formation nous fournit ce qui doit être le résultat souhaité [38]

La valeur de sortie peut être une indication fournie par un expert : par exemple, des valeurs de vérité de type oui/non ou malade/sain. Ces algorithmes cherchent à définir une représentation compacte des associations entrée-sortie, par l'intermédiaire d'une fonction de prédiction.[39]

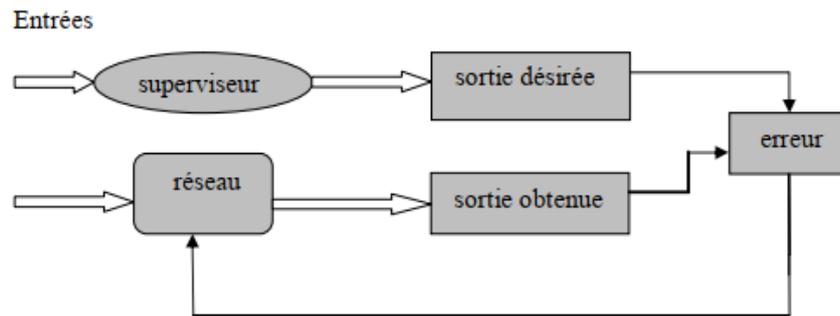


Figure II.4 : Illustration de l'apprentissage supervisé [40]

Les méthodes d'apprentissage supervisé se divisent en deux classes principales en fonction du type de tâches ML qu'elles visent à résoudre.

1. CLASSIFICATION

C'est l'un des types d'apprentissage automatique supervisé qui vise à créer des règles pour classer des objets en fonction de leurs caractéristiques qualitatives ou quantitatives. Elle identifie des éléments particuliers dans toutes les données et essaie d'effectuer des analyses sur la façon dont ces éléments doivent être identifiés ou définis.

Les tâches basées sur la classification dont le principal objectif est de prédire des étiquettes de sortie ou des réponses qui sont de nature catégorique pour des données d'entrée, en se basant sur ce que le modèle a appris lors de la phase d'entraînement. Les étiquettes de sortie, également connues sous le nom de classes ou d'étiquettes de classe, sont de nature catégorique, ce qui signifie qu'elles sont des valeurs non ordonnées et discrètes. Ainsi, chaque réponse de sortie appartient à une classe ou catégorie discrète spécifique. Une tâche où le nombre total de classes distinctes est supérieur à deux devient un problème de classification multi-classes où chaque réponse de prédiction peut être l'une des classes probables de cet ensemble. Dans les deux cas, la classe de sortie est une valeur scalaire pointant vers une classe spécifique. Les tâches de classification multi-étiquettes sont telles que, basées sur n'importe quel échantillon de données d'entrée, la réponse de sortie est généralement un vecteur ayant une ou plusieurs étiquettes de classe de sortie. Un problème simple du monde réel consisterait à essayer de prédire la catégorie d'un article de presse qui pourrait avoir plusieurs classes de sortie comme les actualités, la finance, la politique, etc. Les algorithmes de classification populaires comprennent la régression logistique, les machines à vecteurs de support, les réseaux neuronaux, les ensembles comme les forêts aléatoires et le boosting de gradient, les K plus proches voisins, les arbres de décision, et bien d'autres.[33]

2. REGRESSION

Régression est une approche employée pour prédire des valeurs continues à partir de variables en entrée. Cette méthode implique la création d'une relation mathématique entre les données d'entrée et de sortie, facilitant ainsi les estimations ou les prédictions sur des données inédites. Parmi les techniques de régression les plus utilisées, on retrouve la régression linéaire, qui vise à établir une liaison linéaire entre les variables. D'autres types de régression incluent la régression logistique, utilisée pour la prédiction de variables binaires ou catégorielles. L'objectif fondamental de la régression est de minimiser l'écart entre les valeurs anticipées et les valeurs réelles, afin de concevoir un modèle capable de généraliser de manière efficace sur de nouvelles données.

II.3.2.2 APPRENTISSAGE NON SUPERVISE

Dans le contexte de l'apprentissage non supervisé, nous traitons des données non étiquetées, c'est-à-dire des données d'entrée sans sorties associées identifiées. Ainsi, nous disposons d'un ensemble de données, noté :

$$D = \{x_i\}_{i \in [1, N]} \quad (\text{II.2})$$

Où les sorties ne sont pas explicitement définies. L'objectif du système est alors d'extraire et d'identifier les caractéristiques communes parmi ces données d'entraînement.

Dans ce cas, les algorithmes cherchent à organiser les données en groupes tels que les algorithmes de regroupements (clustering). Ces algorithmes regroupent donc les entrées en familles afin de les étiqueter automatiquement. Chaque groupe doit comprendre des données similaires et les données différentes doivent se retrouver dans des groupes distincts. L'apprentissage ne se fait plus à partir d'une indication qui peut être préalablement fournie par un expert, mais uniquement à partir des fluctuations observables dans les données. [39] [41]

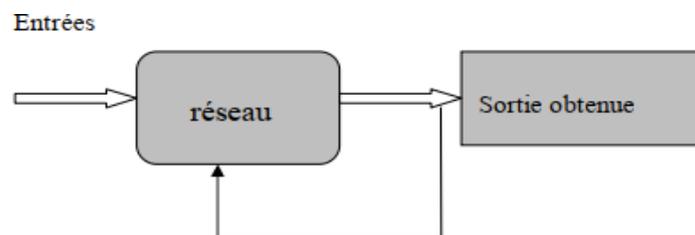


Figure II.5 : Illustration de l'apprentissage non supervisé [40]

1. CLUSTERING (REGROUPEMENT)

Les méthodes de clustering sont des méthodes d'apprentissage automatique qui tentent de trouver des modèles de similarité et des relations entre les échantillons de données de notre ensemble de données, puis de regrouper ces échantillons en différents groupes, de sorte que chaque groupe ou cluster d'échantillons de données présente une certaine similitude, en fonction des attributs ou caractéristiques inhérents. Ces méthodes ne sont absolument pas supervisées, car elles tentent de regrouper les données en examinant les caractéristiques des données sans aucune formation, supervision ou connaissance préalable des attributs, des associations et des relations des données.[33] Cette technique est largement utilisée dans divers domaines tels que la bio-informatique, la reconnaissance de formes, l'analyse des réseaux sociaux, la segmentation de marché et la vision par ordinateur, entre autres.

Le choix de l'algorithme de clustering dépend souvent de la nature des données et des objectifs de l'analyse. Une fois le clustering effectué, il est important d'évaluer la qualité des clusters obtenus à l'aide de mesures telles que l'indice de silhouette ou l'indice de Davies-Bouldin. Ces mesures permettent de déterminer si les clusters sont cohérents et significatifs.

2. LA REDUCTION DE DIMENSION

La réduction de dimensionnalité est un processus étudié en mathématiques et en informatique, qui consiste à prendre des données dans un espace de grande dimension et à les remplacer par des données dans un espace de plus petite dimension. Pour que l'opération soit utile, il faut que les données en sortie représentent bien les données d'entrée [42]. L'objectif est de simplifier les données sans perdre trop d'informations, ce qui peut être réalisé en fusionnant plusieurs caractéristiques corrélées en une seule. Par exemple, le kilométrage d'une voiture peut être très corrélé avec son âge, de sorte que l'algorithme de réduction de la dimensionnalité les fusionnera en une seule caractéristique qui représente l'usure de la voiture, ce processus étant appelé extraction de caractéristiques.[43]

II.3.2.3 APPRENTISSAGE PAR RENFORCEMENT

L'apprentissage par renforcement représente une autre catégorie de systèmes d'apprentissage automatique. Dans ce type de système, un agent, qui est un système d'intelligence artificielle, observe son environnement, effectue des actions données, puis reçoit des récompenses en retour. Contrairement à d'autres formes d'apprentissage, dans ce cas, l'agent doit apprendre de lui-même, ce qui est souvent désigné sous le terme de politique. Ce genre d'apprentissage est couramment

utilisé dans de nombreuses applications robotiques, notamment celles qui visent à apprendre à marcher.[44]

La distinction de l'apprentissage par renforcement par rapport aux méthodes supervisées et non supervisées réside dans le fait que les actions que nous prenons affectent significativement les informations subséquentes que nous obtenons, d'où l'accent mis sur la prise de décision le meilleur possible à chaque itération d'un algorithme donné. L'algorithme de base est décrit comme suit :

- Agent

Exécute une action donnée

Observe un certain résultat

Reçoit une récompense, généralement modélisée sous forme d'un scalaire

- Environnement

Reçoit l'action effectuée par l'agent

Fournit une observation ainsi qu'une récompense scalaire. [45]

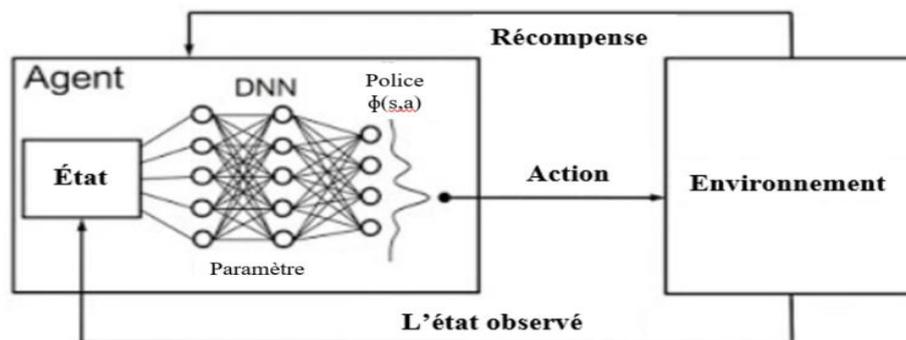


Figure II.6 : Schéma descriptive de l'apprentissage par renforcement [46]

II.4 APPRENTISSAGE PROFOND (DEEP LEARNING)

L'apprentissage profond, aussi appelé Deep Learning en anglais, repose sur les mêmes principes d'apprentissage que l'apprentissage automatique, mais avec une densité substantiellement plus élevée de neurones analytiques. Grâce à cette augmentation de densité, la couche de perception est éliminée, ce qui permet au réseau de neurones lui-même de reconnaître les caractéristiques discriminantes du problème, d'où l'utilisation courante de l'expression « réseaux de neurones profonds ». Cette profondeur désigne les diverses couches de neurones présentes dans ces réseaux, et grâce à cette méthode, l'intelligence artificielle a un avenir prometteur. Effectivement, la mise en place de l'apprentissage profond a simplifié de nombreuses applications concrètes de l'intelligence artificielle, offrant ainsi de nouvelles opportunités dans le domaine de l'IA. Des applications telles que les voitures sans conducteur, les soins de santé préventifs les plus efficaces, voire les recommandations de films plus précises, sont déjà

disponibles ou en cours de développement. Avec l'aide de l'apprentissage profond, l'IA pourrait même réaliser les rêves de science-fiction que nous avons longtemps imaginés. Les algorithmes de réseaux de neurones récents s'inspirent de la structure biologique de notre cerveau et de ses interconnexions neuronales. Toutefois, contrairement aux cerveaux biologiques, où n'importe quel neurone peut être connecté à n'importe quel autre, ces réseaux neuronaux sont liés les uns aux autres dans une direction spécifique de propagation des données et apprennent en réagissant aux stimuli externes, en intégrant les résultats des niveaux précédents pour en tirer des abstractions toujours plus complexes.

II.5 LES ALGORITHMES D'APPRENTISSAGE SUPERVISE

L'apprentissage automatique supervisé, un domaine crucial de l'intelligence artificielle, se divise en deux branches principales : la régression et la classification. Chacune de ces branches comporte diverses méthodes et techniques, toutes visant à modéliser et à prédire des relations entre des données d'entrée et des variables cibles. Dans cette section, en mettant en lumière certaines des méthodes les plus couramment utilisées dans la classification.

II.5.1 L'ARBRE DECISION (DECISION TREE)

Un arbre de décision est un enchaînement hiérarchique de règles logiques ou de production construites de manière automatique à partir d'un ensemble de données. La construction de l'arbre de décision consiste à utiliser les descripteurs, pour subdiviser progressivement l'ensemble en sous-ensembles de plus en plus fins.

Les arbres de décision sont des algorithmes de classification de données reposant sur un apprentissage supervisé. Comme son nom l'indique, la structure de ces algorithmes ressemble à des arbres constitués de nœuds, de branches et de feuilles. La construction de ces arbres est réalisée à l'aide d'une base de données brute (vecteur des caractéristiques et classes) et de lois qui permettent de déterminer les variables discriminantes pour la classification efficace des futures données. Chacun des nœuds constituant l'arbre représente une règle de classification préalablement déterminée de manière récursive.

Dans les domaines de l'informatique décisionnelle et du forage de données, ce type d'algorithmes est très utilisé, car ils permettent de construire automatiquement des classifications et leur vitesse d'exécution surpasse tous les autres types d'algorithmes. Cependant, ils ne permettent pas d'obtenir de bons résultats quand les données sont complexes.

Pour voir comment un arbre de décision prédit une réponse, il faut suivre les décisions dans l'arbre du nœud racine (début) jusqu'au nœud feuille qui contient la réponse. Les arbres de classification donnent des réponses nominales, tel que vrai ou faux et les arbres de régression donnent des

réponses numériques. Les arbres de décision sont relativement rapides et faciles à suivre dans leur résolution ; vous pouvez voir une représentation complète du chemin parcouru de la racine à la feuille. Cela est particulièrement utile si vous devez partager les résultats avec des personnes intéressées par la manière dont une conclusion a été tirée.[36]

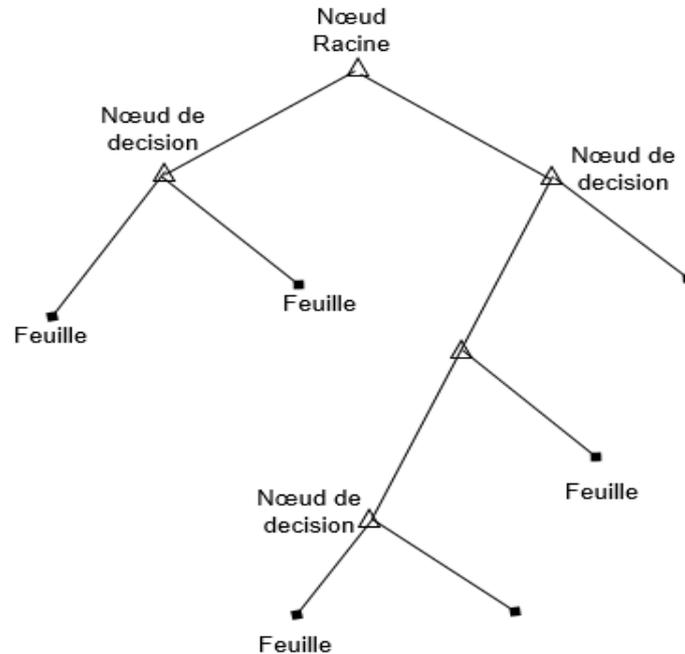


Figure II.7 : Exemple d'illustration d'un arbre de décision [36]

II.5.2 LES k-PLUS PROCHES VOISINS (K-NN)

L'algorithme des K plus proches voisins est l'un des algorithmes d'apprentissage les plus simples à comprendre. Il est basé sur la technique d'apprentissage supervisé et peut être utilisé à la fois pour la régression et pour la classification. Cependant, il est principalement utilisé pour résoudre divers problèmes de classification de données. Cette méthode non paramétrique de classification des motifs a été introduite par Fix et Hodges en 1951 et est depuis lors connue sous le nom de règle des k plus proches voisins.[47] [22]

L'algorithme KNN suppose la similitude entre le nouveau cas/données et les cas disponibles et place le nouveau cas dans la catégorie la plus similaire aux catégories disponibles. Il est également appelé algorithme d'apprentissage paresseux, car il n'apprend pas immédiatement de l'ensemble d'entraînement. Au lieu de cela, il stocke l'ensemble de données et, au moment de la classification, il effectue une action sur l'ensemble de données. Ainsi, lorsqu'il obtient de nouvelles données, il classe ces données dans une catégorie très similaire aux nouvelles données. Le fonctionnement de l'algorithme KNN peut être expliqué sur la base de quatre grandes étapes. On commence par sélectionner le nombre K des voisins dont on calcule la distance.

Nous utilisons une norme euclidienne sur les données standardisées pour déterminer la distance entre un point donné et ses K voisins. Cette équation est donnée comme suit : [48]

$$d(x, y) = \sum_{i=1}^N \sqrt{(x_i - y)^2} \quad (\text{II.3})$$

I : 1, 2, ...N

N : le nombre total d'observations,

X_i : ième observation,

Y : Le point spécifique que nous voulons classer.

Par la suite, on prend les K voisins les plus proches selon cette distance, et on compte le nombre de points de données dans chaque catégorie. Finalement, on affecte les nouveaux points de données à une catégorie pour laquelle le nombre de voisins est maximum. Comme on l'a discuté, le principe de l'algorithme du classificateur KNN consiste à trouver K le nombre prédéfini d'échantillons d'apprentissage les plus proches de la distance du nouveau point et à prédire son étiquette. La valeur minimale de K est 1. Cela signifie utiliser un seul voisin pour la prédiction. Le maximum est le nombre de points de données dont on dispose. La recherche a montré qu'aucun nombre optimal de voisins ne convient à tous les types d'ensembles de données. Chaque jeu de données possède ses propres exigences. Dans le cas d'un petit nombre de voisins, le bruit aura une plus grande influence sur le résultat, et un grand nombre de voisins rend le calcul coûteux. Le plus grand inconvénient de cette méthode est qu'elle peut être erronée par des attributs non pertinents qui masquent des attributs importants. [22] [36]

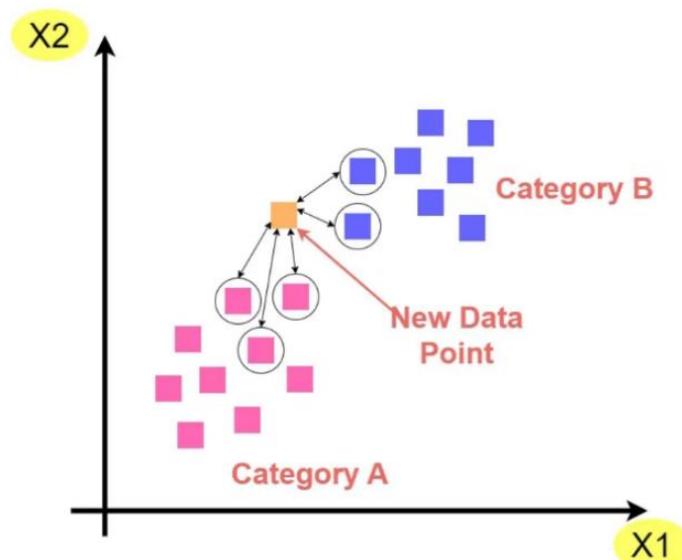


Figure II.8 : Principe de l'algorithme KNN [49]

II.5.3 MACHINES A VECTEURS SUPPORTS (SVM)

Les machines à vecteurs de support (SVM) sont des outils flexibles de classification binaire, aussi connues sous le nom de séparateurs à vaste marge, célèbres pour leur efficacité et leur précision. Elles surpassent la régression logistique en traitant les problèmes de classification non linéaire grâce à l'utilisation de fonctions de noyau pour transformer les données dans des espaces de caractéristiques complexes. Conçues par Vapnik et ses collaborateurs en 1992, les SVM reposent sur une théorie de l'apprentissage statistique établie dans les années 1960. Leur popularité a augmenté en raison de leurs performances robustes, rivalisant voire surpassant parfois les réseaux de neurones dans diverses applications. Leur principe de fonctionnement repose sur la recherche d'un hyperplan optimal qui sépare efficacement les différentes classes dans un espace de caractéristiques. Au début, le SVM reçoit un ensemble de données étiquetées et peut utiliser différentes fonctions de noyau pour projeter ces données dans un espace de dimension supérieure, où la séparation linéaire ou non linéaire est possible. L'objectif principal est de maximiser la marge, qui est la distance entre l'hyperplan et les exemples les plus proches de chaque classe, appelés vecteurs de support. Ceci est réalisé en résolvant un problème d'optimisation convexe qui trouve les coefficients de l'hyperplan de manière à maximiser la marge tout en minimisant les erreurs de classification. Une fois que l'hyperplan optimal est trouvé, de nouveaux exemples peuvent être classés en fonction de leur position par rapport à cet hyperplan. Les SVM sont particulièrement efficaces pour généraliser à partir d'un ensemble de données limité, car ils visent à maximiser la marge et sont insensibles à la dimensionnalité des données, ce qui les rend appropriés pour des espaces de caractéristiques de grande dimension.

II.5.3.1 NOTION DE BASE**1. HYPER PLAN**

Pour deux classes d'exemples donnés, le but de SVM est de trouver un classificateur qui va séparer les données et maximiser la distance entre ces deux classes. Avec SVM, ce classificateur est un classificateur linéaire appelé hyperplan. La figure II.9 ci-dessous représente un hyperplan qui sépare entre deux ensembles de points. [50]

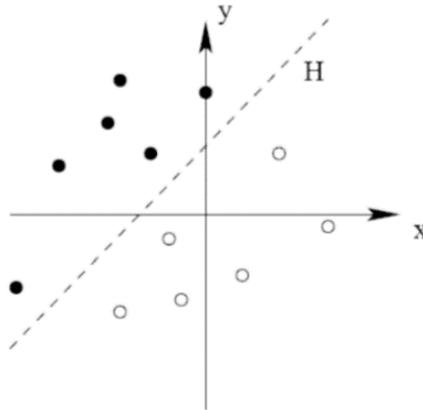


Figure II.9 : Hyperplan séparant deux classes [50]

2. VECTEURS DE SUPPORT (SUPPORT VECTORS)

Les vecteurs de support, qui représentent les points les plus proches de l'hyperplan de séparation [50], jouent un rôle crucial dans les Support Vector Machines (SVM). Ils déterminent la position de cet hyperplan et ont un impact direct sur la capacité du modèle à généraliser efficacement sur de nouvelles données. En d'autres termes, la localisation précise des vecteurs de support influence la frontière de décision de la SVM, ce qui en fait des éléments essentiels à considérer lors de la phase de modélisation.

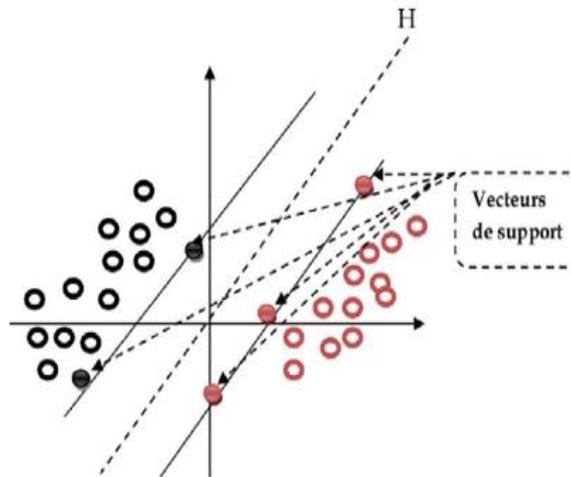


Figure II.10 : les vecteurs de support [51]

3. LA MARGE

La marge, désignant la distance entre l'hyperplan de séparation et les points les plus proches de chaque classe, également connus sous le nom de vecteurs de support.

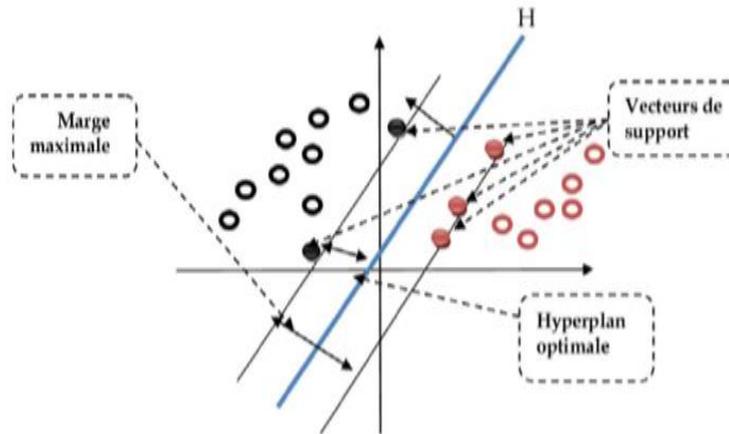


Figure II.11 : La marge [51]

II.5.3.2 PRINCIPES FONDAMENTAUX

1. LA MAXIMISATION DE LA MARGE

Intuitivement, le fait d'avoir une marge plus large procure plus de sécurité lorsque l'on classe un nouvel exemple. De plus, si l'on trouve le classificateur qui se comporte le mieux vis-à-vis des données d'apprentissage, il est clair qu'il sera aussi celui qui permettra au mieux de classer les nouveaux exemples. Dans la figure II.12 qui suit, la partie droite nous montre qu'avec un hyperplan optimal, un nouvel exemple reste bien classé alors qu'il tombe dans la marge. On constate sur la partie gauche qu'avec une plus petite marge, l'exemple se voit mal classé.[50]

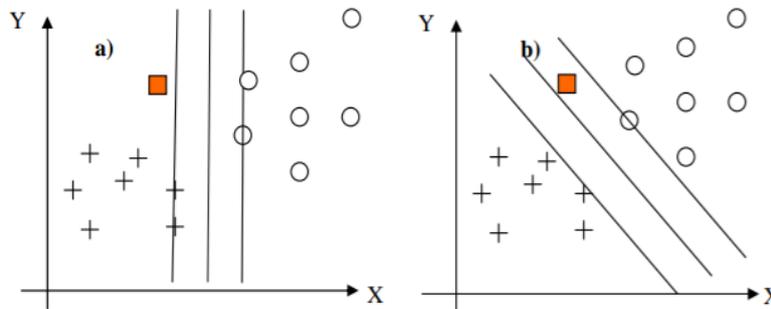


Figure II.12 : a) Hyperplan avec faible marge, b) Meilleur hyperplan séparateur [52]

2. CAS LINEAIREMENT SEPARABLE

Un classificateur dit linéaire, ça veut dire que, dans le cas parfait, les données doivent être linéairement séparables Il est possible d'exprimer sa fonction de décision par une fonction linéaire en x, on peut exprimer une telle fonction par :[36] [53]

$$h(x_i) = \langle w, x_i \rangle + b = \sum_{j=1}^p w_j \cdot x_i^j + b \quad (II.4)$$

Avec w est le vecteur de poids et b est le biais, alors que x est la variable. X est l'espace d'entrée qui correspond à \mathbb{R}^P , où p est le nombre d'attributs des vecteurs d'entrée. P est également la dimension de l'espace d'entée. Notons que l'opérateur $\langle \rangle$ désigne le produit scalaire usuel Pour décider à quelle classe un exemple appartient, il suffit de prendre le signe de la fonction de décision :[53]

$$\begin{cases} \langle w, x_i \rangle + b \geq 1 \text{ si } y_i = 1 \\ \langle w, x_i \rangle + b \leq -1 \text{ si } y_i = -1 \end{cases}$$

Cette fonction est équivalente à :

$$y_i(\langle w, x_i \rangle + b) \geq 1 \quad \text{Avec } i = 1 \dots n \quad (\text{II.5})$$

L'objectif de la recherche de l'hyperplan optimal consiste à maximiser la marge M , ce qui revient à augmenter la somme des distances euclidiennes d entre les exemples des deux classes et l'hyperplan. La marge est donnée par l'expression suivante :

$x_b = x_a - d \frac{w}{\|w\|}$ Avec x_b, x_a, w représentent des vecteurs et $\frac{w}{\|w\|}$ est un vecteur unitaire À partir de là, l'équation est obtenue comme suit :

$$\langle w, x_b \rangle + b = 0 \quad \text{Avec } b \text{ étant un point de l'hyperplan } h$$

3. CAS NON LINEAIREMENT SEPARABLE

Pour surmonter les inconvénients des cas non linéairement séparables, l'idée des SVM est de changer l'espace des données. La transformation non linéaire des données peut permettre une séparation linéaire des exemples dans un nouvel espace. On va donc avoir un changement de dimension. Cette nouvelle dimension est appelée « espace de re-description ».

En effet, intuitivement, plus la dimension de l'espace de re-description est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples est élevée. La figure II.13 représente une séparation non linéaire dans l'espace. [54]

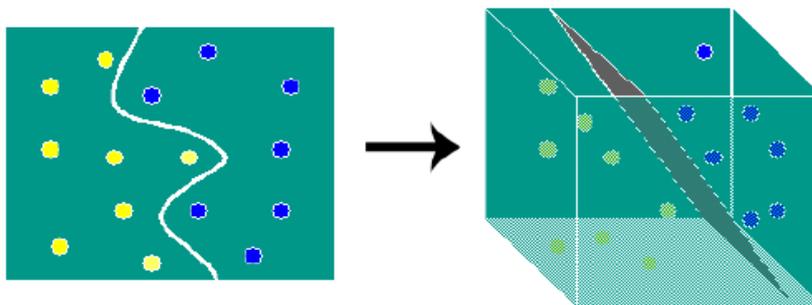


Figure II.13 : Séparation non linéaire dans l'espace [50]

II.5.3.3 TRANSFORMATION A UN ESPACE A HAUTE DIMENSION

1. TECHNIQUE DE L'ASTUCE DES NOYAUX (KERNEL TRICK)

Dans les machines à vecteurs de support (SVM), l'objectif est de trouver un hyperplan optimal qui maximise la capacité de généralisation. Cependant, lorsque les données d'apprentissage ne peuvent pas être séparées linéairement, même en optimisant les hyperplans, le modèle obtenu ne sera pas capable de généraliser efficacement. Pour surmonter cette limitation, une approche consiste à transformer l'espace d'entrée initial en un espace de caractéristiques de dimension supérieure, également appelé espace des caractéristiques. Cela vise à améliorer la séparabilité linéaire des données. Dans la Figure II.5 illustre cette idée de transformation vers un espace de dimension supérieure. Dans cette représentation, les exemples dans l'espace bidimensionnel ne peuvent pas être séparés linéairement, mais après une transformation appropriée, ils deviennent linéairement séparables dans un espace tridimensionnel.

En utilisant la fonction vectorielle non linéaire qui fait correspondre le vecteur d'entrée x (M -dimensionnel) dans l'espace caractéristique l -dimensionnel, la fonction de décision linéaire dans l'espace des caractéristiques est exprimée par :[55]

$$D(x) = w^T g(x) + b \quad (\text{II.6})$$

Avec w est un vecteur à l -dimension et b est un terme de biais.

L'avantage des noyaux (kernels) réside dans le fait qu'ils permettent d'éviter la manipulation directe de l'espace des caractéristiques à haute dimension. Cette approche est couramment désignée sous le terme d'astuce des noyaux (kernel trick).

Pour les nouveaux exemples, nous pouvons classer en utilisant la fonction de décision suivante :

$$x \in \begin{cases} \text{classe 1 si } D(x) > 0 \\ \text{classe 2 si } D(x) < 0 \end{cases}$$

Remarque : si $D(x) = 0$, x est inclassable [55]

2. LES NOYAUX (KERNELS)

a. NOYAUX LINEAIRES

Les noyaux linéaires effectuent simplement un produit scalaire entre les vecteurs d'entrée, sans transformation non linéaire. Ils sont souvent utilisés lorsque les données sont déjà linéairement séparables dans l'espace d'origine ou lorsque la transformation non linéaire n'est pas nécessaire pour la tâche de classification ou de régression.

$$H(x, x') = x^T x' \quad (\text{II.7})$$

b. NOYAUX POLYNOMIAUX

Une transformation non linéaire des données en les élevant à des puissances successives, puis en effectuant un produit scalaire dans un espace de dimension supérieure.

$$H(x, x') = (x^T x')^d \quad (\text{II.8})$$

c. NOYAUX DE FONCTION DE BASE RADIALE (RADIAL BASIS FUNCTION)

Les noyaux de fonction de base radiale (RBF) appliquent une transformation non linéaire en évaluant la similarité entre les données et des centres particuliers dans un espace de caractéristiques de dimension supérieure. Cette mesure de similarité est souvent basée sur la distance euclidienne entre les exemples de données et ces centres spécifiques.

$$H(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (\text{II.9})$$

La figure II.14 démontre une illustration de la transformation de l'espace d'entrée bidimensionnel à l'aide d'un noyau RBF. Dans le nouvel espace de caractéristiques tridimensionnel ainsi obtenu, les exemples deviennent linéairement séparables, facilitant leur séparation par un plan.

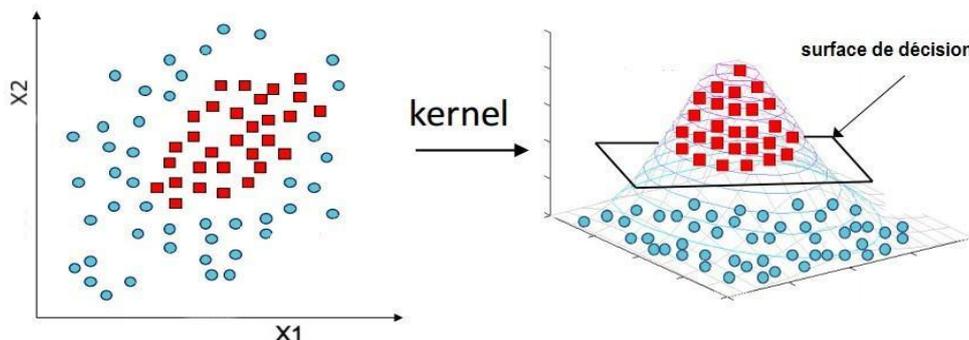


Figure II.14 : Transformation de l'espace en utilisant un noyau (cas RBF) [55]

II.5.4 RESEAUX NEURONES

II.5.4.1 L'ORIGINE DE RESEAUX DE NEURONES

Les principes des neurones biologiques ont influencé le développement des unités neuronales artificielles. Le concept de perceptron, introduit par McCulloch et Pitts en 1943, représente une imitation des neurones biologiques pour former la base des réseaux neuronaux artificiels. Ces unités sont conçues pour refléter le comportement des neurones biologiques, bien qu'elles aient subi quelques adaptations pour faciliter leur utilisation dans les modèles informatiques.[47]

Dans le système nerveux biologique, les neurones interagissent via des connexions complexes, comprenant des axones, des synapses et des dendrites. Les synapses agissent comme des ponts de communication entre les neurones, permettant le transfert de signaux sous forme de

neurotransmetteurs. Chaque neurone intègre les signaux reçus de multiples dendrites et décide de l'émission ou non d'un signal à travers son axone. Ainsi, les réseaux neuronaux biologiques servent de modèle pour comprendre les mécanismes de communication et de traitement de l'information, inspirant ainsi la conception et le développement des réseaux neuronaux artificiels.

En condensant la modélisation des neurones présentée dans le tableau (II.1) et la figure II.15, on peut aisément observer la transition des concepts de neurones biologiques à ceux de neurones formels.

Tableau II.1 : Mise en correspondance neurone biologique / neurone artificiel

| Neurones biologiques | Neurones artificiels |
|----------------------|-----------------------|
| Synapses | Connections pondérées |
| Dendrites | Entrées |
| Corps du neurone | Fonction d'activation |
| Axones | Sorties |

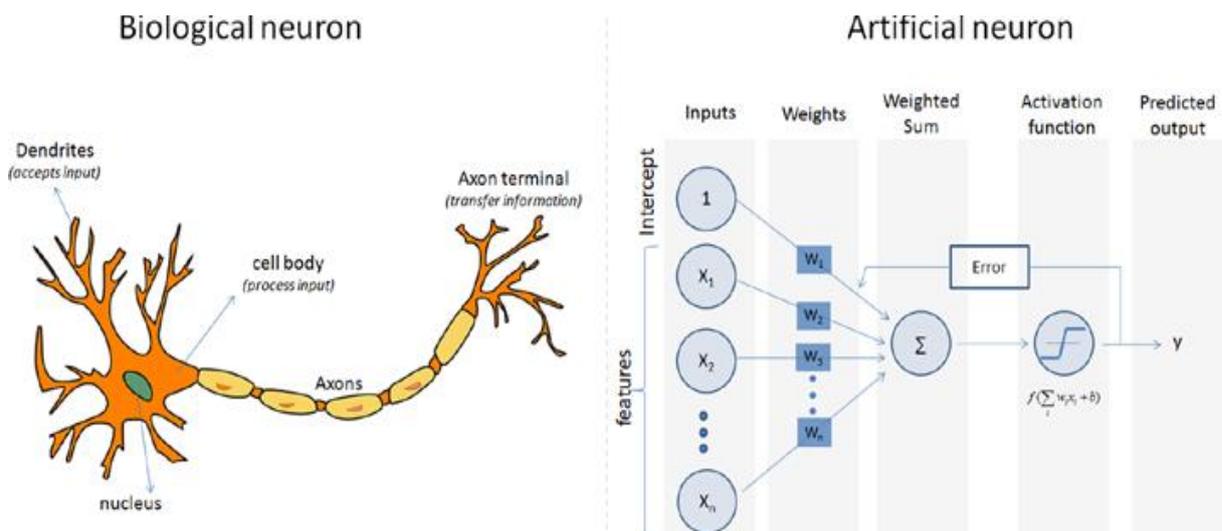


Figure II.15 : Mise en correspondance neurone biologique / neurone artificiel [47]

II.5.4.2 DEFINITION DE RESEAUX NEURONES ARTIFICIEL (RNA)

Actuellement, différents termes sont utilisés pour décrire le domaine des réseaux de neurones artificiels, comme le connexionnisme et la neuromimétique. Cependant, il est important de distinguer leurs nuances sémantiques. Les réseaux de neurones artificiels désignent spécifiquement les modèles utilisés, plutôt qu'un domaine de recherche ou une discipline scientifique en soi. Leur architecture de base consiste en un réseau de petits nœuds de traitement interconnectés par des connexions pondérées et dirigées, analogues aux neurones biologiques. Chaque neurone agit comme un accumulateur de signaux synaptiques entrants, combinant ces

signaux selon une fonction de transfert non linéaire pour produire une sortie. Les applications des réseaux de neurones artificiels sont vastes et touchent de nombreux domaines, incluant la reconnaissance d'images et de sons, la prédiction de séries temporelles, et la robotique.

Les neurones artificiels additionnent le signal provenant d'autres neurones via une somme pondérée des signaux, opération connue sous le nom de multiplication et accumulation (MAC). Les poids, définis par des synapses artificielles, sont ajustés lors de l'apprentissage pour sélectionner les informations pertinentes et supprimer les informations non pertinentes. Après la sommation, les neurones effectuent une transformation non linéaire, pouvant être réalisée à l'aide de différentes fonctions telles que la fonction Rectified Linear Unit (ReLU), qui produit un signal de sortie uniquement au-dessus d'un seuil d'entrée. [56]

II.5.4.3 MODÉLISATION GÉNÉRALE

Par analogie avec la biologie, un neurone artificiel (Fig.II.2), reçoit l'information provenant des entrées $x_i = (i = 1, 2, 3 \dots n)$ par l'intermédiaire des connexions dont on affecte à chacune d'elles un poids w_i abréviation de Wight en anglais, pondérant l'information, et aussi représentatif de la force de la connexion. Le neurone artificiel fonctionne en deux étapes :

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

$$v_j = b_j + \sum_{i=1}^n w_{j,i} x_i \quad (\text{II.10})$$

Où

$w_{j,i}$: désigne le poids de la connexion liant le neurone j à l'entrée i ;

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

Ainsi, la relation s'écrit plus simplement :

$$v_j = \sum_{i=0}^n w_{j,i} x_i \quad (\text{II.11})$$

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

$$S_j = g(v_j) = b_j + \sum_{i=1}^n w_{j,i} x_i \quad i = (1, 2, 3 \dots n) \quad (\text{II.12})$$

Le choix de la fonction d'activation se révèle dans certains cas être un élément constitutif important des réseaux de neurones. Ainsi, le neurone peut être défini mathématiquement comme étant une fonction algébrique, non linéaire (suivant g) et bornée, des entrées x_i et paramétrée par les poids $w_{j,i}$:[57]

$$S_j = g(w_{j,i}x_i) = g_{w_{j,i}}(x_i) \quad i = (1,2,3 \dots .n) \quad (\text{II.13})$$

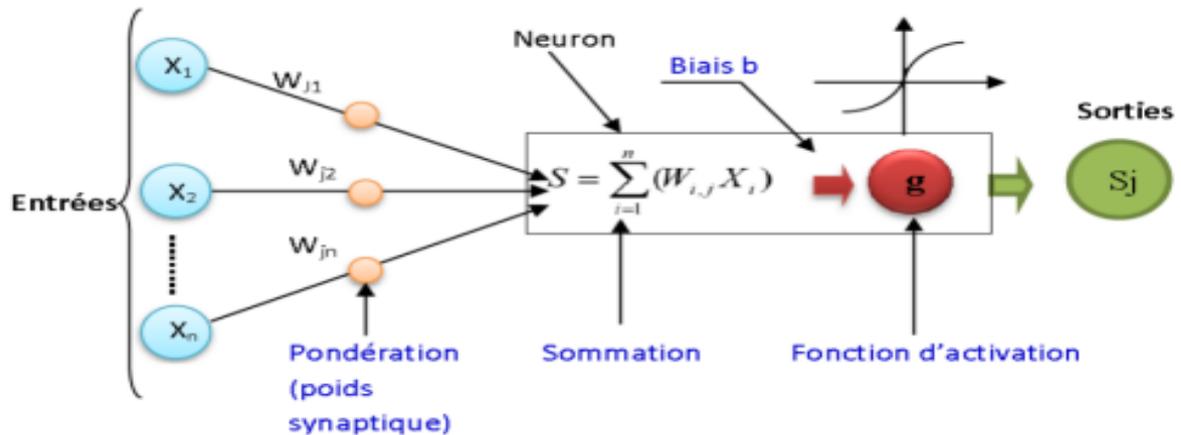


Figure II.16 : La géométrie du neurone artificiel [57]

Le neurone réalise alors trois opérations sur ses entrées :

a) Pondération

Multiplication de chaque entrée par un paramètre appelé poids de connexion.

b) Somme

Une somme des entrées pondérées est effectuée.

a) Fonctions d'activation

La fonction d'activation définit le potentiel de sortie d'un neurone en termes de niveaux d'activité de ses entrées. Il existe plusieurs fonctions d'activations, les plus utilisées sont résumées dans le tableau II.2 suivants :

Tableau II.2 : Différentes fonctions d'activations utilisées dans les RNA

| Nom de la fonction | Relation entrée/sortie | Icône |
|------------------------------------|--|---|
| Seuil | $y = 0$ si $s < 0$ $y = 1$ si $s \geq 0$ |  |
| Seuil symétrique | $y = -1$ si $s < 0$ $y = 1$ si $s \geq 0$ |  |
| Linéaire | $y = s$ |  |
| Linéaire saturée | $y = 0$ si $s \leq 0$ $y = s$ si $0 \leq s \leq 1$ $y = 1$ si $s \geq 1$ |  |
| Linéaire saturée symétrique | $y = -1$ si $s < -1$ $y = s$ si $-1 \leq s \leq 1$ $y = 1$ si $s > 1$ |  |
| Linéaire positive | $y = 0$ si $s \leq 0$ $y = s$ si $s \geq 0$ |  |
| Sigmoïde | $y = \frac{1}{1 + e^{-s}}$ |  |
| Tangente hyperbolique | $y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$ |  |
| Compétitive | $y = 1$ si s maximum $y = 0$ autrement |  |

II.5.4.4 LE PERCEPTRON

Un réseau de neurones pour un neurone est appelé perceptron. Ils ont été introduits pour la première fois par Frank Rosenblatt dans les années 1950 et ont jeté les bases du développement ultérieur des réseaux de neurones artificiels. Il est composé d'une seule couche de neurones. Il s'agit d'un type de neurone simple qui prend plusieurs entrées pondérées, effectue une somme pondérée de ces entrées, ajoute un biais, puis applique une fonction d'activation pour produire une sortie. Il a été initialement développé pour résoudre des problèmes de classification binaire.

II.5.4.5 L'ARCHITECTURE DE RESEAUX DE NEURONES

L'organisation d'un réseau de neurones définit son comportement et joue un rôle essentiel dans son fonctionnement. Elle dépend de la disposition de ses couches et de la structure de ses connexions entre les neurones. Ces caractéristiques permettent de classifier les différentes classes ou types d'architectures neuronales. On distingue principalement deux grandes catégories : les réseaux de neurones à propagation directe (Feedforward) et les réseaux de neurones récurrents.

1. RESEAU NEURONES NON-BOUCLE « FEED FOR WARD »

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées, par composition des fonctions réalisées par chacun des neurones. Un réseau de neurones non bouclé est représenté graphiquement par un ensemble de neurones connectés entre eux. L'information circulant des entrées vers les sorties sans retour en arrière. C'est-à-dire, si l'on se déplace dans le réseau à partir d'un neurone quelconque en suivant les connexions, on ne peut pas revenir au neurone de départ. Les réseaux de neurones non bouclés sont des outils statiques, utilisés principalement pour effectuer des tâches d'approximation de fonctions non linéaires et de modélisation de processus non linéaires. [57], [58]

a. PERCEPTRON MONOCOUCHE « SLP »

Dans un perceptron monocouche, les neurones en entrée sont connectés de manière complète à d'autres neurones en sortie via une couche de poids ajustable. Les seules opérations permises pour ces neurones sont les opérations logiques ET, OU et NON. Ces opérations permettent uniquement de résoudre des problèmes linéairement séparables.

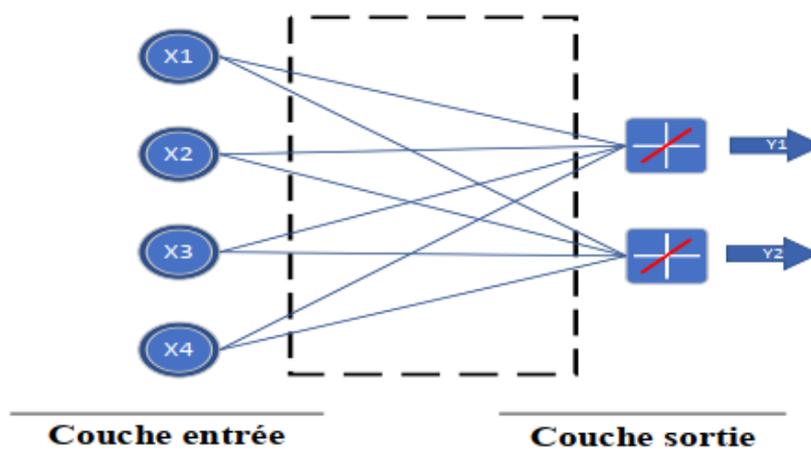


Figure II.17 : Le réseau monocouche [59]

b. LE PERCEPTRON MULTICOUCHES « PMC »

Les neurones sont disposés en couches dans un réseau de perceptron multicouche. Il n'existe pas de connexions entre les neurones d'une même couche ; les connexions sont établies uniquement avec les neurones des couches suivantes. Typiquement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante, ce qui permet de définir le sens de propagation de l'information à travers le réseau et ainsi de distinguer les neurones d'entrée et de sortie. Les couches constituées des neurones d'entrée et de sortie sont respectivement appelées couche d'entrée et couche de sortie. Les couches qui ne sont pas en contact avec l'extérieur sont appelées couches cachées.

Dans un réseau de neurones non récurrent, comme illustré dans la figure II.5, une structure fréquemment rencontrée comprend des entrées, deux couches de neurones cachés et des neurones de sortie. Il est important de noter que les neurones de la couche cachée ne sont pas connectés entre eux. Cette architecture est connue sous le nom de perceptron multicouches.

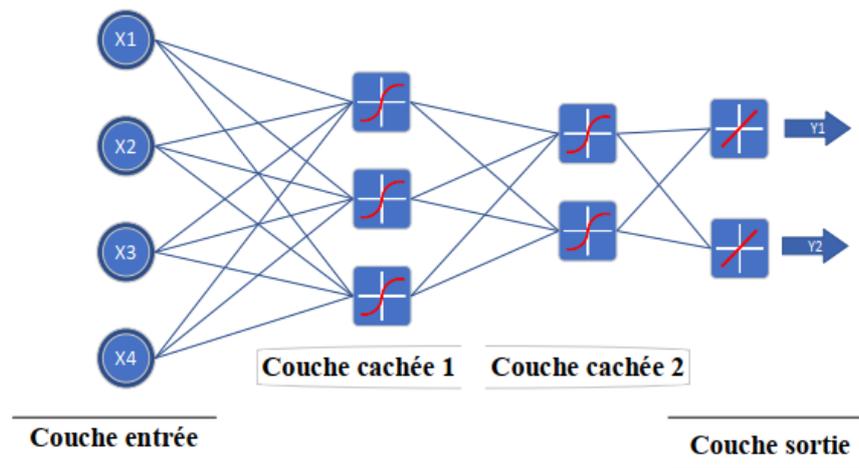


Figure II.18 : Schéma d'un réseau de neurones non bouclé (Perceptron multicouches) [59]

c. RESEAUX A FONCTION RADIALE « RBF »

Les réseaux à fonction radiale RBF sont très semblables à celle des PMC mais leur particularité est qu'ils sont caractérisés par l'utilisation des fonctions Gaussiennes comme fonctions de base [60]. À cause de son architecture, utilise le plus souvent la règle d'apprentissage de correction d'erreur et la règle par apprentissage compétitif. Il peut avoir un apprentissage qui combine en même temps l'apprentissage supervisé et l'apprentissage non supervisé. Il est caractérisé par un apprentissage plus rapide et plus simple. Ils sont utilisés dans les mêmes genres de problèmes que les PMC à savoir, en classification et en prédiction. [57]

2. RESEAUX DE NEURONES RECURRENTS « FEED-BACK »

Les réseaux de neurones récurrents (RNN) représentent une classe d'architectures spécialement conçues pour traiter des données séquentielles de manière efficace. Contrairement aux modèles classiques de réseaux de neurones où l'information circule uniquement de manière unidirectionnelle, de l'entrée vers la sortie (Feedforward), les RNN sont équipés d'une capacité unique à maintenir une forme de mémoire interne. Cette caractéristique leur permet de conserver des informations sur les séquences qu'ils traitent, ce qui s'avère particulièrement avantageux pour des tâches telles que la prédiction de séquences, la génération de séquences, la traduction automatique, l'analyse de sentiments, et bien d'autres applications encore.

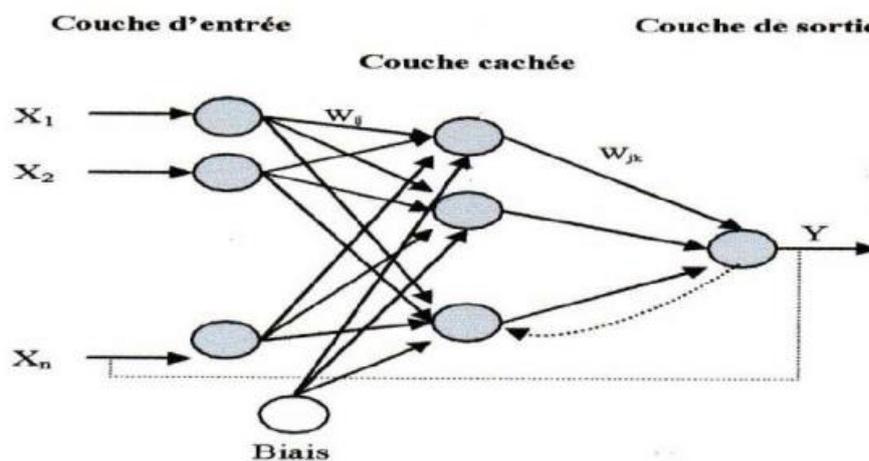


Figure II.19 : Architecture d'un réseau de neurones bouclé(récurrents) [61]

II.6 CONCLUSION

En conclusion, ce chapitre a fourni une base théorique solide sur les concepts et les algorithmes d'apprentissage automatique, nous plongeant ainsi dans l'univers de cette branche clé de l'intelligence artificielle. Nous avons exploré les divers types d'apprentissage tels que supervisé, non supervisé et par renforcement, mettant en lumière leur importance dans la résolution de problèmes variés. En mettant l'accent sur l'apprentissage supervisé, en particulier la classification et ses algorithmes, nous avons observé une palette étendue de méthodes, offrant ainsi aux professionnels un éventail de solutions pour différentes tâches, allant de la prédiction des défaillances industrielles à la correction des anomalies dans le processus.

Le chapitre suivant, consacré à l'étude de cas, appliquera ces concepts théoriques à un scénario pratique. Nous démontrerons comment les techniques et algorithmes décrits dans ce chapitre peuvent être utilisés pour prédire les défaillances dans un système industriel. Cette transition de la théorie à la pratique illustrera l'efficacité de l'apprentissage automatique dans un contexte réel.

CHAPITRE III

ETUDE DE CAS

III.1 INTRODUCTION

Dans l'industrie manufacturière moderne, prédire les pannes est crucial pour maximiser la productivité et minimiser les coûts de maintenance. L'apprentissage automatique de plus en plus utilisé, offre des avantages significatifs pour prévenir les arrêts non planifiés.

Ce chapitre examine son application à la fraiseuse verticale, un équipement critique souvent sujet à des interruptions coûteuses. Nous explorons comment les données opérationnelles en temps réel, combinées à des techniques comme la classification avec des réseaux neuronaux et les SVM, peuvent prédire les défaillances potentielles et améliorer les stratégies de maintenance, optimisant ainsi les opérations et garantissant la disponibilité et la fiabilité des machines.

III.2 SYSTEME TECHNIQUE ETUDIE

Dans notre étude, nous avons choisi le système technique incarné par une fraiseuse. Une fraiseuse représente un équipement essentiel dans le domaine de l'usinage, servant à façonner diverses pièces mécaniques, que ce soit en unité ou en série. Son fonctionnement repose sur le principe de l'enlèvement de matière à partir de blocs ou parfois d'ébauches préformées, grâce à un outil spécialisé appelé fraise. On distingue plusieurs catégories de fraiseuses telles que : horizontale, universelle, à programme commande numérique, verticale et spéciale. Dans notre étude de cas, nous avons opté pour l'utilisation de la fraiseuse verticale illustrée dans la figure III.1, C'est la plus courante où vous voyez l'outil de coupe dans une orientation verticale, c'est-à-dire (l'axe de la broche est perpendiculaire à la table). L'outil appuie contre la pièce fixe et enlève le matériau selon vos exigences de conception.[62] [63]



Figure III.1 : Fraiseuse verticale 380 V EMILGH-632

III.3 LES OUTILS DE DÉVELOPPEMENT

Au sein du développement en Python, trois outils essentiels se distinguent : Anaconda, le langage Python lui-même, et Jupyter. Ensemble, ces composants forment un ensemble harmonieux, offrant aux développeurs une puissante suite d'outils pour mener à bien une gamme diversifiée de projets, allant de l'apprentissage automatique à l'analyse de données, en passant par le développement web et bien d'autres domaines.

III.3.1 ANACONDA

Anaconda représente bien plus qu'une simple distribution de Python. Il se positionne comme une plateforme complète qui propose un environnement de développement intégré pour les langages Python et R. Grâce à ses fonctionnalités avancées, Anaconda simplifie grandement la gestion des paquetages et des environnements virtuels. Cette plateforme offre une solution pratique pour l'installation et la gestion de bibliothèques complexes telles que NumPy, SciPy, Pandas, Scikit Learn. Cette facilité d'utilisation en fait un choix privilégié pour les scientifiques des données et les développeurs spécialisés en apprentissage automatique.

III.3.2 PYTHON

Python est un langage de programmation populaire qui propose une grande variété d'applications. Toutes sortes de solutions techniques liées à Python. Python est un langage de programmation de haut niveau orienté objet. Orienté objet signifie que ce langage est basé sur des objets (tels que des données) plutôt que sur des fonctions, et haut niveau signifie qu'il est facile à comprendre pour les humains. [64]

Il est disponible gratuitement, est open source et fonctionne sur différentes plateformes. Il est aussi adapté aux différents types de données : valeurs numériques, chaînes, listes, n-uplets et dictionnaires... etc.

III.3.3 JUPYTER

Le Jupyter Notebook est la première application web conçue pour créer et partager des documents computationnels. Il offre une expérience simple, épurée et centrée sur le document. [65]

III.4 LES MEUSURES DE PERFORMANCES

Les mesures de performance sont essentielles dans l'évaluation des performances des algorithmes de classification en machine learning dans des contextes particuliers. La matrice de confusion offre une représentation visuelle des classifications réelles par rapport aux classifications prédites pour chaque classe de modèle.

- **True Positive (TP)** : La valeur réelle et la valeur prédite sont identiques. Les valeurs prédites et réelles étaient positives selon le modèle.
- **True Negative (TN)** : Les valeurs réelles et prédites coïncident. Les valeurs prévues et réelles étaient négatives selon le modèle.
- **False Positive (FP)** : L'estimation de la valeur est erronée. Contrairement à ce que prédisait le modèle, la valeur réelle est négative.
- **False Negative (FN)** : La valeur n'est pas celle prévue. Alors que le modèle prévoyait une valeur négative, la valeur réelle était positive.

Ces métriques de performance, comprenant la précision, le rappel et le score F1, fournissent un moyen complet d'évaluer les performances des modèles dans la prédiction de nouveaux cas.

- **Precision** : C'est la précision qui nous indique combien de cas correctement prédits se sont avérés positifs.[66] Sa formule est :

$$\text{precision} = \frac{\text{TP}}{(\text{TP} + \text{FP})}$$

- **Recall** : ou bien rappel Il représente la capacité du modèle à prédire correctement les points positifs à partir des points positifs réels qui existent dans un ensemble de données. Plus le score de rappel est élevé, meilleur est le modèle d'apprentissage automatique pour identifier les exemples positifs et négatifs. Le score de rappel est une mesure utile du succès de la prédiction lorsque les classes sont très déséquilibrées [22] Sa formule est :

$$\text{Recall} = \frac{\text{TP}}{\text{FN} + \text{TP}}$$

- **Accuracy** : Aussi appelée exactitude, elle est une métrique de performance fréquemment utilisée en apprentissage automatique. Elle est définie comme le rapport des prédictions correctes, qu'elles soient positives ou négatives, à l'ensemble des observations. En d'autres termes, elle évalue dans quelle mesure le modèle parvient à prédire avec précision les résultats par rapport à toutes les prédictions qu'il a formulées. Sa formule est :

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

▪ **F1-Score** : Le F-score, une mesure courante en apprentissage automatique, combine à la fois la précision et le rappel d'un modèle. Il est calculé comme la moyenne harmonique de ces deux mesures. Cette métrique est largement utilisée pour évaluer les performances des systèmes de classification binaire, où les exemples sont catégorisés en 'positifs' ou 'négatifs'.

Sa formule est :

$$F1 - Score = 2 \frac{\text{Precision} \cdot \text{Recall}}{\text{precision} + \text{Recall}} = \frac{2TP}{2TP + FN + FP}$$

III.5 PARTIE EXPERIMENTALE

III.5.1 DESCRIPTION DE LA BASE DONNEES

Pour notre étude de cas sur la prédiction des pannes des systèmes mécaniques grâce à l'apprentissage automatique, nous avons importé une base de données de Kaggle concernant les fraiseuses verticales. Cette base de données a été organisée de façon à prendre en compte les principales variables liées à notre analyse. Dans lequel se compose de 9982 points de données stockés sous forme de lignes avec 10 caractéristiques en colonnes. Ci-dessous sont énumérées les colonnes avec leurs significations respectives :[67]

- **UID** : identifiant unique allant de 1 à 9982.
- **ID du produit** : composé d'une lettre L, M ou H pour les variantes de qualité de produit faible (50 % de tous les produits), moyenne (30 %) et élevée (20 %) et d'un numéro de série spécifique à la variante.
- **Type** : uniquement le type de produit L, M ou H de la colonne 2. Il est considéré comme des données catégorielle
- **Température de l'air [K]** : générée à l'aide d'un processus de marche aléatoire, ensuite normalisée à un écart type de 2 K autour de 300 K.
- **Température de processus [K]** : générée à l'aide d'un processus de marche aléatoire normalisé à un écart type de 1 K, ajouté à la température de l'air plus 10 K.
- **Vitesse de rotation [tr/min]** : calculée à partir d'une puissance de 2860 W, recouverte d'un bruit normalement réparti.
- **Couple [Nm]** : les valeurs de couple sont normalement réparties autour de 40 Nm avec un écart type à 10 Nm et aucune valeur négative.
- **Usure de l'outil [min]** : (panne et défaillance progressive d'un outil de coupe en raison d'un fonctionnement régulier) Les variantes de qualité H/M/L ajoutent 5/3/2 minutes d'usure à l'outil utilisé dans le processus.

- **Target** : La variable cible indique si une panne s'est produite pendant la période de surveillance du système ou non.
- **Type de défaillance (Failure Type)** : Indique si l'une des cinq modes de défaillance spécifiés s'est produite.

Les modes de défaillance comprennent :

- Aucune défaillance (No Failure)
- Défaillance d'usure de l'outil (Tool Wear Failure)
- Défaillance de dissipation thermique (Heat Dissipation Failure)
- Défaillance de puissance (Power Failure)
- Défaillance par surcharge (Overstrain Failure)

Pour une meilleure représentation des données et une vue d'ensemble des variables mesurées, voici un échantillon des observations extraites de la base de données :

Tableau III.1 : Échantillon de données de la base sur la fraiseuse verticale

| UDI | Product ID | Type | Air temperature [K] | Process temperature [K] | Rotational speed [rpm] | Torque [Nm] | Tool wear [min] | Target | Failure Type |
|------|------------|------|---------------------|-------------------------|------------------------|-------------|-----------------|--------|--------------------------|
| 1 | M14860 | M | 298.1 | 308.6 | 1551 | 42.8 | 0 | 0 | No Failure |
| 2 | L47181 | L | 298.2 | 308.7 | 1408 | 46.3 | 3 | 0 | No Failure |
| 3 | L47182 | L | 298.1 | 308.5 | 1498 | 49.4 | 5 | 0 | No Failure |
| .. | .. | .. | .. | .. | .. | .. | .. | .. | .. |
| 70 | L47249 | L | 298.9 | 309 | 1410 | 65.7 | 191 | 1 | Power Failure |
| 78 | L47257 | L | 298.8 | 308.9 | 1455 | 41.3 | 208 | 1 | Tool Wear Failure |
| 243 | L47422 | L | 298 | 308.2 | 1348 | 58.8 | 202 | 1 | Overstrain Failure |
| 3237 | M18096 | M | 300.8 | 309.4 | 1342 | 62.4 | 113 | 1 | Heat Dissipation Failure |
| .. | .. | .. | .. | .. | .. | .. | .. | .. | .. |
| 9980 | M24857 | M | 299 | 308.6 | 1645 | 33.4 | 22 | 0 | No Failure |
| 9981 | H39412 | H | 299 | 308.7 | 1408 | 48.5 | 25 | 0 | No Failure |
| 9982 | M24859 | M | 299 | 308.7 | 1500 | 40.2 | 30 | 0 | No Failure |

La description détaillée de la base de données des fraiseuses verticales offre une vue complète des variables mesurées et des défaillances associées, posant ainsi les fondements nécessaires à une compréhension approfondie du système étudié. Sur ce fondement robuste, la phase de prétraitement des données prend son essor.

III.5.2 PRETRAITEMENT DES DONNEES

Le processus de prétraitement des données comprend plusieurs phases essentielles qui garantissent la qualité et l'efficacité des modèles de machine learning, donc nous les avons regroupées dans le logigramme suivant :

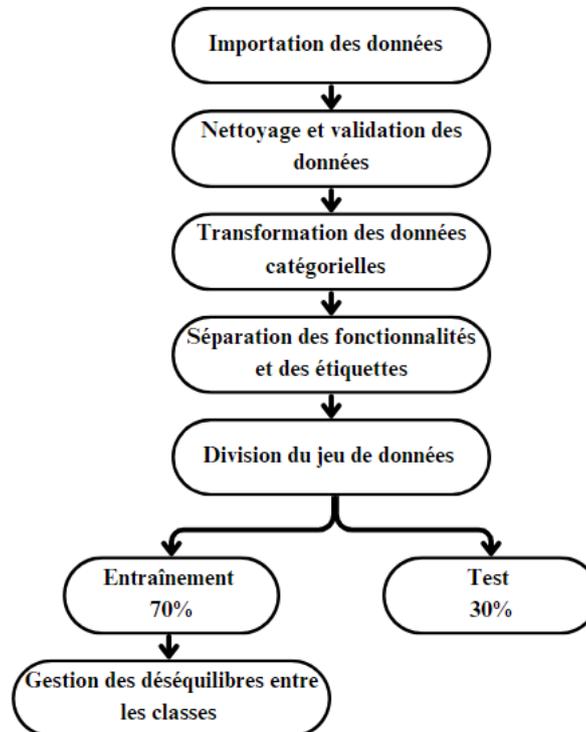


Figure III.2 : Les étapes de prétraitement des données

- **Importation des données** : Les données ont été importées à l'aide de la fonction `read_csv()` de Pandas à partir du fichier CSV. Cela nous a permis de charger les données tabulaires dans notre environnement de travail.
- **Nettoyage et validation des données** : Les colonnes non pertinentes ont été identifiées et supprimées après l'importation des données en utilisant la méthode `drop()` de Pandas. Ensuite, Les valeurs nulles et les doublons ont été vérifiés en utilisant les méthodes `isnull()` et `uplicated()` de Pandas. Les lignes contenant des valeurs nulles ou des doublons ont été éliminées à l'aide des méthodes `dropna()` et `drop_duplicates()`.
- **Transformation des données** : Nous avons également abordé la manipulation des données catégorielles (Type, Failure Type), en les convertissant en valeurs numériques pour les rendre compatibles avec les algorithmes d'apprentissage automatique. L'utilisation de données catégorielles, qui représentent des catégories particulières, peut représenter des difficultés lors de la création du modèle, car les algorithmes d'apprentissage automatique utilisent principalement des valeurs numériques. Le tableau III.2 représente le codage des données catégorielles.

Tableau III.2 : Codage des données catégorielles

| Les données catégorielles | Codage |
|---------------------------|--------|
| Failure Type | |
| No Failure | 0 |
| Heat dissipation Failure | 1 |
| Power Failure | 2 |
| Overstrain Failure | 3 |
| Tool Wear Failure | 4 |
| Type | |
| L | 2 |
| M | 3 |
| H | 5 |

▪ **Division du jeu de données** : Une fois le nettoyage effectué, nous avons séparé les fonctionnalités (Air temperature [K], Tool wear [min]) et les étiquettes (Failure Type). Ensuite, L'ensemble de données a été divisé en ensembles d'entraînement et de test en utilisant la fonction `train_test_split()` de Scikit-learn, en spécifiant un ratio de 20 % pour les données de test et de 80 % pour les données d'entraînement. Cela nous a permis d'évaluer les performances de notre modèle sur des données indépendantes.

▪ **Gestion des déséquilibres entre les classes** : Après avoir séparé les fonctionnalités et les étiquettes, la technique SMOTE a été appliquée à l'aide de la bibliothèque `imbalanced-learn` en Python pour équilibrer les classes des étiquettes. Réduisant ainsi le biais envers la classe dominante et améliorant les performances du modèle.

Comme le montrent les graphiques ci-après, le premier représentant les classes déséquilibrées et le second illustrant les classes équilibrées après utilisation de la technique SMOTE, le nombre d'instances pour chaque classe a été ajusté à 6757. Cela offre une représentation plus équitable de toutes les classes lors de l'entraînement du modèle.

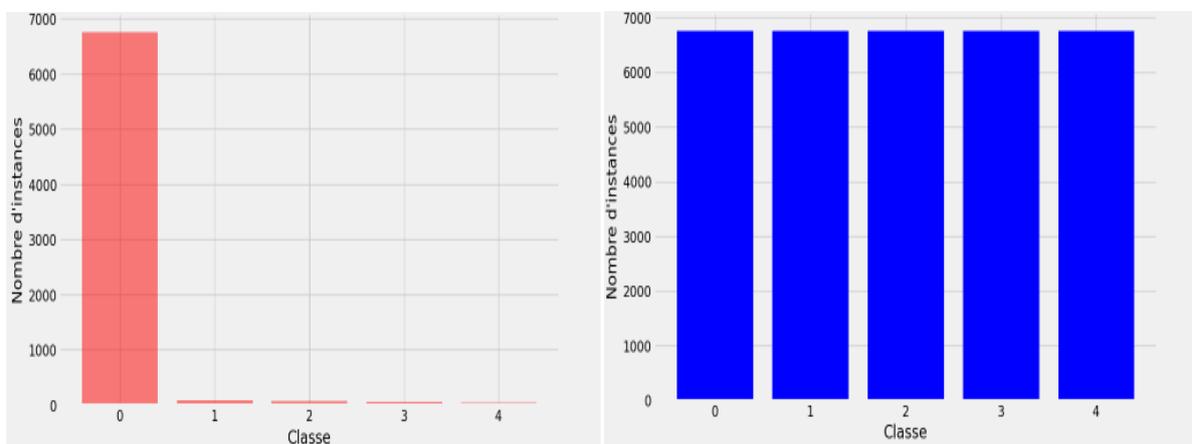


Figure III.3 : Nombre d'instances par classe avant et après utilisation de la technique SMOTE

III.5.3 CREATION DU MODELE

Pour cette étude, deux algorithmes de machine learning ont été utilisés : SVM et ANN, dans le but de réaliser une analyse approfondie de notre cas. Après le prétraitement et la division des données, Python et des bibliothèques robustes telles que "Scikit-learn" ont été employés pour créer et entraîner les modèles. Les algorithmes SVM et ANN ont été ajustés avec les données d'apprentissage, puis testés avec les données de test pour évaluer la précision des prédictions. Enfin, les performances des modèles ont été comparées afin de recommander la méthode la plus précise pour prédire l'état de la fraiseuse. La figure III.4 illustre les étapes suivies dans la création et l'évaluation des modèles.

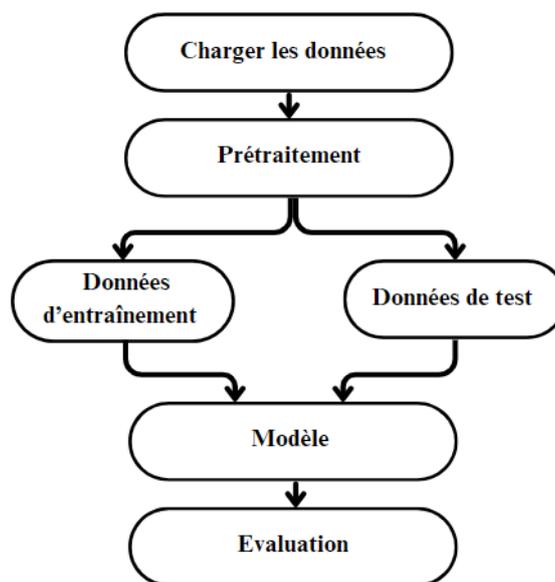


Figure III.4 : Construction du modèle

III.5.3.1 MODELE MACHINE A VECTEURS DE SUPPORT (SVM)

1. IMPLEMENTATION EN PYTHON :

Après avoir complété le nettoyage, la validation et la préparation des données, nous avons procédé à la création d'un modèle SVM (Support Vector Machine) utilisant un noyau linéaire. Le SVM est un algorithme d'apprentissage supervisé largement utilisé pour la classification et la régression.

Pour mettre en place notre modèle SVM, nous avons utilisé la classe SVC (Support Vector Classifier) de la bibliothèque scikit-learn. En choisissant un noyau linéaire, notre modèle cherche à trouver la meilleure séparation linéaire entre les différentes classes dans l'espace des caractéristiques.

Une fois que le modèle a été initialisé et entraîné, nous avons entrepris d'évaluer ses performances en utilisant diverses métriques telles que la précision, le rappel, le F-score, etc. Cette évaluation nous permet de comprendre le comportement de notre modèle SVM linéaire sur notre ensemble de test et de déterminer sa capacité à généraliser à de nouvelles données.

2. RESULTAT DE LA CLASSIFICATION POUR SVM

Cette section dévoile les résultats de la classification obtenus grâce au modèle SVM (Support Vector Machine). Après avoir entraîné notre modèle avec un noyau linéaire, nous explorons ici ses performances sur les données de test. La Figure III.5 illustre les résultats de cette classification

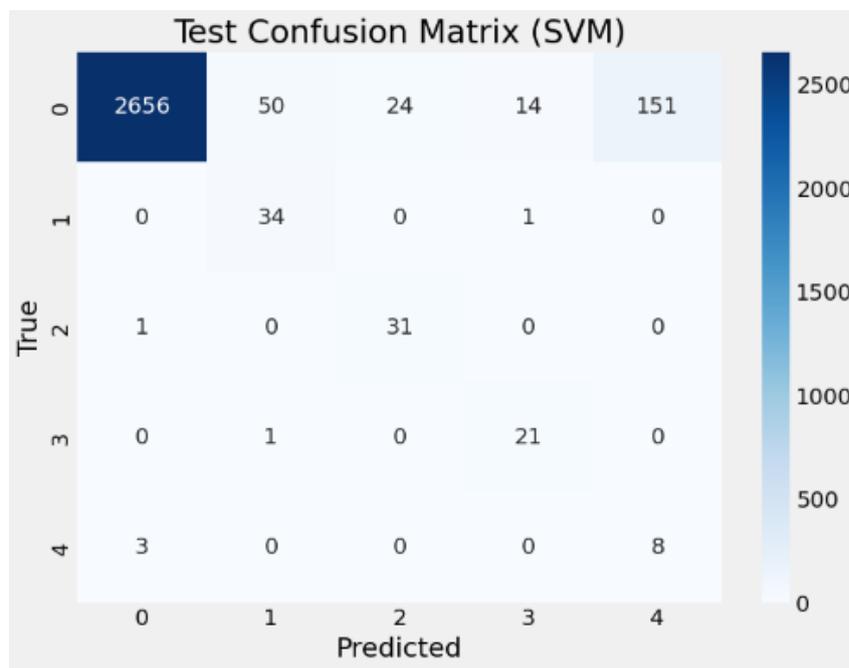


Figure III.5 : Matrice de confusion pour le classificateur SVM

La matrice de confusion fournit une représentation des résultats obtenus par un modèle de classification sur cinq classes distinctes. Chaque cellule de la matrice indique le nombre d'instances prédites comme appartenant à une classe spécifique par rapport à leurs classes réelles.

À partir de cette matrice, un résumé des performances de chaque classe a été élaboré dans un tableau III.3. Ce tableau synthétise les valeurs de True Positives (TP), True Negatives (TN), False Positives (FP) et False Negatives (FN), fournissant ainsi une évaluation détaillée de la capacité du modèle à classer correctement les instances de chaque classe.

Tableau III.3 : Performance de classification par classe pour le modèle SVM

| Classe | TP | TN | FP | FN |
|-------------------------------------|------|------|----|-----|
| 0 = No Failure | 2656 | 95 | 4 | 219 |
| 1 = Heat Dissipation Failure | 34 | 2939 | 51 | 1 |
| 2 = power Failure | 31 | 2923 | 24 | 1 |
| 3 = Oversrain Failure | 21 | 2978 | 15 | 1 |
| 4 = Tool Wear Failure | 8 | 2999 | 16 | 3 |

Il ressort de ce tableau que le modèle SVM a une excellente performance pour prédire la classe majoritaire "No Failure", avec 2656 instances correctement identifiées (True Positives). Cependant, il y a des confusions notables, comme 4 instances de "No Failure" prédites incorrectement comme appartenant à d'autres classes (False Positives), ainsi que 219 instances de "No Failure" incorrectement prédites comme n'appartenant pas à cette classe (False Negatives). Les classes minoritaires montrent des résultats variés : la classe 1 ("Heat Dissipation Failure") et la classe 2 ("Power Failure") sont relativement bien prédites, avec respectivement 34 et 31 instances correctement identifiées (True Positives), mais avec également 1 faux négatif chacune. En revanche, la classe 4 ("Tool Wear Failure") montre une performance plus faible, avec seulement 8 instances correctement prédites, et 3 faux négatifs. En se basant sur ces résultats, nous avons calculé les mesures de performance pour une évaluation approfondie du modèle. Ces mesures fournissent des indicateurs précis sur la qualité des prédictions du modèle. Le tableau III.4 ci-dessous présente les mesures de performance du modèle SVM avec un noyau linéaire.

Tableau III.4 : Mesures des performances du modèle SVM

| Mesures | SVM (kernal= linéaire) |
|-------------------------|------------------------|
| Accuracy (L'exactitude) | 91,81 % |
| Precision (Précision) | 50,81 % |
| Recall (Rappel) | 90,80 % |
| F1-score (F-mesure) | 59,21 % |

III.5.3.2 MODELE RESEAU NEURONES (ANN)

1. IMPLEMENTATION EN PYTHON

Après avoir complété les étapes prétraitement, validation et préparation des données, un nouveau modèle a été introduit dans le pipeline d'apprentissage automatique. Le MLPClassifier (Multi-Layer Perceptron), une implémentation de réseaux de neurones artificiels dans la bibliothèque scikit-learn en python, offre une approche différente de la classification. En configurant les paramètres, tels que `hidden_layer_sizes= (100,)`, `activation='relu'`, `solver='adam'`,

et `random_state=42`, Cela signifie qu'il y a une seule couche cachée dans le réseau de neurones avec 100 neurones dans cette couche, utilisant la fonction d'activation ReLU et l'algorithme d'optimisation Adam. De plus, nous avons fixé la graine aléatoire à 42 pour garantir la reproductibilité des résultats. Après initialisation et l'entraînement du modèle `MLPClassifier`, le test de ce modèle sur les données de test a été effectué et ses performances ont été analysées pour évaluer sa capacité à généraliser à de nouvelles données.

2. RESULTAT DE LA CLASSIFICATION POUR ANN

Après avoir entraîné et testé le modèle ANN avec une couche cachée contenant 100 neurones, les résultats ont été obtenus sous la forme d'une matrice de confusion présentée dans la figure III.6.

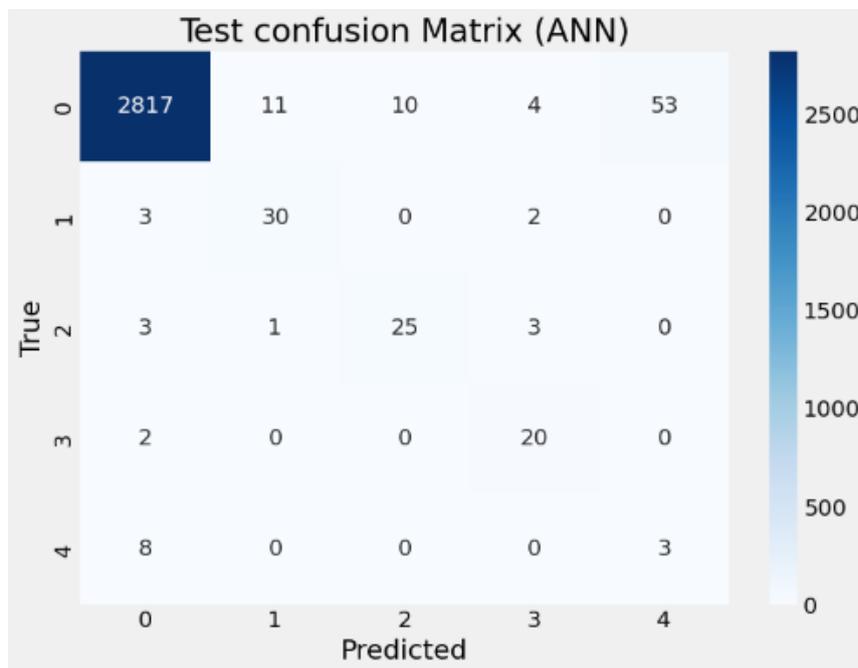


Figure III.6 : Matrice de confusion pour le classificateur ANN

À partir de cette matrice, les performances du modèle ANN avec une couche cachée contenant 100 neurones ont été résumées dans le Tableau III.5. Ce tableau présente les valeurs de Vrais Positifs (VP), Vrais Négatifs (VN), Faux Positifs (FP) et Faux Négatifs (FN), permettant ainsi une évaluation approfondie de sa capacité à classifier correctement les instances de chaque classe.

Tableau III.5 : Performance de classification par classe pour le modèle ANN

| Classe | TP | TN | FP | FN |
|-------------------------------------|------|------|----|----|
| 0 = No Failure | 2817 | 84 | 16 | 78 |
| 1 = Heat Dissipation Failure | 30 | 2938 | 12 | 5 |
| 2 = power Failure | 25 | 2943 | 10 | 7 |
| 3 = Oversrain Failure | 20 | 2955 | 9 | 2 |
| 4 = Tool Wear Failure | 3 | 2925 | 53 | 8 |

Les résultats du modèle ANN, comme présentés dans le tableau, mettent en lumière sa performance dans la prédiction des différentes classes. Tout d'abord, le modèle démontre une forte capacité à prédire la classe majoritaire "No Failure", avec 2817 instances correctement identifiées en tant que Vrais Positifs (VP). Néanmoins, des erreurs significatives sont également notables, telles que 16 instances de "No Failure" incorrectement prédites comme appartenant à d'autres classes (Faux Positifs), ainsi que 78 instances de "No Failure" faussement classées comme n'appartenant pas à cette classe (Faux Négatifs).

Pour les classes minoritaires, les performances varient. Les classes 1 ("Heat Dissipation Failure") et 2 ("Power Failure") affichent des résultats relativement solides, avec respectivement 30 et 25 instances correctement identifiées en tant que Vrais Positifs, accompagnées de quelques erreurs mineures. En revanche, la classe 4 ("Tool Wear Failure") montre une performance moindre, avec seulement 3 instances correctement prédites et 8 Faux Négatifs, indiquant une difficulté à détecter cette classe spécifique.

Ces observations fournissent une base pour évaluer la performance globale du modèle. Les mesures de performance, telles que la précision, le rappel et le F1-score, peuvent être calculées à partir de ces valeurs pour offrir une évaluation plus précise de l'efficacité du modèle ANN dans la classification des différentes classes.

Tableau III.6 : Les Mesures des performances du modèle ANN

| Mesures | MLPClassifier (ANN) |
|------------------------------|---------------------|
| Accuracy (L'exactitude) | 96,66 % |
| Precision (Précision) | 62,01 % |
| Recall (Rappel) | 75,80 % |
| F1-score (F-mesure) | 65,81 % |

III.5.4 ÉVALUATION DES MODELES

L'évaluation des méthodes d'apprentissage automatique constitue une étape cruciale de notre processus. Les performances des deux classificateurs, obtenues lors de l'étape précédente, sont consolidées dans le Tableau III.7.

Tableau III.7 : Tableau comparatif entre les deux modèles

| Mesures | SVM (kernel= linéaire) | MLPClassifier (ANN) |
|-------------------------|------------------------|---------------------|
| Accuracy (L'exactitude) | 91,81 % | 96,66 % |
| Precision (Précision) | 50,81 % | 62,01 % |
| Recall (Rappel) | 90,80 % | 75,80 % |
| F1-score (F-mesure) | 59,21 % | 65,81 % |

Dans l'évaluation des modèles SVM et MLPClassifier (ANN) pour la prédiction des pannes de systèmes mécaniques, une analyse approfondie des performances de chaque modèle a été réalisée. En examinant les mesures de performance telles que l'exactitude, la précision, le rappel et le F1-score consolidées dans le Tableau III.7, ainsi que les matrices de confusion établies sur chaque classe, des observations significatives sont constatées. Le modèle MLPClassifier (ANN) 9a eu un avantage sur le modèle SVM, présentant une exactitude globale plus élevée et de meilleures performances dans la plupart des mesures d'évaluation.

Cependant, il est essentiel de se concentrer sur les performances par classe. Dans cette optique, le modèle SVM a démontré une meilleure capacité à classifier les classes minoritaires par rapport à l'ANN, se traduisant par des taux de faux négatifs (FN) plus faibles. Par conséquent, il existe une probabilité accrue que l'ANN produise des classifications incorrectes pour les classes minoritaires. Dans le cadre de la maintenance industrielle, où la transparence des décisions est tout aussi cruciale que la précision des prédictions, le modèle SVM se distingue par sa capacité à offrir un équilibre satisfaisant entre précision et interprétabilité. Avec des performances solides en termes de précision et un caractère explicite de ses frontières de décision, le modèle SVM est en mesure de fournir des prédictions précises et facilement compréhensibles, essentielles pour la prise de décision en maintenance.

III.5.5 VALIDATION DU MODELES

Pour valider les modèles SVM et ANN déjà entraînés, nous avons utilisé la méthode `cross_val_score` de Scikit-learn avec 15 plis sur notre base de données. La validation croisée divise les données en plusieurs sous-ensembles (plis), puis entraîne et évalue le modèle sur différents sous-ensembles successivement. Cela permet d'estimer la performance du modèle sur des données non vues et d'évaluer sa capacité à généraliser. Les données ont été préalablement normalisées pour garantir des échelles comparables entre les caractéristiques.

Le tableau ci-dessous récapitule les scores de validation croisée pour les modèles ANN et SVM.

Tableau III.8 : Les scores de validation croisée pour les modèles ANN et SVM

| Plis | Score de validation croisée (ANN) % | Score de validation croisée (SVM) % |
|----------------|-------------------------------------|-------------------------------------|
| 1 | 99.467 | 97.736 |
| 2 | 99.556 | 98.624 |
| 3 | 99.556 | 98.313 |
| 4 | 99.600 | 98.579 |
| .. | .. | .. |
| 12 | 99.644 | 98.623 |
| 13 | 99.511 | 98.534 |
| 14 | 99.245 | 98.268 |
| 15 | 99.333 | 97.779 |
| Moyenne | 99.508 | 98.289 |

Pour le modèle SVM, configuré avec un noyau linéaire, les scores de précision ont été calculés pour chaque pli. Les résultats montrent une précision moyenne de 98,289%, avec un écart-type de 0,315. Pour le modèle ANN, les scores de précision ont également été calculés, montrant une précision moyenne de 99,508%, avec un écart-type de 0,137.

Ces résultats confirment que les modèles SVM et ANN maintiennent des performances élevées et stables, renforçant leur capacité à généraliser efficacement sur de nouvelles données.

III.5.6 MISE EN ŒUVRE

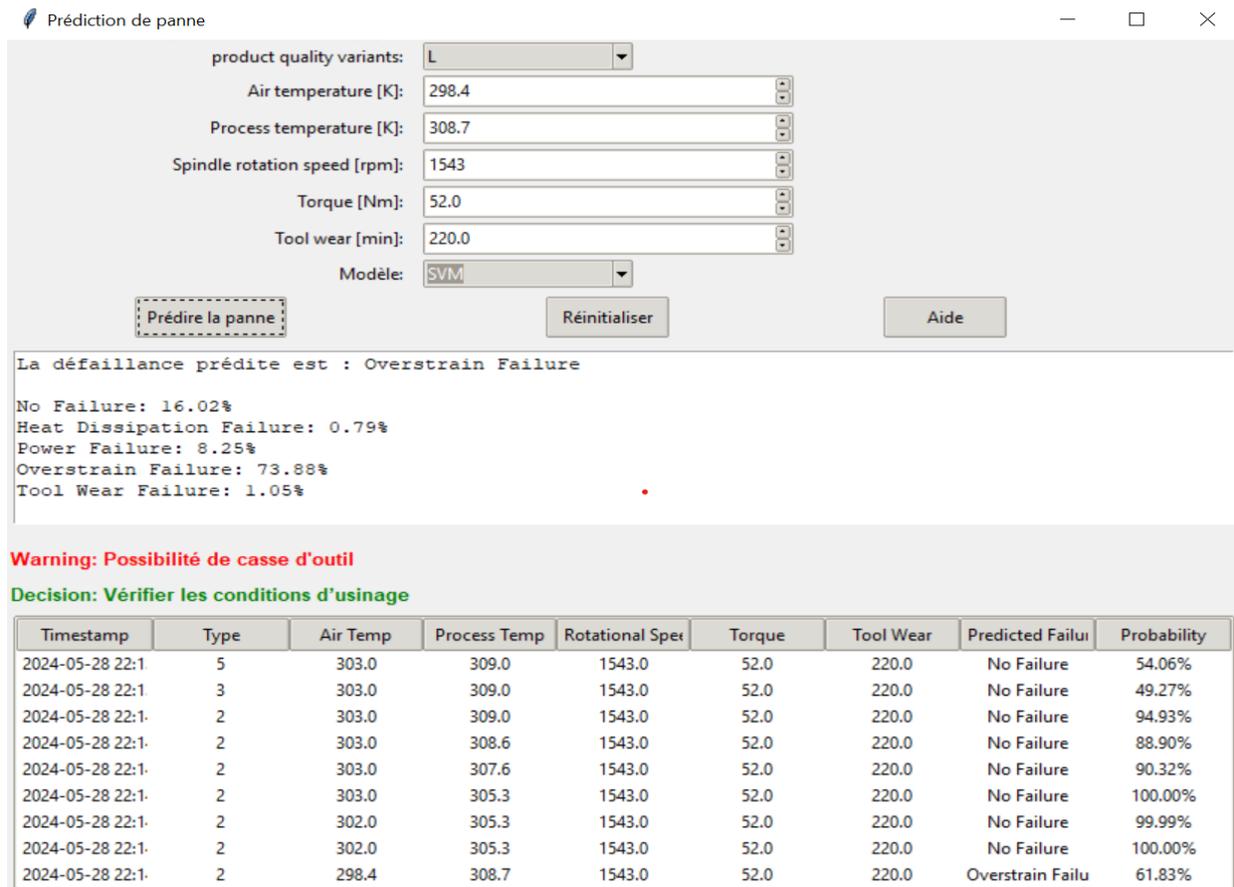
Après avoir calculé les mesures de performance et connu les faiblesses et les forces pour chacun des modèles SVM et ANN, nous avons commencé à programmer une application qui fait la prédiction des défaillances liées à la fraiseuse verticale à l'aide de l'interface graphique Tkinter. L'application commence par charger des modèles SVM et ANN pré-entraînés et un scaler, tous trois stockés dans des fichiers externes, grâce à la bibliothèque Joblib. Cette étape est réalisée à l'aide des commandes `joblib.load('svm_model.pkl')`, `joblib.load('mlp_model.pkl')` et `joblib.load('scaler.joblib')`, entourées d'un bloc try-except pour gérer les erreurs de fichier introuvables.

Pour permettre à l'utilisateur de choisir entre les modèles SVM et ANN pour la prédiction des défaillances, un menu déroulant a été intégré à l'interface utilisateur de l'application Tkinter. Ce menu déroulant, implémenté à l'aide d'un `tkk.ComboBox`, présente les options "SVM" et "ANN". L'utilisateur peut sélectionner le modèle souhaité directement depuis l'interface.

Ensuite, l'application utilise Pandas pour structurer et préparer les données saisies par l'utilisateur. L'interface Tkinter comprend des spinboxes pour les entrées de caractéristiques telles que la température de l'air, la température du processus, la vitesse de rotation, le couple et l'usure de l'outil. Les spinboxes sont créées avec `tkk.Spinbox` et disposées dans une grille, avec des étiquettes descriptives pour chaque caractéristique.

En plus des spinboxes, un menu déroulant (ttk.Combobox) permet à l'utilisateur de sélectionner le type de pièce parmi les options "L", "M" et "H". La valeur sélectionnée est ensuite mappée à une valeur numérique via un dictionnaire pour être utilisée dans le modèle. Une fois que l'utilisateur a entré les données et déclenché la prédiction en appuyant sur un bouton, les valeurs saisies sont récupérées et organisées dans un DataFrame Pandas. Ces données sont ensuite normalisées à l'aide du scaler précédemment chargé avec la méthode transform. Les modèles SVM et ANN prédisent alors la classe de défaillance et les probabilités associées pour chaque classe en utilisant les méthodes predict et predict_proba. Les résultats de la prédiction, y compris la classe de défaillance prédite et ses probabilités, sont affichés dans une zone de texte pour informer l'utilisateur. Les probabilités de chaque classe sont également affichées pour fournir une compréhension plus détaillée de la prédiction.

Des avertissements et recommandations spécifiques sont fournis en fonction de la défaillance prédite, avec des messages d'avertissement et des décisions à prendre affichés en conséquence. Par exemple, une "Overstrain Failure" déclenchera un avertissement concernant la possibilité de casse d'outil et recommandera de vérifier les conditions d'usage. Enfin, un historique des prédictions est maintenu et affiché dans un tableau Treeview pour une référence ultérieure. Chaque entrée de l'historique inclut les caractéristiques saisies, la défaillance prédite et les probabilités. Cela permet à l'utilisateur de suivre et d'analyser les prédictions passées pour des prises de décision plus informées. La figure suivante montre l'interface de l'application avec ses différentes composantes.



Figures III.7 : Interface de l'application de prédiction des défaillances de la fraiseuse verticale

• RESULTATS DE TEST DE L'APPLICATION

Pour évaluer les performances de l'application, nous avons effectué plusieurs tests avec des configurations variées des paramètres d'entrée. Les résultats sont présentés dans le tableau ci-dessous :

Tableau III.9 : Résultats de test

| Product Quality | Air Temp | Process temp | Spindle rotation | Torque | Tool wear | Predicted failure (SVM) | Probability (SVM) | Predicted failure (ANN) | Probability (ANN) |
|-----------------|----------|--------------|------------------|--------|-----------|-------------------------|-------------------|-------------------------|-------------------|
| 2.0 | 298.0 | 309.0 | 1357.0 | 43.0 | 200.0 | Tool wear failure | 70.11% | No Failure | 64.05% |
| 3.0 | 298.0 | 309.0 | 1357.0 | 43.0 | 200.0 | Tool wear failure | 84.49% | No Failure | 51.40% |
| 5.0 | 298.0 | 309.0 | 1357.0 | 43.0 | 200.0 | No Failure | 89.75% | No Failure | 98.78% |
| 2.0 | 300.0 | 310.0 | 1466.0 | 54.0 | 210.0 | Overstrain Failure | 99.63% | Overstrain Failure | 99.88% |
| 3.0 | 300.0 | 310.0 | 1466.0 | 54.0 | 210.0 | No Failure | 92.64% | No Failure | 99.87% |
| 5.0 | 300.0 | 310.0 | 1466.0 | 54.0 | 210.0 | No Failure | 80.64% | No Failure | 99.89% |
| 2.0 | 300 | 308 | 1762 | 53 | 111 | Power Failure | 55.31% | Power Failure | 99.82% |
| 3.0 | 300 | 308 | 1762 | 53 | 111 | Power Failure | 97.26% | Power Failure | 100% |

| | | | | | | | | | |
|-----|-------|-------|--------|------|-------|--------------------------|--------|-------------------|--------|
| 5.0 | 300 | 308 | 1762 | 53 | 111 | No Failure | 99.74% | Power Failure | 100% |
| 2.0 | 303.3 | 309.9 | 1474.8 | 50.9 | 220 | Heat Dissipation Failure | 59.86% | No Failure | 100% |
| 3.0 | 303.3 | 309.9 | 1474.8 | 50.9 | 220 | Heat Dissipation Failure | 99.19% | No Failure | 100% |
| 2.0 | 302.0 | 308.4 | 1599.1 | 10 | 222 | No Failure | 99.83% | No Failure | 100% |
| 3.0 | 302.0 | 308.4 | 1599.1 | 10 | 222 | No Failure | 97.64% | No Failure | 100% |
| 5.0 | 302.0 | 308.4 | 1599.1 | 10 | 222 | No Failure | 98.42% | No Failure | 99.32% |
| 2.0 | 303.3 | 310.6 | 1577.8 | 54.0 | 224.4 | Power Failure | 65.08% | No Failure | 89.43% |
| 3.0 | 303.3 | 310.6 | 1577.8 | 54.0 | 224.4 | Power Failure | 60.93% | Power Failure | 99.96% |
| 5.0 | 303.3 | 310.6 | 1577.8 | 54.0 | 224.4 | No Failure | 93.46% | Power Failure | 100% |
| 3.0 | 302.8 | 309.8 | 1529.5 | 22.0 | 220 | Tool wear failure | 88.23% | No Failure | 100% |
| 5.0 | 302.8 | 309.8 | 1529.5 | 22.0 | 220 | Tool wear failure | 55.37% | No Failure | 99.67% |
| 2.0 | 298.3 | 308.3 | 1567.5 | 47 | 249.8 | Overstrain Failure | 86.46% | No Failure | 70.95% |
| 3.0 | 298.3 | 308.3 | 1567.5 | 47 | 249.8 | Tool wear failure | 95.65% | No Failure | 91.81% |
| 5.0 | 298.3 | 308.3 | 1567.5 | 47 | 249.8 | Tool wear failure | 99.07% | Tool wear failure | 99.41% |
| 2.0 | 300.8 | 311.5 | 2004.3 | 55.0 | 266.0 | Power Failure | 61.08% | Power Failure | 100% |
| 3.0 | 300.8 | 311.5 | 2004.3 | 55.0 | 266.0 | Power Failure | 75.23% | Power Failure | 100% |

Les résultats des tests de l'application de prédiction des défaillances d'une fraiseuse verticale, basée sur les modèles SVM et ANN, mettent en lumière les performances et les caractéristiques distinctives de chaque modèle.

Le modèle SVM démontre une capacité remarquable à prédire un large éventail de défaillances, couvrant des scénarios allant de l'usure de l'outil à la surcharge, aux pannes de courant et aux défaillances de dissipation de chaleur. Sa robustesse dans la classification des défaillances en fonction de multiples paramètres opérationnels est clairement visible, tout comme sa capacité à prédire avec précision même dans des conditions opérationnelles variées. Cette adaptabilité aux variations des paramètres opérationnels en fait un choix solide pour une application de maintenance prédictive dans un environnement industriel dynamique.

D'autre part, le modèle ANN présente également des performances prometteuses, notamment en ce qui concerne sa sensibilité accrue à certains types de défaillances, comme les défaillances de courant (Power Failure). Cette sensibilité peut être un atout majeur pour prédire rapidement des défaillances critiques et pour prendre des mesures correctives préventives. Cependant, le modèle

semble être moins capable de gérer la variabilité des données d'entrée, ce qui pourrait limiter sa précision dans des conditions opérationnelles complexes.

III.6 CONCLUSION

Ce chapitre a démontré l'utilisation des techniques de machine learning dans la prédiction des défaillances industrielles en créant une application qui fonctionne avec deux modèles : le SVM et le MLP. L'objectif de travailler avec deux modèles est de les comparer et de choisir le meilleur. Le modèle ML Classifier (ANN) surpasse le modèle SVM avec un noyau linéaire en termes de précision et d'exactitude globale. Cependant, le SVM montre un meilleur rappel et une meilleure performance pour certaines classes spécifiques. Ainsi, le choix du modèle approprié dépend des mesures de performance qui correspondent le mieux aux critères de l'application.

Cette approche marque une avancée significative dans la gestion proactive de la maintenance industrielle. Elle permet aux opérateurs de prendre des décisions éclairées grâce à des données fiables, augmentant ainsi la disponibilité des équipements, réduisant les coûts de maintenance et améliorant la sécurité des opérations. Les modèles développés offrent des prédictions précises des pannes, permettant de prévenir les défaillances critiques.

CONCLUSION GENERALE

La prévision des défaillances mécaniques est l'un des problèmes qui intéresse de nombreux chercheurs industriels en raison de son impact direct sur la fiabilité et la sécurité des systèmes. Ce mémoire explore les multiples facettes de l'intégration des technologies de l'Industrie 4.0, particulièrement axée sur la maintenance prédictive dans le domaine industriel. L'Industrie 4.0 marque un tournant décisif dans le paysage industriel, transformant les processus traditionnels par l'intégration de technologies avancées comme l'apprentissage automatique et l'analyse prédictive. Cette évolution vers une maintenance proactive et prédictive représente une avancée significative, permettant d'anticiper les défaillances des équipements, de réduire les coûts de maintenance et d'améliorer la sécurité et l'efficacité opérationnelle.

Les chapitres précédents ont mis en évidence l'importance de l'apprentissage automatique dans cette transformation. En introduisant des concepts clés et des algorithmes variés, nous avons démontré comment ces outils peuvent être appliqués pour résoudre des problèmes industriels concrets, notamment la prédiction des pannes. L'accent a été mis sur l'apprentissage supervisé qui offre des solutions adaptées à différents types de données et de besoins opérationnels.

La transition de la théorie à la pratique, illustrée par l'application de ces techniques à des cas spécifiques comme la maintenance prédictive des fraiseuses verticales, a confirmé l'efficacité de l'apprentissage automatique pour améliorer la fiabilité et la performance des équipements. En utilisant des données de fonctionnement en temps réel et des algorithmes d'apprentissage automatique comme les réseaux neuronaux et les machines à vecteurs de support (SVM), nous avons démontré comment il est possible de prédire les pannes avant qu'elles ne se produisent. Les résultats montrent une amélioration notable de la stratégie de maintenance, réduisant les temps d'arrêt et les coûts associés, tout en augmentant la fiabilité des équipements. Les modèles bien conçus peuvent fournir des prédictions précises, aidant ainsi les entreprises à optimiser leurs stratégies de maintenance et à maximiser la disponibilité de leurs machines.

Cependant, la mise en œuvre de ces technologies n'est pas sans défis. Des obstacles tels que la cybercriminalité, les lacunes en compétences internes et la résistance au changement doivent être surmontés pour réaliser pleinement le potentiel de l'Industrie 4.0. De futures recherches et développements se concentreront sur l'optimisation des modèles prédictifs et leur intégration avec des systèmes de collecte de données en temps réel, afin d'améliorer encore leurs capacités.

LISTE BIBLIOGRAPHIQUE :

- [1] V. Teigens, P. Skalfist, et D. Mikelsten, Intelligence artificielle : la quatrième révolution industrielle. Cambridge Stanford Books, 2020.
- [2] S. MERAGHNI, « La maintenance prédictive dans les usines intelligentes », PhD Thesis, Université de mohamed kheider biskra, 2021.
- [3] G. Zwingelstein, « La maintenance prédictive intelligente pour l'industrie 4.0 », Ref: TIP095WEB-“Maintenance, 2019.
- [4] W. Z. Khan, M. H. Rehman, H. M. Zangoti, M. K. Afzal, N. Armi, et K. Salah, « Industrial internet of things: Recent advances, enabling technologies and open challenges », Computers & Electrical Engineering, vol. 81, p. 106522, janv. 2020.
- [5] S. Madakam, V. Lake, V. Lake, et V. Lake, « Internet of Things (IoT): A literature review », Journal of Computer and Communications, vol. 3, n° 05, p. 164, 2015.
- [6] H. Boyes, B. Hallaq, J. Cunningham, et T. Watson, « The industrial internet of things (IIoT): An analysis framework », Computers in Industry, vol. 101, p. 1-12, oct. 2018.
- [7] C. Greer, M. Burns, D. Wollman, et E. Griffor, « Cyber-physical systems and internet of things », 2019.
- [8] E. Sisinni, A. Saifullah, S. Han, U. Jennehag, et M. Gidlund, « Industrial internet of things: Challenges, opportunities, and directions », IEEE transactions on industrial informatics, vol. 14, n° 11, p. 4724-4734, 2018.
- [9] N. Fourdaous, « L'industrie 4.0 : présentation d'une révolution numérique modifiant significativement le paysage de la production pharmaceutique », p. 101, déc. 2022.
- [10] A. Brahmia, « l'apprentissage en profond pour la cybersécurité dans l'Internet industriel des objets (IIoT) », Université de Guelma, Working Paper, 2022.
- [11] O. Cardin, W. Derigent, et D. Trentesaux, Digitalisation et contrôle des systèmes industriels cyber-physiques : Concepts, technologies et applications. ISTE Group, 2023.
- [12] O. Cardin, W. Derigent, et D. Trentesaux, Digitalization and Control of Industrial Cyber-Physical Systems : Concepts, Technologies and Applications. John Wiley & Sons, 2022.
- [13] B. Hopkins et al., « Expand your digital horizon with Big Data. Forrester Research », Inc. Reproduction Prohibited, vol. 30, 2011.
- [14] M. Karoui, G. Davauchelle, et A. Duzert, « Big data. Mise en perspective et enjeux pour les entreprises. », Ingénierie des Systèmes d'Inf., vol. 19, n° 3, p. 73-92, 2014.
- [15] H. Pacha et M. Taha, « Vers une coordination transparente entre le Cloud Computing et le Fog Computing », Thesis, Université laarbi tebessi tebessa, 2020.
- [16] S. Sadik, « La protection des données dans les contrats de cloud computing », phdthesis, Université de Perpignan, 2023.

- [17] C. El Zant, « Industrie 4.0 processus – Quel modèle pour une intégration réussie », phdthesis, HESAM Université, 2021.
- [18] M. Ghobakhloo, « The future of manufacturing industry: a strategic roadmap toward Industry 4.0 », *Journal of Manufacturing Technology Management*, vol. 29, n° 6, p. 910-936, janv. 2018, doi: 10.1108/JMTM-02-2018-0057.
- [19] I. GHAMRI et M. AMIAR, « Les approches de la maintenance prédictive intelligente dans l'industrie 4.0 », université Badji Mokhtar – Annaba, 2021.
- [20] D. Wu, C. Jennings, J. Terpeny, R. X. Gao, et S. Kumara, « A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests », *Journal of Manufacturing Science and Engineering*, vol. 139, n° 071018, avr. 2017.
- [21] J. Mattioli, P.-O. Robic, et T. Reydellet, « L'intelligence artificielle au service de la maintenance prévisionnelle », in 4ème conférence sur les Applications Pratiques de l'Intelligence Artificielle APIA2018, Nancy, France, juill. 2018.
- [22] M. Jemmali, « Maintenance prédictive pour une turbine de puissance en utilisant des algorithmes d'apprentissage machine », masters, École de technologie supérieure, 2021.
- [23] Y. Lei, N. Li, S. Gontarz, J. Lin, S. Radkowski, et J. Dybala, « A Model-Based Method for Remaining Useful Life Prediction of Machinery », *IEEE Transactions on Reliability*, vol. 65, n° 3, p. 1314-1326, sept. 2016.
- [24] M. Baptista, S. Sankararaman, Ivo. P. de Medeiros, C. Nascimento, H. Prendinger, et E. M. P. Henriques, « Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling », *Computers & Industrial Engineering*, vol. 115, p. 41-53, janv. 2018.
- [25] P. Henriquez, J. B. Alonso, M. A. Ferrer, et C. M. Travieso, « Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals », *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 44, n° 5, p. 642-652, mai 2014.
- [26] A. Alaoui Belghiti, « Prédiction de situations anormales par apprentissage automatique pour la maintenance prédictive : approches en transport optimal pour la détection d'anomalies », These de doctorat, université Paris-Saclay, 2021.
- [27] K. Ilyes, « Diagnostic des machines tournantes par les techniques de l'intelligence artificielle », Université Badji Mokhtar de Annaba, Département de Génie Mé, 2014.
- [28] J. Heng, *Pratique de la maintenance préventive - 4e éd.* Dunod, 2017.
- [29] B. Fouzi, « Diagnostic et détection des défauts mécaniques affectant les systèmes électromécaniques », Université Badji Mokhtar Annaba, 2019.

- [30] « L'Analyse Par Thermographie Infrarouge », Scribd. Disponible sur : <https://fr.scribd.com/document/544521368/4-5830330302303570809>
- [31] L. DE MATTEIS, S. JANNY, S. NATHAN, et W. SHU-QUARTIER, « Introduction à l'apprentissage automatique ».
- [32] P.-A. Leboeuf, « Introduction à l'apprentissage automatique en pharmacométrie : concepts et applications », nov. 2021.
- [33] D. Sarkar, R. Bali, et T. Sharma, Practical Machine Learning with Python: A Problem-Solver's Guide to Building Real-World Intelligent Systems. Apress, 2017.
- [34] T. M. Mitchell, Machine Learning. McGraw-Hill, 1997.
- [35] E. Alpaydin, Introduction to Machine Learning. MIT Press, 2004.
- [36] W.-B. A. B. Zoungrana, « Application des algorithmes d'apprentissage automatique pour la détection de défauts de roulements sur les machines tournantes dans le cadre de l'Industrie 4.0 », masters, Université du Québec à Chicoutimi, Chicoutimi, 2020.
- [37] O. Mehdi, « Classification d'objets avec le Deep Learning », Mémoire Master, université de Bouira.
- [38] G. Zaccone, M. R. Karim, et A. Menshawy, Deep Learning with TensorFlow. Packt Publishing Ltd, 2017.
- [39] E. Biernat et M. Lutz, Data science : fondamentaux et études de cas : Machine learning avec Python et R. Eyrolles, 2015.
- [40] B. Nora et B. Fatiha, « Application des reseaux de neurones à la détection et la classification des défauts dans les machines tournantes », Université Mouloud Mammeri, 2010.
- [41] L. D. Matteis, « Introduction à l'apprentissage ».
- [42] R. Raphaël, « Réduction de dimensionnalité ».
- [43] H. Bellahmer, « Implémentation et évaluation d'un modèle d'apprentissage automatique pour l'estimation de la valeur marchande de propriétés immobilières », Université Mouloud Mammeri, 2020.
- [44] R. Russell, Machine Learning: Step-by-step guide to implement machine learning algorithms with python. 2018.
- [45] I. I. Taweh Beysolow, Introduction to Deep Learning Using R: A Step-by-step Guide to Learning and Implementing Deep Learning Models Using R. Apress, 2017.
- [46] R. Mifdal, « Application des techniques d'apprentissage automatique pour la prédiction de la tendance des titres financiers », masters, École de technologie supérieure, Montréal, 2019.
- [47] M. Swamynathan, Mastering Machine Learning with Python in Six Steps: A Practical Implementation Guide to Predictive Data Analytics Using Python. Apress, 2017.

- [48] J. Olivares, « Scaling out-of-core k-nearest neighbors computation on single machines », phdthesis, Université de Rennes, 2016.
- [49] D. Sharma, « Step by Step Machine Learning: K Nearest Neighbours », Medium.
- [50] M. Hasan et F. Boris, « Svm: Machines à vecteurs de support ou séparateurs à vastes marges », Rapport technique, Versailles St Quentin, France. Cité, vol. 64, 2006.
- [51] L. Redouane, « Application des SVMS pour la reconnaissance d'extrasystoles », Université Mouloud Mammeri, 2015.
- [52] F. Zaiz, « Les Supports Vecteurs Machines (SVM) pour la reconnaissance des caractères manuscrits arabes », Thesis, 2010.
- [53] L. Redouane, « Application des SVMS pour la reconnaissance d'extrasystoles », Université Mouloud Mammeri, 2015.
- [54] M. Hasan et F. Boris, « SVM : Machines à Vecteurs de Support ou Séparateurs à Vastes Marges ».
- [55] K. MAIZ Ibrahim, « Classification automatique des arythmies cardiaque en utilisant les ondelettes et les SVM », 2021.
- [56] N. Leroux, « Artificial neural networks with radio-frequency spintronic nano-devices », phdthesis, Université Paris-Saclay, 2022.
- [57] M. C. eddine Laoubi, « Contrôle d'un pendule inversé par un réseau de neurones artificiels », Thesis, université Akli Mouhend-Oulhadj de Bouira, 2018.
- [58] G. Dreyfus et al., Réseaux de Neurones : Méthodologie et Applications. 2002.
- [59] Y. Djeriri, « Les Réseaux de Neurones Artificiels », 2017.
- [60] E. M. Brakni, Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM. Université du Québec en Abitibi-Témiscamingue (Canada), 2011.
- [61] Y. Ben Youcef, « Simulation par les réseaux de neurones du comportement dynamique d'un réacteur continu parfaitement agité », Thesis, UNIVERSITE KASDI MERBAH OUARGLA, 2020.
- [62] Rapiddirect, « Comprendre les différences entre le fraisage horizontal et vertical ». Disponible sur : <https://www.rapiddirect.com/fr/blog/horizontal-vs-vertical-milling/>.
- [63] S. Khaldi et S. Sekiou, « Élaboration d'un plan de maintenance préventive d'une machine de fraisage. », Thesis, 2021.
- [64] « Learn R, Python & Data Science Online ». Disponible sur: <https://www.datacamp.com/blog/all-about-python-the-most-versatile-programming-language>).
- [65] « Project Jupyter ». Disponible sur : <https://jupyter.org>.
- [66] W. S.-B. S. Provider, « Confusion Matrix in Python ». Disponible sur : <https://ris-ai.com>

[67] « Kaggle: Your Machine Learning and Data Science Community ». Disponible sur:
<https://www.kaggle.com/>

ملخص

تتناول هذه الأطروحة تطبيق الصيانة التنبؤية في سياق الصناعة 4.0، مع التركيز على استخدام تقنيات التعلم الآلي للتنبؤ بالفشل. يتم عرض دراسة حالة لألة الطحن العمودي، وهي قطعة رئيسية من المعدات في تصنيع الأجزاء الميكانيكية. تدمج الصناعة 4.0 التقنيات المتقدمة مثل البيانات الضخمة والذكاء الاصطناعي لتسهيل الصيانة التنبؤية.

يستخدم النهج المتبع أدوات لتطوير وتقييم نماذج التنبؤ بناءً على خوارزميات التعلم الآلي، مثل أجهزة ناقل الدعم (SVM) والشبكات العصبية الاصطناعية (ANN). توضح النتائج قدرة هذه النماذج على توقع الأعطال، مما يساعد على تحسين الصيانة وتقليل وقت التوقف عن العمل وتحسين موثوقية النظام.

الكلمات المفتاحية: الصيانة التنبؤية، الصناعة 4.0، التعلم الآلي، أجهزة ناقل الدعم، الشبكات العصبية الاصطناعية

Résumé

Ce mémoire examine l'application de la maintenance prédictive dans le contexte de l'industrie 4.0, en mettant l'accent sur l'utilisation de techniques d'apprentissage automatique pour prédire les défaillances. Une étude de cas portant sur une fraiseuse verticale, un équipement clé dans la fabrication de pièces mécaniques, est présentée. L'industrie 4.0 intègre des technologies avancées comme le big data et l'intelligence artificielle pour faciliter la maintenance prédictive.

L'approche adoptée utilise des outils pour développer et évaluer des modèles de prédiction basés sur des algorithmes de machine learning, tels que les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (ANN). Les résultats démontrent la capacité de ces modèles à anticiper les défaillances, ce qui permet d'optimiser la maintenance, de réduire les temps d'arrêt et d'améliorer la fiabilité des systèmes.

Mots clés : maintenance prédictive, Industrie 4.0, machine learning, machines à vecteurs de support, réseaux de neurones artificiels

Abstract

This dissertation examines the application of predictive maintenance in the context of Industry 4.0, with a focus on the use of machine learning techniques to predict failures. A case study of a vertical milling machine, a key piece of equipment in the manufacturing of mechanical parts, is presented. Industry 4.0 integrates advanced technologies like big data and artificial intelligence to facilitate predictive maintenance.

The approach taken uses tools to develop and evaluate prediction models based on machine learning algorithms, such as support vector machines (SVM) and artificial neural networks (ANN). The results demonstrate the ability of these models to anticipate failures, which helps optimize maintenance, reduce downtime and improve system reliability.

Keywords: predictive maintenance, Industry 4.0, machine learning, support vector machines, artificial neural networks