

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



PROJET DE FIN DE D'ETUDES

MASTER

Domaine : Sciences et Technologie

Filière : Electromécanique

Parcours : Master

Spécialité : Maintenance Industrielle

Thème

Détection des pannes d'un système
mécanique par apprentissage automatique

Préparé par :

- MORSELI Roufaida
- MOKHTARI Madjida Sirine

Soutenu publiquement le : 25 / 06 / 2023, devant le jury composé de :

M. ABOSHIGHIBA Hicham	Maître de Conférences "B" (Université de Tiaret)	Président
M ^{me} . MAKHFI Souad	Maître de Conférences "B" (Université de Tiaret)	Examinatrice
M. SEBA Mohamed Rida	Docteur (Université de Tiaret)	Examineur
M. MEKROUSSI Said	Professeur (Université de Tiaret)	Encadrant
M. MOSTEFAOUI S.Mokhtar	Maître de Conférences "A" (Université de Tiaret)	Co-Encadrant

Année universitaire : 2022 - 2023

Remerciements

Avant tout. Nous tenons à remercier notre Dieu ALLAH tout puissant de nous avoir donné la patience et le courage pour réaliser ce modeste travail avec succès.

Ce modeste travail est le fruit d'une collaboration entre le Département de Génie Mécanique de La Faculté Science Appliqué et le Département d'Informatique du Faculté Mathématiques et Informatique à l'Université IBN Khaldoun de Tiaret.

On tient à exprimer nos reconnaissances à notre Encadrant, Monsieur MEKROUSSI Said, Professeur à l'Université Ibn Khaldoun de Tiaret et le Co-Encadrant Monsieur MOSTEFAOUI Sid Ahmed Mokhtar, Maître de conférences « A » à l'Université Ibn Khaldoun de Tiaret (Département d'Informatique) pour leur disponibilité, leur compétence, dévouement et de ses conseils judicieux qui a été un grand soutien moral et qui nous a conduit à réaliser ce travail. Les mots ne suffiraient pas pour exprimer toute nos reconnaissances envers Monsieur MEGHAZI Hadj Madani, Maître assistant « A » à l'Université Ibn Khaldoun de Tiaret (Département d'Informatique) pour son soutien tout au long de notre travail.

Nous remercions les autres membres de jury, Monsieur ABOSHIGHIBA Hicham Maître de conférences « B » à l'Université Ibn Khaldoun de Tiaret qui a accepté de présider ce jury, Monsieur SEBA Mohamed Rida Docteur à l'Université Ibn Khaldoun de Tiaret, Madame MAKHFI Souad Maître de conférences « B » à l'Université Ibn Khaldoun de Tiaret, qui ont bien voulu examiner notre travail et participer au jury.

Nous ne pouvons terminer ces remerciements sans y associer nos parents, notre amies, et toutes les personnes qui ont contribues à la réussite de ce travail.

Dédicace

À mes chers parents qui m'ont beaucoup aidé pour terminer mes études qui m'ont comblée de leur soutien leurs grands sacrifices et leurs encouragements. Je prie Dieu de les bénir et de les protéger pour moi. En espérant qu'ils soient toujours fiers de moi.

À Mes très chers frères Kadda, Mohammed, Abdelillah et ma chère sœur Naima.

*À mon grand-père, que Dieu l'accueille dans son vaste paradis
et ma grand-mère que Dieu la protège.*

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

À mon binôme Sirine.

À tous mes amis les plus proche Chifaa, Amel, Wafaa.

À tous mes amis de la promotion sortante

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

MORSELI Roufaida

Dédicace

Je dédie cet humble travail à ceux qui ont tout sacrifié pour moi, « mes cher parents ». Merci pour tout le soutien et l'amour que vous m'avez donné depuis mon enfance et j'espère que votre

bénédictio n sera toujours avec moi.

À mes frères et ma sœur, Abdul Jalil, Chehab et Zina

À toute ma famille en particulier mon grand-père.

À mes encadreurs pour le soutien.

À ma chère binôme Roufaida avec laquelle j'ai vécu des souvenirs inoubliables durant les cinq années d'études.

À mes chers amis Hanane, Mrieme, chafika, Fatima, Nariman.

MOKHTARI Madjida Sirine

Sommaire

Remerciements	i
Dédicace	ii
Dédicace	iii
Sommaire	iv
Liste des figures	v
Liste des tableaux	vi
Liste d'abréviation	vii
Introduction générale	1

Chapitre I : Généralités sur la maintenance industrielle

I.1 Introduction	2
I.2 Concepts et terminologies	2
I.2.1 Défaut	2
I.2.2 Dégradation	2
I.2.3 Défaillance	3
I.2.4 La panne	4
I.3 Maintenance industrielle	4
I.3.1 Définition de maintenance	4
I.3.2 Rôle et l'importance de maintenance dans une entreprise	4
I.3.3 Objectives de maintenance	4
I.3.4 La politique de maintenance	6
I.3.5. Les type de maintenance	6
I.3.5.1. Maintenance préventive	7
I.3.5.2 La maintenance corrective	8
I.3.5.3 La maintenance améliorative	9
I.3.6 Opération de maintenance	9
I.3.6.1 Opération de maintenance préventive	9
I.3.6.2 Opération de maintenance corrective	10

I.3.7 Niveau de maintenance	10
I.3.8 Les fonctions de maintenance	11
I.3.8.1 La fonction méthode	12
I.3.8.2 La fonction ordonnancement	12
I.3.8.3 La fonction réalisation	12
I.3.9 La sureté de fonctionnement	13
I.3.9.1 La fiabilité	13
I.3.9.2 La maintenabilité	14
I.3.9.3 La disponibilité	15
I.3.10 Etude AMDEC	15
I.3.10.1 Objectif de l'AMEC	15
I.3.10.2 Les concepts de l'AMDEC	16
I.3.10.3 Différents types d'AMDEC.....	16
I.3.11. Diagramme de Pareto	16
I.4 La détection	17
I.5 Diagnostic industriel	18
I.5.1 Définition Diagnostic	18
I.5.2 L'objectif du diagnostic	18
I.5.3 Les étapes des diagnostics.....	19
I.5.4 Les méthodes de diagnostic	20
I.5.4.1 Mode de raisonnement	21
I.5.4.2 Les différentes méthodes	21
I.6 Conclusion	23

Chapitre II : Modélisation par apprentissage automatique

II-1. Introduction	24
II.2 Intelligence artificielle	24
II.3 Apprentissage automatique	24
II.3.1 Définition	25
II.3.2 Type d'apprentissage automatique	25
II.3.2.1 L'apprentissage supervisé	26
II.3.2.2 L'apprentissage non-supervisé	27
II.3.2.3 Apprentissage par renforcement	28
II.4 L'apprentissage profond « Deep Learning »	28

II.5 les méthodes d'apprentissage supervisé	28
II.5.1 Naïve Bayes	28
II.5.2. Machines à Vecteurs Supports (SVM)	30
II.5.2.1. Principe de SVM	30
II.5.2.2. Notions de base	31
II.5.2.3. Propriétés fondamentales	32
II.5.2.4. Classificateur linéaire séparable	32
II.5.2.5. Classificateur non linéaire séparable	34
II.5.3 Les réseaux de neurones	34
II.5.3.1. Les neurones artificiels	34
II.5.3.2. réseaux de neurones biologiques	35
II.5.3.3. Fonctionnement des neurones artificiels	36
II.5.3.4. Modèle mathématique d'un neurone formel	37
II.5.3.5. Types de modèles de neurones	39
II.5.3.6. Le perceptron	40
II.5.3.7. Architecture d'un réseau de neurones artificiel	40
II.6 Conclusion	44

Chapitre III : Etude de cas : Boite de vitesse

III.1 Introduction.....	45
III.2 La boite de vitesses	45
III.3 Le fonctionnement de la boite de vitesse	46
III.4 Plateforme « Kaggle ».....	47
III.5 KNIME Analytics Platform	47
III.5.1 Les caractéristiques clés de KNIME	48
III.5.2 Les mesure de performances utilisées	48
III.6 Description du DataSet utilisé	49
III.6.1 DataSet pour le premier cas	50
III.6.1.1 Apprentissage par le Réseau Bayésien.....	51
III.6.1.2 Apprentissage par Machines à Vecteurs Supports (SVM)	52
III.6.1.3 Apprentissage par Réseau de Neurone	54
III.6.2 DataSet pour le deuxième cas	55
III.6.2.1 Apprentissage par réseau bayésien	56
III.6.2.2 Apprentissage par SVM	57

III.6.2.3 Apprentissage par réseau de neurone	58
III.6.2.4 Comparaison entre les deux DataSets	59
III.7 Conclusion	60
Conclusion Générale.....	61
Bibliographie	
Résumé	

Liste des figures

Chapitre I

Figure I.1	Types de défaillance	3
Figure I.2	Schématisation objective de la maintenance	5
Figure I.3	Type de maintenance	6
Figure I.4	Les fonctions opérationnelle de la maintenance.....	12
Figure I.5	Graphe de analyse ABC	17
Figure I.6	Les différentes étapes du diagnostic industriel.....	19
Figure I.7	Classification des méthodes du diagnostic industriel.....	20

Chapitre II

Figure II.1	Les domaines de l'intelligence artificielle.....	24
Figure II.2	Type d'apprentissage automatique.....	26
Figure II.3	Modèle de conception en réseau bayésien naïf.....	29
Figure II.4	L'hyperplan H qui sépare les deux ensembles de points.....	31
Figure II.5	L'hyperplan H optimal, vecteurs supports et marge maximale.....	31
Figure II.6	Meilleur hyperplan séparateur.....	32
Figure II.7	Expression de la marge pour l'exemple xi.....	33
Figure II.8	Exemple de projection dans un espace de redécrotions.....	34
Figure II.9	Modèle de neurone artificiel de M. Culloch et Pitts.....	35
FigureII.10	Modèle d'un réseau de neurone biologiques.....	35
FigureII.11	Mise en correspondance neurone biologique / neurone artificiel.....	36
FigureII.12	Modèle d'un neurone formel.....	37
Figure II.13	Fonctions d'activations : (a) « seuil » ; (b) « linéaire », et (c) « Sigmoidé ».....	38
Figure II.14	Neurone à simple entrée.....	39
FigureII.15	Neurone à entrées multiples.....	40
Figure II.16	Réseaux de neurone monocouche.....	41

Figure II.17	Structure d'un réseau neuronal multicouche Feed-Forward.....	42
Figure II.18	Structure d'un réseau de neurones de type RBF.....	43
Figure II.19	Réseaux récurrents.....	43
Figure II.14	Réseaux cellulaires.....	44
Chapitre III		
Figure III.1	Boîte de vitesse manuelle.....	46
Figure III.2	Boîte de vitesse automatique.....	46
Figure III.3	KNIME analytique plate-forme.....	48
Figure III.4	Flux d'apprentissage knime adopté pour le réseau bayésien.....	51
Figure III.5	Résultat de classification sur trois capteurs en 3D.....	52
Figure III.6	Flux d'apprentissage knime adopté pour le SVM.....	53
Figure III.7	Résultat de classification sur les trois capteurs en 3D.....	54
Figure III.8	Flux d'apprentissage knime adopté pour le réseau de neurone.....	54
Figure III.9	Résultat de classification sur les trois capteurs en 3D.....	55
Figure III.10	Flux d'apprentissage knime adopté pour le réseau bayésien.....	56
Figure III.11	Résultat de classification sur les trois capteurs en 3D.....	57
Figure III.12	Flux d'apprentissage knime adopté pour le SVM.....	57
Figure III.13	Flux d'apprentissage knime adopté pour le réseau de neurone.....	58
Figure III.14	Résultat de classification sur les trois capteurs en 3D.....	59

Liste des tableaux

Chapitre I

Tableau I.1 : Les niveaux de maintenance	11
--	----

Chapitre II

Tableau II.1 : Mise en correspondance neurone biologique / neurone artificiel	36
Tableau II.2 : Différentes fonctions d'activations utilisées dans les RNA	39
Tableau II.3 : Table de vérité (ET, OU)	42

Chapitre III

Tableau III.1 : Aperçu sur les données du premier DataSet	50
Tableau III.2: Matrice de confusions pour réseau bayésien	51
Tableau III.3: les statistiques de classification pour réseau bayésien	51
Tableau III.4: Résulta de classification globale pour réseau bayésien	52
Tableau III.5 : Matrice de confusions pour SVM	53
Tableau III.6 : les statistiques de classification pour SVM	53
Tableau III.7 : Résultat de classification globale pour SVM	53
Tableau III.8: Matrice de confusions pour réseau de neurone	54
Tableau III.9 : les statistiques de classification pour réseau de neurone	54
Tableau III.10 : Résultat de classification globale pour réseau neurone	55
Tableau.III.11 : Aperçu sur les donnes du deuxième DataSet	56
Tableau III.12 : Matrice de confusions pour réseau bayésien	56
Tableau III.13 : les statistiques de classification pour réseau bayésien	56
Tableau III.14 : Résultat de classification globale pour réseau bayésien	57

Tableau III.15 : Matrice de confusions pour réseaux de neurone	58
Tableau III.16 : les statistiques de classification pour réseaux de neurone	58
Tableau III.17 : les statistiques de classification global pour réseaux de neurone	58
Tableau III.18 : Comparaison entre les deux DataSet	59

Liste d'abréviation

AFNOR : Agence Française de Normalisation

AMDEC : Analyse des Modes de Défaillance de leurs effets et de leur Criticité

ARN : Artificial Neural Network

ART : Théorie de Résonance Adaptative

CSV : Valeurs Séparées Par Des Virgules

D(t) : Disponibilité

IA : Intelligence Artificielle

KNIME : Konstanz Information Miner

LF : Logique Floue

M(t) : Maintenabilité

ML : Machine Learning

MTTR : Moyenne des Temps Techniques de Réparation

N/A : Not Available

PMC: Perceptron multicouche

R(t) : Fiabilité

RBF: Radial- Basis- Function

RBFNN: Radial- Basis- Function Neural Network

RNF: Réseau de Neurone Flou

SLP: Perceptron Monocouches

SVM : Machines à Vecteurs Supports

WNN : Wavelet Neural Network

μ : Taux de réparation

Introduction Générale

Introduction générale

L'apprentissage automatique, également connu sous le nom de machine Learning, est un domaine de l'intelligence artificielle qui se concentre sur le développement de techniques et d'algorithmes permettant aux ordinateurs d'apprendre à partir de données et d'améliorer leurs performances avec l'expérience, sans être explicitement programmés.

A cet effet nous allons étudier dans ce mémoire de fin d'étude la capacité de ce type de modèle sur un état réel existé dans la vie industrielle.

L'apprentissage automatique repose sur l'idée fondamentale que les machines peuvent apprendre à partir de l'expérience en identifiant des schémas et des relations dans les données. Au lieu d'être explicitement programmées pour effectuer une tâche spécifique, les machines sont entraînées à partir d'exemples pour reconnaître des schémas et effectuer des prédictions ou des classifications.

L'objectif de ce travail est de tester les méthodes actuelles d'apprentissage automatique sur une boîte de vitesse, nous chercherons à étudier des modèles capables de détecter d'éventuels dysfonctionnements ou anomalies dans le fonctionnement de la boîte de vitesses. Cela permettra de prévenir les pannes, d'améliorer la maintenance préventive et d'optimiser les performances globales du système de transmission.

Notre étude comprend trois chapitres, le premier chapitre est consacré à l'état de l'art sur la maintenance industrielle ainsi que leurs différentes stratégies.

On retrouve à l'intérieur du second chapitre, la modélisation par apprentissage automatique. Nous présentons les trois méthodes de classification.

Le dernier chapitre est consacré à la présentation et l'analyse des résultats.

Enfin, cette étude se termine par une conclusion générale qui contient un résumé des résultats obtenus.

Chapitre I

Généralités sur la Maintenance Industrielle

I.1 Introduction

La maintenance industrielle est un domaine essentiel pour assurer le bon fonctionnement et la fiabilité des équipements, machines et installations dans le secteur industriel. Elle englobe toutes les actions nécessaires pour prévenir les pannes, réduire les temps d'arrêt et maintenir les équipements en bon état de fonctionnement.

Ce chapitre fournira donc une base solide pour comprendre les principes de la maintenance industrielle et permettra aux lecteurs de mieux appréhender les différentes approches et stratégies pour maintenir les équipements en bon état de fonctionnement.

I.2 Concepts et terminologies

L'objectif premier de la maintenance industrielle est d'inspecter l'état de fonctionnement d'une machine et d'effectuer les réglages indispensables en cas de dysfonctionnement. Une machine, quel que soit son type, peut soit être dans un état de fonctionnement optimal, soit rencontrer être des problèmes plus ou moins graves. Si nous les classons par leurs intensités nous pouvons les définir de la façon suivante : Selon la politique de maintenance de l'entreprise, les objectifs de la maintenance seront :

I.2.1 Défaut

Un défaut est une anomalie de comportant au sein du système, Ce concept est essentiel dans les opérations de surveillance pour la conduite et la maintenance des processus industriels. On le définit par l'écart entre la caractéristique observée sur le dispositif et la caractéristique de référence lorsque celui-ci est en dehors des spécifications tolérées. Si les défauts n'affectent pas la tâche principale de l'appareil, il peut toujours conserver sa fonctionnalité. Par conséquence, il est essentiel d'identifier et de traiter les défauts pour éviter les pannes et garantir des performances optimales du système [1].

I.2.2 Dégradation

D'après le dictionnaire Petit Robert, la dégradation désigne un affaiblissement graduel et continu. Un matériel qui subit une dégradation voit ses performances diminuer progressivement, plus ou moins rapidement. En absence d'intervention, ce processus destructeur peut éventuelle [ment rendre l'équipement totalement inutilisable. Néanmoins le caractère progressif des dégradations s'accompagne dans la plupart des cas de signes avant-coureurs qu'il faut savoir déceler. La dégradation peut être attribuée à des phénomènes physiques et/ou chimiques et tend à affecter principalement les composants mécaniques des systèmes [2].

Les dégradations sont la résultante de quatre paramètres :

- La matière utilisée pour les composants ;
- Les procédés d'obtention des composants ;
- La conception du système ;
- Les conditions d'utilisation.

I.2.3 Défaillance

Une défaillance est une altération ou la cessation de l'aptitude d'un ensemble à accomplir sa (ou ses) fonction(s) requise(s) avec les performances définies dans les spécifications techniques [3]. Un défaut peut se présenter dans un système sans mener ce dernier à la défaillance. On peut classer les défaillances selon leur degré de sévérité par :

- Défaillance absorbable : pouvant être ignorée dans un premier temps ;
- Défaillance significative : nécessitant un processus de traitement ;
- Défaillance critique : nécessitant une intervention d'urgence.

• Type de défaillance

- Défaillance progressive : La défaillance se développe au fur et à mesure jusqu'à l'arrêt définitif du système ;
- Défaillance aléatoire : Dans ce cas la défaillance se présente d'une façon aléatoire, c'est-à-dire, le système s'arrête et reprend son fonctionnement plusieurs fois pendant une période de temps avant sa défaillance complète ;
- Défaillance soudaine : C'est le basculement soudain et définitif d'un système au-dessous du seuil du fonctionnement normal.




Figure I.1 : Types de défaillance

I.2.4 La panne

Une panne est l'inaptitude d'une entité (composant ou système) à assurer une fonction requise. Si nous écartons la possibilité d'erreurs de conception, la définition précédente implique que toute défaillance entraîne une panne. La défaillance correspond à une date et la panne à une durée comprise entre la date d'occurrence de la défaillance et la date de fin de réparation. [4]

I.3 Maintenance industrielle

I.3.1 Définition de maintenance

Le dictionnaire Petit Rebert la définit ainsi : «Maintien d'un matériel technique en état de fonctionnement, ensemble des moyens d'entretien et de leur mise en œuvre ». L'AFNOR (Agence Française de Normalisation) par la norme NF X 60-010 quant à elle l'a défini comme suit : «ensemble des actions permettant de maintenir ou de rétablir un biens dans un état spécifié ou en mesure d'assurer un service déterminé » [5]. Depuis 2001, elle a été remplacée par une nouvelle définition, désormais européenne (NF EN 13306 X 60-319) « Ensemble de toutes les actions techniques, administratives et de Management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise» [6].

La maintenance regroupe les actions de dépannage, de réparation, de réglage, de révision, de contrôle et de vérification des équipements matériels (machines, véhicules, objets, Manufacturés, etc.) ou même immatériels (logiciel). Dans la définition de la maintenance, nous trouvons deux mots-clés : maintenir et rétablir. Le premier mot « maintenir » évoque une action de prévention. Tandis que le deuxième « rétablir » fait allusion à l'action de correction.

I.3.2 Rôle et l'importance de maintenance dans une entreprise

Dans une entreprise quel que soit son type et son secteur d'activité le rôle de la fonction maintenance est dans de garantie la plus grande disponibilité des équipements et bon fonctionnement de l'installation matérielle de production et de leurs annexes impliquant un minimum économique de temps d'arrêt au rendement meilleurs tout en respectant le budget et alloué. La fonction maintenance est en générale assimilée à la fonction dépannage et réparation d'équipement soumis à usage et vieillissement.

I.3.3 Objectifs de maintenance

- **Les objectifs opérationnels**
- ✓ Maintenir le bien durable ;
- ✓ Assure la disponibilité maximale à un coût raisonnable ;

- ✓ Eliminer les pannes à tout moment et au meilleur coût ;
- ✓ Maximiser la durée de vie de bien ;
- ✓ Remplacer le bien à des périodes prédéterminées ;
- ✓ Assurer au bien des performances de haute qualité ;
- ✓ Assurer au bien un fonctionnement sûr et efficace ;
- ✓ Obtenir de l'investissement un rendement maximum ;
- ✓ Garder au bien une présentation suffisamment satisfaisante ;
- ✓ Maintenir le bien dans un état de propreté absolue.

• **Les objectifs de coût**

- ✓ Minimiser les dépenses de maintenance ;
- ✓ Assurer la maintenance dans les limites d'un budget ;
- ✓ Avoir des dépenses de maintenance portant sur le service exigé par l'installation en fonction de leur âge et de leur taux d'utilisation ;
- ✓ Tolérer à la discrétion du responsable de la maintenance une certaine quantité de dépense imprévue.

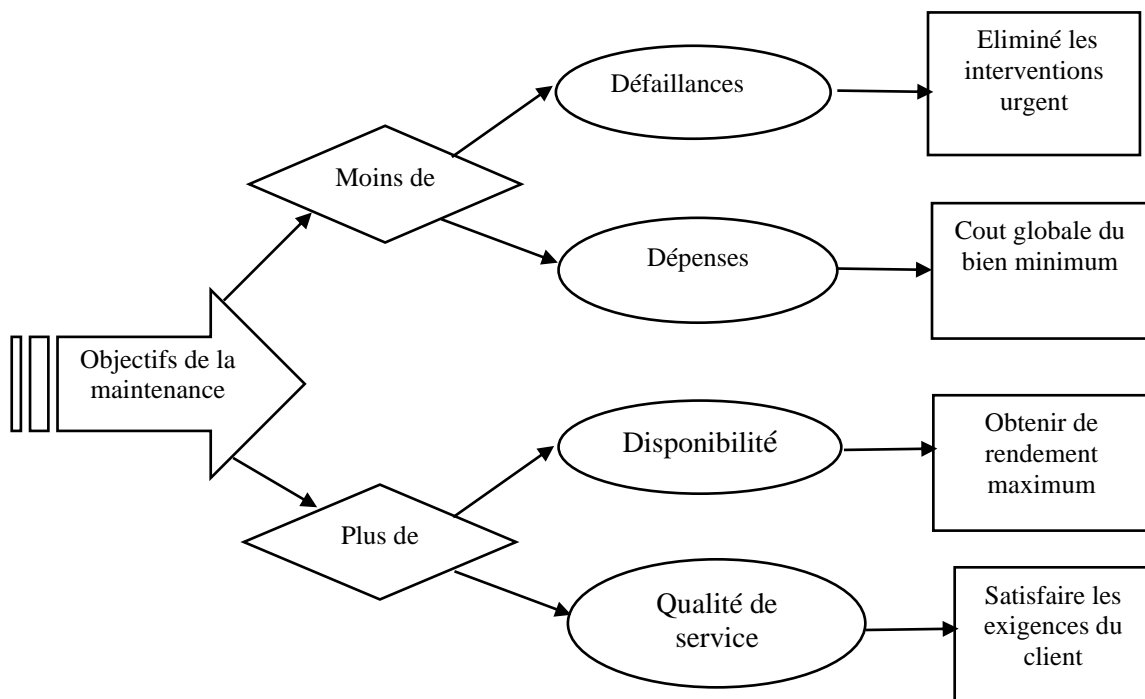


Figure I.2 : Schématisation d'objectifs de la maintenance

I.3.4 La politique de maintenance

La politique de maintenance d’une entreprise consiste à fixer les orientations en matière de méthode, programme, budget, etc... Dans le cadre des objectifs fixés. La politique de maintenance conduit à faire des choix du type de maintenance, à la réaliser en interne ou l’externaliser en faisant appel à la sous-traitance. Elle définit également l’approvisionnement en pièces de rechange, le développement des ressources humaines, l’établissement du système sécurité et le management qualité et de la fonction maintenance, et bien d’autres aspects similaires. La stratégie de maintenance, qui résulte de la politique de maintenance, impose des choix pour atteindre, voire dépasser les objectifs fixés. Les choix à faire concernent les méthodes de maintenance, les standards de travail, les méthodes et moyens de sécurité, les flux d’informations, l’organisation des équipes de maintenance et la gestion des stocks. La stratégie de maintenance la stratégie de maintenance permet d’organiser les différentes méthodes et les types de maintenance. La naissance des différents types de la maintenance est le résultat de l’influence de l’environnement interne de l’entreprise, mais aussi et surtout externe (technologique, économique, social, écologique, etc.)

I.3.5. Les type de maintenance

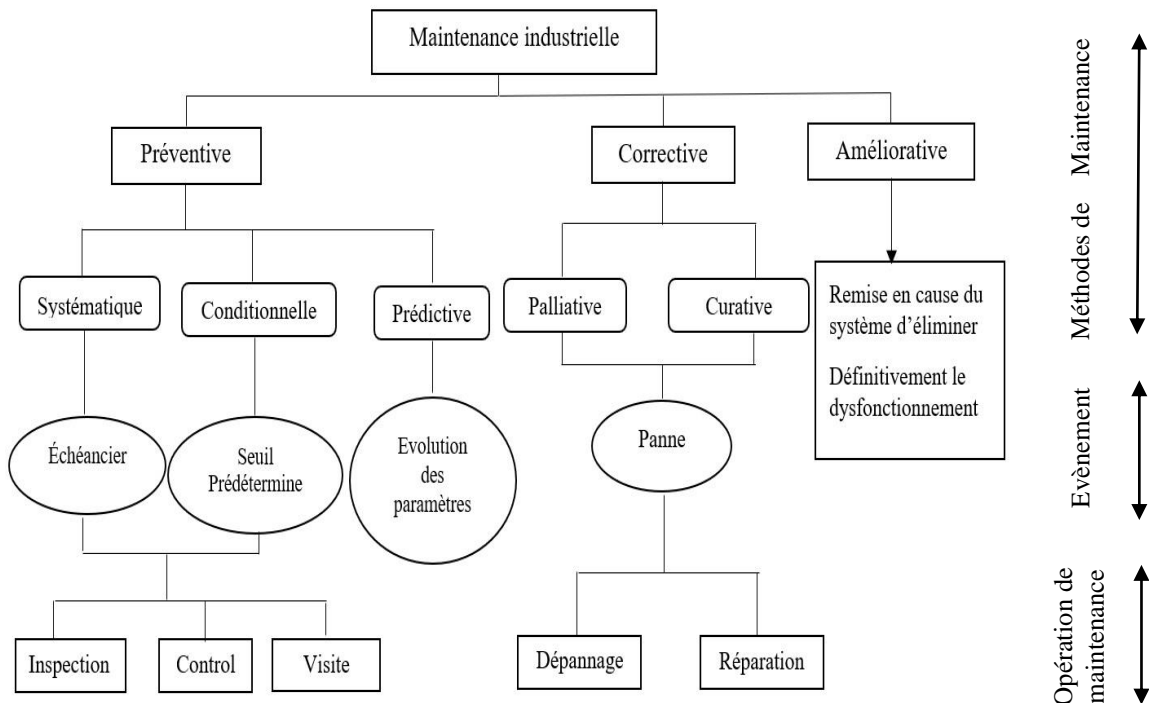


Figure I.3 : Les types de maintenance

I.3.5.1. Maintenance préventive

Elle est définie comme une maintenance effectuée selon des critères prédéterminés dans l'intention de réduire la probabilité de défaillance d'un bien ou la dégradation d'un service [2].

La maintenance préventive est une intervention de maintenance prévue, préparée et programmée en fonction de différents paramètres en vue d'éviter l'apparition probable d'une défaillance identifiée [8]. Les activités correspondantes sont déclenchées selon un échéancier établi à partir d'un nombre prédéterminé d'unités d'usage ou selon un intervalle de temps.

La maintenance préventive comprend :

- Les contrôles ou visites systématiques ;
- Les expertises, les actions et les remplacements effectués à la suite de contrôles ou de visites ;
- Les remplacements systématiques ;
- La maintenance conditionnelle ou les contrôles non destructifs.

La maintenance préventive peut être :

- Systématique
- Conditionnelle
- Prévisionnelle

a. La maintenance préventive systématique

Lorsque la maintenance préventive est réalisée à des intervalles prédéterminés, on parle de maintenance systématique. L'opération de maintenance est effectuée conformément à un échéancier, un calendrier déterminé a priori. Aucune intervention n'a lieu avant l'échéance prédéterminée. L'optimisation d'une maintenance préventive systématique consiste à déterminer au mieux la périodicité des opérations de maintenance sur la base du temps, du nombre de cycles de fonctionnement, du nombre de pièces produites, ect... [9].

b. La maintenance préventive conditionnelle

D'après la définition Afnor, il s'agit d'une forme de maintenance préventive basée sur une surveillance de fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement et intégrant les actions qui en découlent. La maintenance conditionnelle permet d'assurer le suivi continu du matériel en service, révélateur l'état de dégradation du bien. La maintenance conditionnelle est donc une maintenance dépendant de l'expérience et faisant intervenir des informations recueillies en temps réel. La maintenance préventive conditionnelle se caractérise

par la mise en évidence des points faibles. Suivant le cas il est souhaitable de les mettre sous surveillances et, a partir de la de décider d'une intervention est prise lorsqu'un y a une évidence expérimentale de défaut imminent ou d'un seuil de dégradation prédéterminé [10].

Tous les matériels sont concernés. Cette maintenance préventive conditionnelle se fait par des mesures pertinentes sur le matériel en fonctionnement. Les paramètres mesurés peuvent porter sur :

- Le niveau et la qualité de l'huile
- Les températures et les pressions
- La tension et l'intensité des matériels électrique...ect.

c. Maintenance préventive prévisionnelle

Est définie par la norme AFNOR- 2002, comme la maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évolution de paramètres significatifs de la dégradation de l'entité aux instants futurs. La maintenance prévisionnelle est parfois également appelée maintenance proactive [11].

La maintenance prédictive a le même objectif principal que la maintenance préventive, qui est d'intervenir avant que la panne se produise et éviter de ce fait son impact. Mais, contrairement à la maintenance préventive, elle est basée sur les conditions mesurées de l'équipement. La maintenance prédictive se base sur des mesures discrètes qui peuvent être orientées par rapport à une limite prédéfinie, ou suivies à l'aide de graphiques de contrôle statistique. Lorsqu'une anomalie est observée, un avertissement est fourni avec suffisamment de temps pour analyser la nature du problème et prendre des mesures correctives pour éviter une panne [12].

I.3.5.2 La maintenance corrective

La norme (NF EN 13306) définit ainsi la maintenance corrective : « Exécutée après détection d'une panne est destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise ». Ou bien c'est l'ensemble des activités réalisées après la panne du système pouvant être liée à sa défaillance ou à la dégradation de sa fonction, elle a alors pour but de le remettre en état de marche. Il faut distinguer là, deux aspects : la maintenance curative et la maintenance palliative [13].

a. La maintenance corrective curative (Dépannage)

Le dépannage permet de remettre provisoirement en service un équipement victime d'une défaillance partielle ou totale, en attendant une réparation définitive. Dans ce cas, la rapidité de l'intervention prime sur la qualité. Cette action doit répondre le plus rapidement possible à l'arrêt

du système en amenant des solutions de marche même temporaires. L'action de dépannage peut être faite par le personnel technique habilité au service de la pompe ou, si le problème est grave, par une équipe technique rapide. Le but de cette action n'est pas de réparer l'équipement mais de lui permettre de fournir une partie du service pour lequel il a été mis en place. Si nécessaire, une partie de l'équipement sera court-circuitée afin de permettre le fonctionnement partiel du système [14].

b. La maintenance corrective palliative (Réparation)

La maintenance corrective palliative regroupe les activités de maintenance corrective destinées à permettre à un bien d'accomplir provisoirement tout ou partie d'une fonction requise. Ces activités du type dépannage qui présentent un caractère provisoire devront être suivies d'activité curative [2].

I.3.5.3 La maintenance améliorative

Après plusieurs défaillances de même nature, ce type de maintenance permet, après réflexion et étude, déterminant les causes réelles du problème et recherchant les solutions adaptées à leur réduction ou suppression. Elle nécessite obligatoirement une concertation entre service production bureau d'étude maintenance L'amélioration est ensemble des mesures techniques administrative et de gestion à apporter peuvent avoir comme objectif l'augmentation des performances de production d'installations ; l'augmentation de la fiabilité, et diminuer les fréquences d'interventions ; l'augmentation le rendement et la sécurité du personnel.

I.3.6 Opération de maintenance

I.3.6.1 Opération de maintenance préventive

- **Inspection** : contrôle de qualification par la mesure l'observation le test ou l'étalonnage d'une caractéristique importante d'un article, il permet d'identifier des anomalies et d'effectuer des réglages simples ne nécessitant pas d'outillage aspécifique ou d'arrêter, la production ou l'équipement (sans démontage).
- **Control** : C'est la vérification de la conformité avec des données préétablies suivie d'un jugement. Cette maîtrise peut déboucher sur des actions de maintenance corrective ou des décisions de rejet, d'acceptation ou de report.
- **Visite** : c'est une opération de surveillance se situant dans le cadre d'action de maintenance préventive systématique consistant en un examen détaillé et programmées de tout ou partie d'un équipement. La visite pour but vérifié de l'évolution de l'état des

équipements gérés par un programme qui fixe la périodicité. Ils sont basés sur une liste prédéterminée de fonctions. Selon l'importance et l'exigence de précision d'observation requise. Ils provoquent un léger démontage. Par conséquent, ils doivent parfois être inclus dans le plan de production pour éviter toute interruption de production.

I.3.6.2 Opération de maintenance corrective

- **Dépannage** : aux actions de remise en état de fonctionnement des équipements défaillance, compte tenu des objectifs, les actions de dépannage peuvent être associées à des résultats provisoires dont la réalisation dépasse les règles de procédure, de coût et de qualité. Dans de tels cas, un dépannage de maintenance suivra. La connaissance du comportement de l'équipement est des modèles de dégradation sans condition spécifique à l'application est la base d'un bon diagnostic et permet souvent de gagner du temps. Les opérations de réparation sont généralement de courte durée, mais peuvent être nombreuses. De ce fait le service maintenance afin de réduire les coûts.

Ainsi, par exemple, le dépannage peut s'appliquer à des équipements en fonctionnement continu dont les impératifs de production interdisent tout accès ou intervention à l'arrêt

- **Réparation** : intervention définitive et limitée pour la maintenance corrective après une panne ou une défaillance. Les réparations peuvent être effectuées immédiatement après une visite de réparation ou de maintenance préventive. Il s'agit d'une opération corrective, elle est programmée et planifiée, avec tous les moyens (temps techniciens, matériels, pièces détachées...) pour cela la réparation correspond à l'action finale.

I.3.7 Niveau de maintenance

Un niveau de maintenance se définit par rapport :

- A la nature de l'intervention
- A la qualification de l'intervention
- Aux moyens mis en œuvre

La norme NF X 60-010 donne, à titre indicatif, cinq niveaux de maintenance, en précisant le service qui en a la responsabilité, la production ou la maintenance.

Niveau	Définition Personnel	Personnel D'intervention	Moyens
1	Réglages simples prévus par le constructeur au moyen d'éléments accessibles sans aucun démontage ou ouverture de l'équipement, ou échanges d'éléments consommables accessibles en toute sécurité	Exploitant du bien, sur place	L'outillage portable défini par les instructions de maintenance
2	Dépannage par échange standard des éléments prévus à cet effet et opérations mineures de maintenance préventive	Technicien habilité, de qualification moyenne, sur place	L'outillage portable défini par les instructions de maintenance
3	Identification et diagnostic des pannes, réparations par échange de composants ou d'éléments fonctionnels, réparations mécaniques mineures et toutes opérations courantes de maintenance préventive telles que réglage général ou réaligement des appareils de mesure.	Technicien spécialisé, sur place ou dans l'atelier de maintenance,	L'outillage prévu, et des appareils de mesure et de réglage, des bancs d'essais et de contrôle, l'ensemble de la documentation nécessaire ainsi que les pièces approvisionnées par le magasin.
4	Tous les travaux importants de maintenance corrective ou préventive à l'exception de la rénovation et de la reconstruction	Une équipe comprenant un encadrement technique très spécialisé	Outillage général plus spécialisé et éventuellement, des bancs de mesure et des étalons de travail nécessaires à l'aide de toute documentation générales et particulière
5	Rénovation, reconstruction ou exécution des réparations importantes confiées à un atelier central ou à une unité extérieure prestataire de service.	Equipe complète, polyvalente, en atelier central	Moyens proches de la fabrication par le constructeur

Tableau I.1 : Les niveaux de maintenance [15].

I.3.8 Les fonctions de maintenance

La mission principale de la maintenance est la gestion optimisée des équipements de production en fonction des objectifs propres à l'entreprise. Nous identifions trois fonctions associées à la

maintenances présentées dans Ces fonctions sont différentes dans leurs descriptions, complémentaires finalités [16].

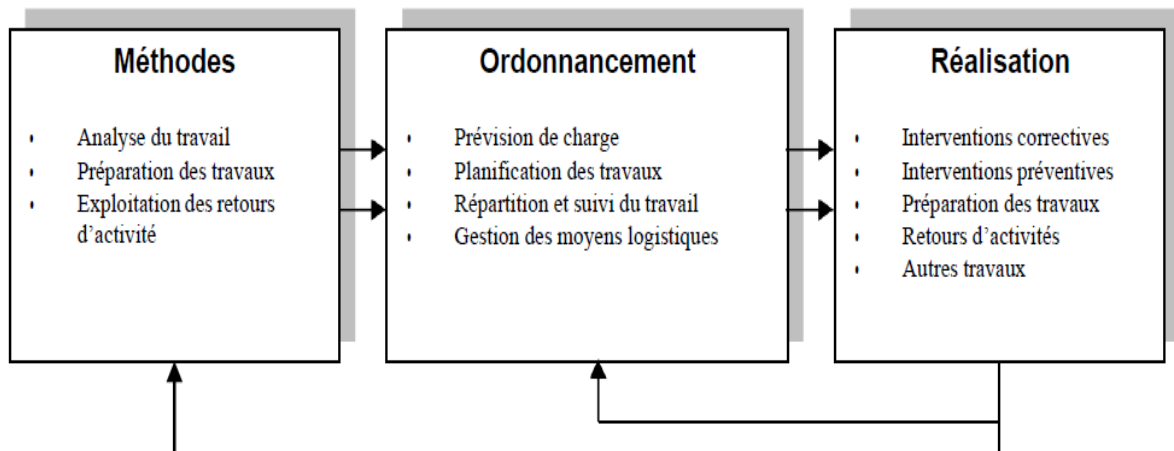


Figure I.4 : Les fonctions opérationnelles de la maintenance [16].

I.3.8.1 La fonction méthode

Le but principal du département méthode est la préparation. Pour la maintenance préventive cela comprend la définition d'un plan de maintenance des équipements, puis l'évolution de son l'optimiser et pour la maintenance corrective La préparation consiste à anticiper les problèmes pouvant ralentir les opérateurs pour une maintenance externalisée, à définir des règles et procédures pour le prestataire sélectionné puis à accompagner le prestataire lors des interventions sur le terrain.

I.3.8.2 La fonction ordonnancement

L'épine dorsale de la maintenance est la fonction de planification. Cette fonction permet de synchroniser les opérations de maintenance interne ou externe. Planifier le travail, optimiser les méthodes en fonction des délais et des chemins critiques, contrôler l'avancement des travaux sont les missions principales de la fonction ordonnancement.

I.3.8.3 La fonction réalisation

La fonction réalisation a pour objet d'utiliser les moyens mis à disposition, suivant les procédures imposées, dans les délais préconisés, pour réaliser dans les règles de l'art, une tâche définie et remettre le matériel dans un état spécifié. La réalisation peut nécessiter un diagnostic c'est-à-dire identifier et caractériser la défaillance [14].

I.3.9 La sureté de fonctionnement

I.3.9.1 La fiabilité

La fiabilité est l'aptitude d'un dispositif à accomplir une fonction requise dans des conditions d'utilisation et pour un intervalle de temps donnés. Le terme de fiabilité est utilisé comme une caractéristique indiquant une probabilité ou une proportion de succès. Autrement dit est considéré comme faible un système dont la probabilité de connaître une défaillance est faible .le nombre de défaillance est faible par unité de temps ou d'usage est donc le critère d'évaluation de la fiabilité [5].

Considérons l'instant T d'occurrence de la défaillance, cette variable aléatoire permet de définir la notion de fiabilité qui s'interprète comme la probabilité que l'entité considérée ne tombe pas en panne avant un instant (t) donnée ou bien comme la probabilité qu'elle tombe en panne après l'instant (t).Par extension, on appelle également fiabilité la probabilité associée R(t) à cette notion alors qu'elle n'en est qu'une mesure. Elle est définie par :

$R(t)=P(E \text{ non défaillance sur la durée } [0, t] \text{ en supposant qu'elle n'est pas défaillante à l'instant } t=0)$ [6].

Ce qui peut s'exprimer par :

$$R(t) = P(T > t) \quad (\text{I.1})$$

- Objectif et l'intérêt de fiabilité :

L'analyse de fiabilité constitue une phase indispensable dans toute étude de sureté de fonctionnement. Aujourd'hui, la fiabilité est devenue un paramètre :

- De mesurer une garantie dans le temps ;
- Dévaluer rigoureusement de degré de confiance ;
- De chiffrer une dure de vie ;
- Dévaluer une précision du temps de bon fonctionnement ;
- De calculer le risque pris ;
- De déterminer la stratégie d'entretien ;
- De choisir le stock magasin judicieux.

I.3.9.2 La maintenabilité

Dans des conditions données la maintenabilité aptitude d'un bien à être maintenu ou rétabli dans un état où il peut accomplir une fonction requise, lorsque la maintenance est accomplie dans des conditions données, en utilisant des procédures et des moyens prescrits. C'est aussi la probabilité de rétablir un système dans des conditions de fonctionnement spécifiées, en des limites de temps désirées, lorsque la maintenance est accomplie dans des conditions données, en utilisant des procédures et des moyens prescrits. La maintenabilité d'une entité réparable est caractérisée par une probabilité $M(t)$ que la maintenance d'une entité E accomplie dans des conditions données, avec des procédures et des moyens prescrits, soit achevée au temps t , sachant que E est défaillante au temps $t = 0$ [17].

A partir de ces définitions, on distingue :

- La Maintenabilité intrinsèque : elle est « construite » dès la phase de conception à partir d'un cahier des charges prenant en compte les critères de maintenabilité (modularité, accessibilité, etc.).
- La Maintenabilité prévisionnelle : elle est également « construite », mais à partir de l'objectif de disponibilité.
- La Maintenabilité opérationnelle : elle sera mesurée à partir des historiques d'interventions [17].

- Calcul de la maintenabilité

La Maintenabilité se calcule par la formule suivante [16] :

$$M(t) = e^{-\mu t} \quad (\text{I.2})$$

L'analyse de maintenabilité permettra d'estimer la MTTR ainsi que les lois probabilistes de maintenabilité.

MTTR : (Mean Time To Repair) ou encore Moyenne des Temps Techniques de Réparation.

$$MTTR = \frac{\sum \text{Temps d'intervention pour } n \text{ pannes}}{\text{Nombre de panne } (n)} \quad (\text{I.3})$$

Taux de réparation μ :

$$\mu = \frac{1}{MTTR} \quad (\text{I.4})$$

I.3.9.3 La disponibilité

Aptitude d'un bien à être en état d'accomplir une fonction requise dans des conditions données, à un instant donné ou durant un intervalle de temps donné, en supposant que la fourniture des moyens extérieurs nécessaires est assurée. Cette aptitude dépend de la combinaison de la fiabilité, de la maintenabilité et de la logistique de maintenance. Les moyens extérieurs nécessaires autres que la logistique de maintenance n'affecte pas la disponibilité du bien la probabilité associée $D(t)$ à l'instant t est aussi appelée disponibilité par [6] :

$$D(t) = P(E \text{ non défaillant à l'instant } t) \quad (I.5)$$

L'aptitude contraire est appelée indisponibilité est défini par :

$$D'(t) = 1 - D(t) \quad (I.6)$$

-Quantification de la disponibilité

La disponibilité peut se mesurer :

- a. Sur un intervalle de temps donné (disponibilité moyenne),
- b. À un instant donné (disponibilité instantanée),
- c. À la limite, si elle existe, de la disponibilité instantanée lorsque $t \rightarrow \infty$ (disponibilité asymptotique).

I.3.10 Etude AMDEC

L'AMDEC :(Analyse des Modes de Défaillance de leurs effets et de leur Criticité). C'est une méthode d'analyse préventive de la fiabilité d'un produit, d'un processus, ou d'un moyen de production ou d'un flux d'information. Elle permet d'hierarchiser les défaillances redoutées pour définir des actions correctives pertinentes et efficaces. et c'est une méthode inductive permettant pour chaque composant d'un système, de recenser son mode de défaillance et son effet sur le fonctionnement ou sur la sécurité du système.

I.3.10.1 Objectif de l'AMEC

L'AMDEC est une méthode qui permettra d'obtenir la qualité par une action préventive plutôt que curative. Elle s'applique soit en phase de conception (innovation), soit en phase de maîtrise. Son objectif est d'identifier les risques liés à un processus de fabrication. Il pourra s'agir des risques liés à la sécurité, à la qualité, à la performance de production. L'utilisation de la méthode

AMDEC consiste à identifier les points faibles de la capacité de production de l'équipement, ce qui permet de proposer et de mettre en place des mesures correctives en conséquence. L'étude AMDEC permet principalement d'optimiser les coûts indirects. Et obtenir une bonne maintenance. En effet elle constitue une méthode de diagnostic intelligente dans la mesure où elle permet de prévoir un certain nombre des faiblesses, des défauts, des anomalies et des pannes au niveau de l'ensemble des éléments qui concourent à la fabrication d'un produit [18].

I.3.10.2 Les concepts de l'AMDEC sont basés sur les notions comme

- a) **La cause de défaillance** : on entend par cause de défaillance, la source qui la fait apparaître ou qui a provoqué son occurrence. la cause de défaillance sont en relation direct avec milieux, matière, méthode, la fabrication et l'utilisation.
- b) **Mode de défaillance** : est la manière dont le système vient à ne plus remplir la fonction requise ou fonctionner anormalement. Il sont relatifs à la fonction de service devant être assurée par l'entité en question.
- c) **Effet d'une défaillance** : les conséquences ou les résultats ou la suite logique d'un fait, ou d'une action observable ou constatables sur l'entité étudié suite à une défaillance [19].

I.3.10.3 Différents types d'AMDEC

On peut distinguer trois types :

- **AMDEC moyens de production (moyen ou machine)** : analyse des défaillances à la conception et/ou à l'utilisation d'un outil de production par rapport à la sûreté de son fonctionnement et à la conformité du produit à fabriquer.
- **AMDEC produit ou service** : analyse de la conception du produit ou du service afin de déterminer les défaillances potentielles à partir de l'analyse fonctionnelle de ce produit ou de ce service.
- **AMDEC processus** : analyse des défauts qui peuvent affecter le produit (output) et qui sont imputable au processus [18].

I.3.11 Diagramme de Pareto

Parmi la multitude de préoccupation qui est confronté le service maintenance choisir entre plusieurs problèmes ceux qui doivent être traité en priorité. Pour cela il faut déceler celles qui sont la résolution ou l'amélioration serait le plus rentable, en particulier en termes de couts

d'indisponibilité. Ainsi en appliquant la méthode la méthode ABC de Pareto on peut remédier à ce problème en déterminer exactement les type d'intervention à mener priorité. Principe de base à classer les pannes par ordre décroissant de couts (temps d'arrêt cout financier.), chaque événement se rapportant à une entité. On établit un graphique faisant correspondre les pourcentages de cout cumulés aux pourcentages de type de pannes cumulés. On obtenir ainsi un graphe montrant trois zones [20] :

- Zone A : 20% des pannes représentent 80% des couts.
- Zone B : 30% de pannes suivantes ne coutent que 15% supplémentaire.
- Zone C : 50% des pannes restantes ne reviennent qu'à 5% des coutes.




Figure I.5 : Graphe d'analyse ABC

I.4. La Détection

La détection des pannes est une méthode utilisée pour identifier les problèmes éventuels dans les équipements mécaniques, électriques avant qu'ils ne se transforment en pannes majeures. Cela permet de minimiser les temps d'arrêt et les coûts de réparation, et d'optimiser la production des machines et systèmes. Dans le domaine de l'automobile, par exemple, un mécanicien peut affecter un auto-diagnostic complet pour détecter tous les problèmes pouvant être causés par un véhicule qui ne se transformera pas en un volet majeur. Dans les industries, les techniques de détection et de diagnostic des pannes sont utilisées pour surveiller le processus de production, identifier les pannes des équipements et prévenir les pannes coûteuses. La qui utilise des capteurs ou des interrupteurs de position en contact direct avec la pièce en mouvement qu'il faut détecter

en détection générale, La détection mécanique est souvent utilisée dans des applications industrielles pour détecter la présence ou l'absence de pièces, la position des pièces, le mouvement des pièces, ou encore pour mesure des forces ou des pressions. Somme, la détection de pannes est une méthode importante pour garantir la fiabilité et la durabilité des systèmes mécaniques.

I.5 Diagnostic industriel

I.5.1 Définition Diagnostic

Le diagnostic est l'identification de la cause probable de la (ou des) défaillance(s) à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test [21].

Le diagnostic industriel est une méthode permettant de déterminer si un équipement de production est défaillant et d'identifier la source de la panne dans le but de réparer ou de remplacer les outils défaillants. Elle implique l'utilisation de diverses techniques de mesure et d'analyse pour évaluer les performances des machines et équipements industriels. Le diagnostic industriel peut être réalisé de manière préventive pour prévoir les pannes et éviter les arrêts de production, ou de manière curative pour réparer les machines défaillantes et éviter les surcoûts liés aux arrêts de production. Par conséquent, les diagnostics industriels sont cruciaux pour assurer la fiabilité et la pérennité des équipements de production dans les entreprises industrielles, et peuvent détecter rapidement les problèmes et intervenir efficacement pour les résoudre.

I.5.2 L'objectif du diagnostic

Le diagnostic est une étape initiale et essentielle pour démarrer la maintenance préventive et corrective d'une machine. Par conséquent, le diagnostic des équipements de production est le meilleur moyen de déterminer si l'outil est défaillant ou non, et il permet également de déterminer l'origine du défaut s'il doit être changé ou entretenu.

Pour diagnostiquer les performances industrielles, il est important d'évaluer le flux de travail actuel, d'investir dans la formation des employés de mettre à jour les équipements et les technologies, d'optimiser les processus de production, de gérer efficacement la chaîne d'approvisionnement et d'adopter des pratiques durables. Les méthodes de diagnostic industrielle peuvent également aider à détecter les problèmes de sécurité, de qualité et de conformité ainsi qu'à améliorer les performances environnementales et sociales des entreprises.

En somme, le diagnostic industriel vise à améliorer la productivité, la rentabilité, et la durabilité des entreprises tout en assurant la qualité des produits et la sécurité des travailleurs.

I.5.3 Les étapes des diagnostics

Les étapes de base du diagnostic industriel nécessaires pour conception, développement et exploitation de systèmes d'aide au diagnostic, spécifiés dans la figure (I.6).

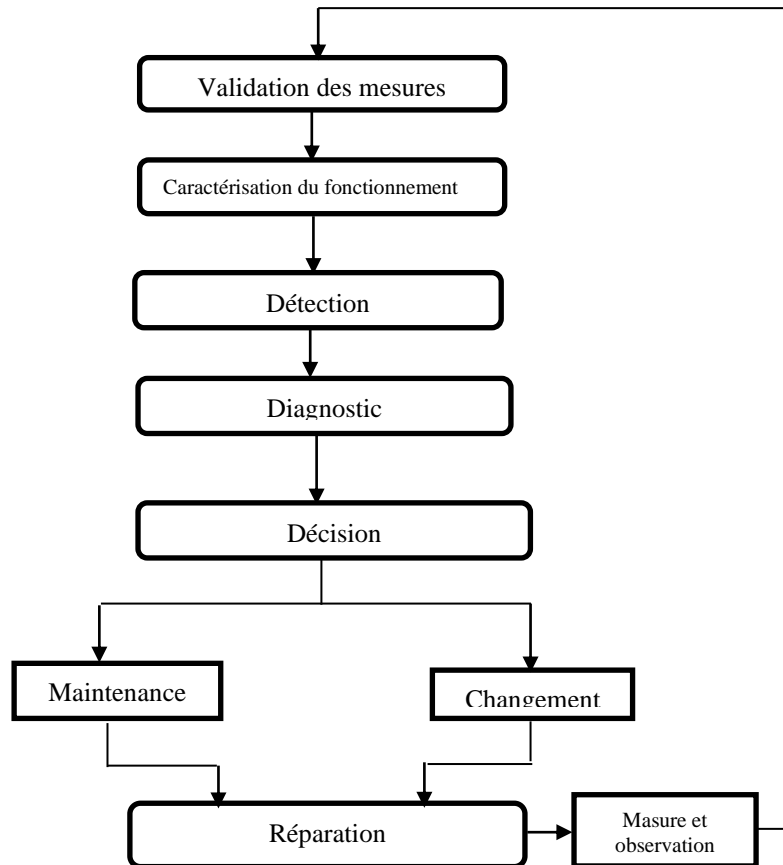


Figure I.6 : les différentes étapes du diagnostic industrie [22].

a) Validation des mesures

Extraire les informations nécessaires au formatage des fonctionnalités connecter fonctionnement normal et anormal, par des mesures ou des moyens appropriés Observations faites par le personnel de surveillance en dehors des rondes de service.

Deux méthodes d'estimation des grandeurs physiques :

- Mesure directe : à l'aide de capteurs,
- Mesure indirecte : estimateur d'état.

b) Caractérisation des performances

Détailler les caractéristiques et les signatures associées aux symptômes

Échec et refus pour découvrir l'échec.

Procédures de vérification, qui sont les opérations qui incluent les informations générées

Il représente une grandeur physique considérée comme valide et fiable et les responsables de cette étape sont les opérateurs et les systèmes de diagnostic.

c) Détection

Détectez les défaillances en fonction des signatures des partenaires

Définition de l'état de santé et des indicateurs de confiance une déclaration. Le bruit de signature est pris en considération à l'aide de certains tests.

d) Diagnostic et décision

Appliquez des méthodes de diagnostic de faute ou de détérioration en utilisant votre connaissance des causes et des effets Les décisions sont basées sur les conséquences futures de l'échec et de la honte. Si tel est le cas, la décision peut conduire à la fermeture de l'établissement Les conséquences comptent.

e) Maintenance ou changement

Sont apportés pour corriger anomalies existantes utilisant un procédé industriel. Pour assurer l'efficacité l'opération a été effectuée, des mesures doivent être prises et traitées.

I.5.4 Les méthodes de détection et diagnostic

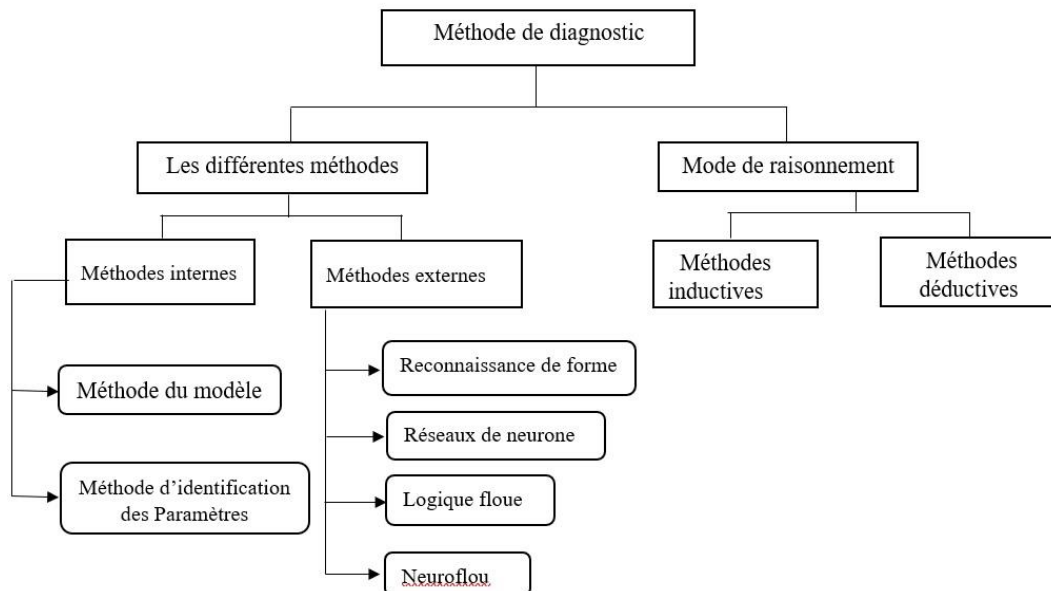


Figure I.7 : classification des méthodes du diagnostic industriel [3].

I.5.4.1 Mode de raisonnement

a) Méthodes inductives

Ces méthodes de diagnostic s'inscrivent dans une démarche prospective. Il s'agit d'identifier l'impact des défauts sur le système. Dans ce cas, nous utilisons un mécanisme de pensée avancé conçu pour interpréter les symptômes afin de repérer les erreurs.

b) Méthodes déductives

Les raisonnements en arrière est la principale caractéristique de ces méthodes. Les méthodes déductives doivent trouver quels sont les effets dans les systèmes. Une vérification des "effets trouvés par rapport aux effets possibles" permet de confirmer ou d'infirmer l'existence du défaut. Ce qui justifie notre raisonnement. [22, 24] Le diagnostic peut utiliser soit un seul type de raisonnement (avant ou arrière) soit une combinaison de raisonnement (avant et arrière). Dans ce dernier cas, le raisonnement est appelé raisonnement mixte ou avant arrière. La connaissance "à priori" de la cause "défaut" implique la connaissance de certains effets [23].

I.5.4.2 Les différentes méthodes

a. Méthodes internes

Ces méthodes sont validées expérimentalement sur la base de modèles physiques ou comportementaux (modèles mathématiques). Ces méthodes se répartissent en deux grandes catégories : Méthodes analytiques itératives utilisant des techniques d'estimation de cas et des techniques d'estimation canonique visant à estimer les paramètres du modèle, la méthode de diagnostic interne varie selon le modèle utilisé.

a.1 Méthode du modèle

Cette méthode est basée sur la comparaison du comportement attendu résultant du modèle dans la bonne exécution du comportement qui a déjà été observé, afin d'explorer écarts et déduire les causes des dysfonctionnements matériels (capteurs ou actionneurs) ou erreur de processus de contrôle.

a.2 Méthode d'identification des Paramètres

La détection et la localisation des pannes par estimation paramétrique consistent à déterminer les valeurs numériques des paramètres structuraux d'un modèle de connaissance qui régit le comportement dynamique du système. Ainsi, la première étape consiste à développer un modèle

mathématique de complexité plausible pour la différenciation des dispositifs dans un processus sain et dégradé. Le type de défauts pouvant être détecté dépend du choix du modèle.

b. Méthodes externes

Les méthodes de diagnostic externe n'ont pas de modèles disponibles pour décrire les relations causales. Seule la connaissance est basée sur l'expérience humaine acquise par l'apprentissage.

Utilisez le système d'identification d'observateur, d'entrée et de sortie du système pour trouver des relations causales. Dans ces méthodes de diagnostic, le facteur décisif est l'algorithme de classification, qui peut tirer toutes les conclusions possibles en fonction de l'ensemble des symptômes qu'il maîtrise, proposer de nouvelles hypothèses et approfondir le diagnostic du système à diagnostiquer en utilisant les informations supplémentaires collectées.

b.1 Reconnaissance de forme

Lorsque les observations sont de type numérique, la méthode de reconnaissance de formes Les modèles peuvent être utilisés dans des problèmes complexes il est souvent difficile à mettre en œuvre. Dans le domaine du diagnostic des machines et les systèmes industriels, cette approche a été mise en œuvre avec succès par de nombreux travail. [25]. Parmi toutes les approches du diagnostic, la reconnaissance des formes est une technique de définition d'algorithmes permettant de classer des objets dont l'aspect a varié par rapport à un objet type. Il s'agit de définir à quelle forme-type une forme observée ressemble le plus [26].

b.2 Réseaux de neurone artificiel

Un réseau de neurones artificiels est un réseau fortement connecté de préprocesseurs fonctionnant en parallèle. Chaque préprocesseur calcule une sortie unique basée sur les informations qu'il reçoit. Il est clair que toute structure hiérarchique de réseaux est un réseau [Les réseaux de neurones artificiels et leur nature associative facilitent la possibilité d'identifier les données incomplètes et bruitées, ce qui contribue à la recherche et au diagnostic du défaut.

b.3 Logique floue

Le principe de fonctionnement du diagnostic basé sur la logique floue consiste à extraire et à calculer les signaux d'entrée, en utilisant les règles linguistiques représentées sous forme de fonctions d'appartenances, ces règles peuvent contenir tous les modèles possibles qui correspondent au mode de défaut considéré [27]. La logique floue fonctionne en exploitant toutes les règles Disponible pour approximer le résultat obtenu. En d'autres termes, il est logique

S'efforce de fournir des solutions à un problème majeur de toutes les réalisations pratiques, par le biais d'utiliser l'expertise de l'opérateur expert.

b.4 Neuroflou

Cette méthode est un réseau de neurones à signal flou qui fonctionne en combinant les concepts de réseaux de neurones logique (ARN) et logique floue (LF) Le système neuronal flou hybride est un réseau neuronal avec un signal flou, des poids flous, une fonction de transfert floue et une unité adaptative de structure RNF par apprentissage d'un [28].

I.6 Conclusion

Dans ce chapitre nous avons présenté les notions de base de la maintenance et diagnostic industrielle, et identifier les différentes méthodes de maintenance et de leur importance en s'appuyant sur la surveillance qui consiste à détecter les défauts puis les diagnostiquer pour les localiser et identifier les pannes.

Dans le chapitre suivant nous allons voir les méthodes de diagnostic par l'apprentissage automatique.

Chapitre II

Modélisation par Apprentissage Automatique

II.1 Introduction

L'apprentissage automatique est un champ assez vaste, c'est un domaine nouvellement émergent dans le monde et se caractérise par un développement rapide et une efficacité croissante de ses performances avec l'augmentation de sa capacité à apprendre, ce qui contribue à sa pénétration dans le domaine industriel (Maintenance industrielle).

Dans ce chapitre, nous explorerons les différentes techniques et les méthodes utilisées en apprentissage automatique pour classer les données selon certaines caractéristiques. Nous discuterons de la définition d'apprentissage automatique, ses différents types et les méthodes de classification, y compris les naïves bayes, les réseaux de neurone et support vecteur machine, utilisés dans la prédiction et la détection des défauts mécanique.

II.2 Intelligence artificielle

Intelligence artificielle appartient au domaine de l'informatique et concerne les approches informatiques ayant pour but de faire apparaître un comportement intelligent. C'est une science s'intéresse à la conception de machines pouvant simuler la cognition humaine. En effet, elle tend à donner à la machine un comportement humain, capable notamment de s'adapter à des situations nouvelles et d'apprendre en permanence. L'IA considère le fonctionnement cognitif comme un processus logique-déductif qui implique la manipulation de symboles de base. En établissant des parallèles entre le fonctionnement du cerveau et celui des ordinateurs, l'IA vise à créer des machines capables d'effectuer des tâches typiquement associées à l'intelligence humaine [29].

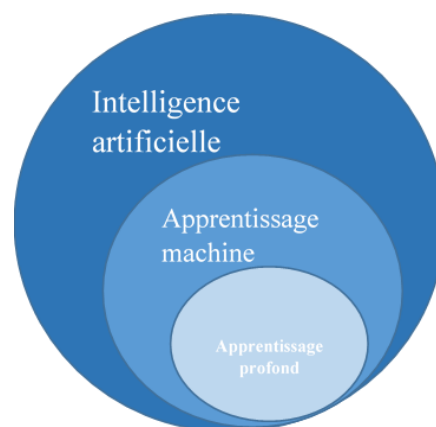


Figure II.1 : Les domaines de l'intelligence artificielle

II.3 Apprentissage automatique

Depuis leur évolution, les humains utilisent de nombreux types d'outils pour accomplir diverses tâches de manière plus simple. La créativité du cerveau humain a conduit à l'invention de différentes machines. Ces machines ont facilité la vie humaine en permettant aux gens de

répondre à divers besoins de la vie, notamment les voyages, les industries et l'informatique. Et l'apprentissage automatique est l'un d'entre eux.

L'apprentissage automatique (machine Learning) est au cœur de la science des données et de l'intelligence artificielle. Que l'on parle de transformation numérique des entreprises, de Big Data. Le machine Learning est devenue incontournable. Ses applications sont nombreuses et variées puis qu'il est entré dans le domaine de la mécanique et de la maintenance industrielle, l'apprentissage automatique concerne la modélisation des données. Les grands principes de ce domaine sont issus des statistiques récurrentes ou bayésiennes, de l'intelligence artificielle ou du traitement du signal.

II.3.1 Définition

L'apprentissage automatique également appelée apprentissage machine ou machine Learning (en anglais) : Parmi les branches de l'intelligence artificielle on trouve l'apprentissage automatique, pour que le système soit considéré comme intelligent, il doit avoir la capacité à apprendre et à tirer parti de ses expériences, afin de pouvoir s'adapter à un environnement variable. L'intelligence artificielle, caractérisé comme l'agencement des techniques utilisées pour fabriquer des machines aptes à montrer une conduite qui peut être qualifiée d'astucieuse.

Ou apprentissage d'ajuster leur modèle et leurs comportements en fonctions des résultats observé. L'apprentissage automatique est une science consiste à concevoir et développer des algorithmes permettant à donner à l'ordinateur ou à une machine la capacité d'apprendre à partir des données d'exécuter des tâches sans avoir été explicitement programmé. [30] Il s'agit exploiter des données brutes, de les transformer en connaissances et ce, de manière automatique afin de prendre de meilleure décision d'affaires. L'apprentissage automatique permet ainsi d'utiliser un modèle d'algorithmes pour piloter des stratégies d'affaires (data-driven strategy). son principal objectif est d'offrir des techniques pour développer cette intelligence. Ces algorithmes ont la particularité, au fil d'un processus appelé entraînement.

II.3.2 Type d'apprentissage automatique

Il existe plusieurs façons d'apprendre automatiquement à partir des données dépendamment des problèmes à résoudre et données disponibles. La figure qui est ci-dessous donne un sommaire de type d'apprentissage automatique les plus connus.

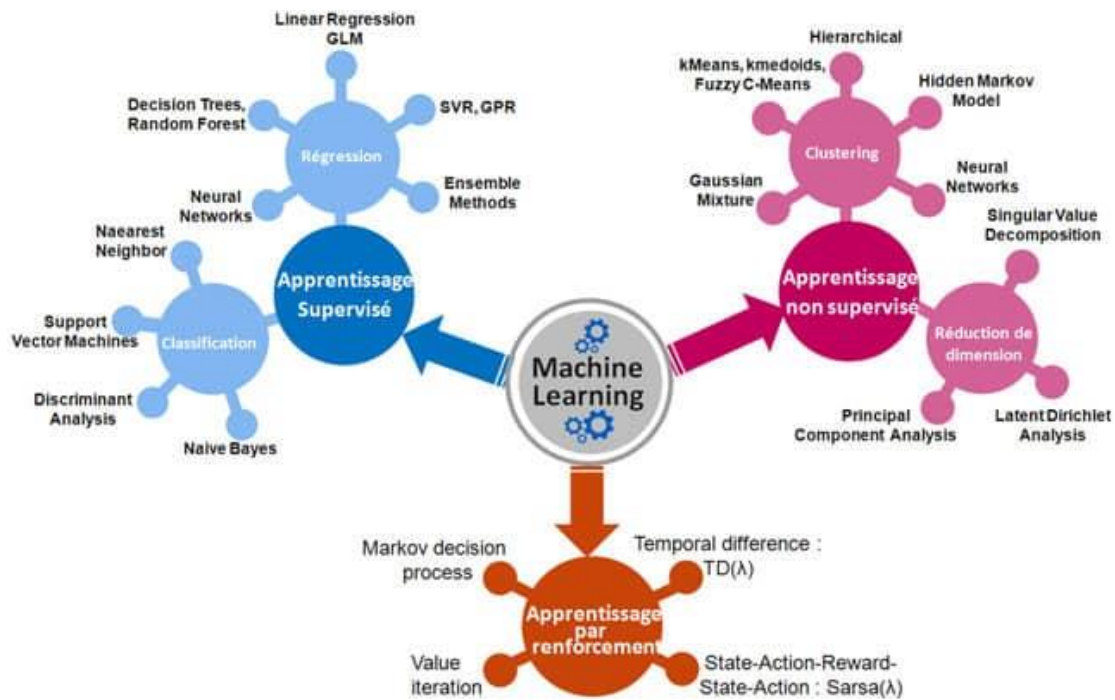


Figure II.2 : Type d'apprentissage automatique [31].

II.3.2.1 Apprentissage supervisé

L'ordinateur est entraîné en utilisant une base de données d'apprentissage contenant des exemples de cas réels traités et validés. L'objectif est de trouver des corrélations entre les données d'entrée (variables explicatives) et les données de sortie (variable à prédire), pour ensuite inférer avec des sorties inconnues [32]. En apprentissage supervisé, on distingue entre deux types de tâches :

Classification : est un type d'apprentissage automatique supervisé dont l'objectif est principalement de définir des règles permettant de classer des objets dans des classes à partir de variables qualitatives ou quantitatives caractérisant ces objets. Les méthodes s'étendent souvent à des variables Y quantitatives. On dispose au départ d'un échantillon dit d'apprentissage dont le classement est connu. Cet échantillon est utilisé pour l'apprentissage des règles de classement. Il est nécessaire d'étudier la fiabilité de ces règles pour les comparer et les appliquer, évaluer les cas de sous-apprentissage ou de sur-apprentissage (complexité du modèle). On utilise souvent un deuxième échantillon indépendant, dit de validation ou de test. La classification est appliquée souvent pour la reconnaissance de formes à titre d'exemples : la reconnaissance de chiffres, la classification de pages web. Les entrées de ces modèles sont des documents (texte ou html), tandis que la sortie sera une catégorie [33].

La régression : La régression est un autre type de méthode d'apprentissage supervisé qui utilise un algorithme pour comprendre la relation entre les variables dépendantes et indépendantes. Les

modèles de régression sont utiles pour prédire des valeurs numériques sur la base de différents points de données. Les algorithmes de régression sont par exemple la régression linéaire, la régression logistique et la régression polynomiale [34].

II.3.2.2 Apprentissage non-supervisé

Quand le système ou l'opérateur ne dispose que d'exemples, mais non d'étiquettes, et que le nombre de classes et leur nature n'ont pas été prédéterminés, on parle d'apprentissage non supervisé (ou clustering). Apprentissage non supervisé, utilise des algorithmes d'apprentissage automatique pour analyser et regrouper des jeux de données non étiquetés. Ces algorithmes découvrent des modèles cachés ou des groupements de données sans nécessiter d'intervention humaine. La similarité est généralement calculée selon la fonction de distance entre paires d'exemples. C'est ensuite à l'opérateur d'associer ou déduire du sens pour chaque groupe. Divers outils mathématiques et logiciels peuvent l'aider [35].

Clustering : L'analyse de cluster implique l'application d'un ou plusieurs algorithmes de clustering avec pour objectif de trouver les modèles ou les groupements cachés dans un Dataset. Les algorithmes de clustering permettent de former des groupements ou des clusters de manière à ce que les données d'un cluster possèdent une mesure de similarité plus élevée que les données de n'importe que autre cluster. L'analyse de cluster est utilisée en bio-informatique pour les analyses de séquences et les regroupements génétiques, en Data Mining pour l'extraction de séquences et de modèles, en imagerie médicale pour les segmentations d'images et en vision par ordinateur pour la reconnaissance d'objets [36].

La réduction de la dimension : est un processus qui permet de réduire le volume d'informations à traiter et faciliter le processus de l'apprentissage. Elle tire avantage de la variance des variables plus précisément de la corrélation entre elles en éliminant la redondance de l'information contenue dans les variables. Nous pouvons classer toutes les techniques Mathématiques de réduction des dimensions en deux grandes catégories :

- La sélection de variables : qui consiste à choisir des caractéristiques dans l'espace de mesure.
- L'extraction de traits : qui vise à sélectionner des caractéristiques dans un espace transformé (dans un espace de projection). La raison pour laquelle une telle opération est utile est que les données de plus petites dimensions peuvent être traitées plus rapidement. Cette opération est cruciale en apprentissage automatique par exemple, pour lutter contre le fléau de la dimension [37].

II.3.2.3 Apprentissage par renforcement

Dans le cadre de l'apprentissage par renforcement, le système d'apprentissage peut interagir avec son environnement et accomplir des actions. En retour de ces actions, il obtient une récompense, qui peut être positive si l'action était un bon choix, ou négative dans le cas contraire. La récompense peut parfois venir après une longue suite d'actions ; c'est le cas par exemple pour un système apprenant à jouer au go ou aux échecs. Ainsi, l'apprentissage consiste dans ce cas à définir une politique, c'est-à-dire une stratégie permettant d'obtenir systématiquement la meilleure récompense possible. Les applications principales de l'apprentissage par renforcement se trouvent dans les jeux (échecs, go, etc.) et la robotique [38].

II.4 Apprentissage profond (« Deep Learning »)

L'apprentissage en profondeur est une méthode d'IA dérivée du concept d'apprentissage automatique. Cette méthode dite d'apprentissage en profondeur repose sur un concept plus spécifique de réseau de neurones artificiels.

De structure non linéaire, un réseau de neurones artificiels se présente sous la forme d'un réseau d'ensembles d'unités d'exécution d'informations (représentant des neurones) empilées les unes sur les autres et associées entre elles par des connexions (synapses). À partir de là, il traite les informations à travers les schémas de propagation d'activité de ces unités, qui fonctionnent au-delà d'un certain seuil. L'apprentissage en profondeur peut être considéré comme une nouvelle étape dans le développement de l'intelligence artificielle. Concernant son origine, ce dernier se contente de respecter des règles prédéterminées basées sur un modèle cognitif. L'intervention d'un programmeur est alors encore nécessaire pour parfaire le système ou intégrer d'autres fonctions ou de nouvelles règles.

À l'instar de la machine Learning statistique, le Deep Learning rend l'IA autonome en lui permettant d'intégrer seule de nouvelles règles. L'amélioration exponentielle de la puissance de calcul et le développement d'applications associées permettent au deep Learning de générer des couches de neurones de plus en plus complexes et denses [39].

II.5 les méthodes d'apprentissage supervisé

L'apprentissage automatique supervisé est divisé en deux parties, la régression et la classification, qui contiennent toutes deux plusieurs méthodes, dont certaines seront abordées.

II.5.1 Naïve Bayes

La classification Naïve Bayes est basée sur l'hypothèse que toutes les caractéristiques sont conditionnellement indépendantes les unes les autres. Cette méthode est basée sur le théorème de

Bayes qui calcule la probabilité d'un événement en utilisant les conditions précédentes pertinentes. Ce théorème a été découvert par un statisticien anglais, Bayes, au 18ème siècle mais il n'a jamais publié l'ouvrage. Après sa mort, ses notes ont été éditées par le mathématicien Richard Price. Le théorème est donné par la formule suivante




Figure II.3 : Modèle de conception en réseau bayésien naïf.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (\text{II.1})$$

Le terme $P(A)$ est la probabilité a priori de A . Elle est « antérieure » au sens qu'elle précède toute information sur B . $P(A)$ est aussi appelée la probabilité marginale de A . Le terme $P(A|B)$ est appelé la probabilité a posteriori de A sachant B (ou encore de A sachant B). Elle est « postérieure », au sens qu'elle dépend directement de B . Le terme $P(B|A)$, pour un B connu, est appelée la fonction de vraisemblance de A . De même, le terme $P(B)$ est appelé la probabilité marginale ou a priori de B .

Dans un problème de classification, notre tâche est de trouver l'étiquette la plus probable A , étant donné les caractéristiques B , le théorème de Bayes devient :

$$P(y|x_1, \dots, x_n) = \frac{P(x_1, \dots, x_n|y)}{P(y)P(x_1, \dots, x_n)} \quad (\text{II.2})$$

Où n représente le nombre de caractéristiques, y est l'évènement qu'on cherche à classer. Par conséquent, en tenant compte de l'hypothèse d'indépendance, Bayes est la classe qui constitue la probabilité la plus élevée [40].

$$y = \arg \max_y P(y) \prod_{i=1}^n P(x_i|y) \quad (\text{II.3})$$

Le théorème de Bayes permet d'inverser les probabilités. C'est-à-dire que si l'on connaît les conséquences d'une cause, l'observation des effets permet de remonter aux causes, c'est l'effet d'induction « Bottom-up ». Sachant aussi qu'une lecture littérale du théorème de Bayes permet une induction « top-down », c'est à dire à partir des causes en déduire les conséquences. Mais il

existe aussi un troisième type d'induction dit « explaining away » ou comment réfuter une cause en constatant une autre, autrement dit partir d'une conséquence pour remonter aux causes, constater la quelle est vraie et réfuter les conséquences sous-jacentes des autres causes. En résumé pour induire sur un réseau bayésien, il faut en premier lieu trouver les probabilités conditionnelles de chaque variable aléatoire avec lesquelles elles sont directement dépendantes. Ce que les experts font à partir des statistiques étudiées sur le système voulu. Puis partir de faits produits auxquels on appliquera une probabilité de 1 ou 0 sur le réseau bayésien suivant qu'ils identifient une variable à vraie ou fautive dans celui-ci. Et enfin par le biais de calcul respectant la règle d'addition et ou de multiplication précédemment décrite, on modifie les probabilités causales et ou conséquentes. La nouvelle probabilité obtenue est l'induction que l'on peut faire sur un réseau bayésien

II.5.2 Machines à Vecteurs Supports (SVM)

SVM est une méthode de classification qui fut introduite par Vapnik (1995). Le succès de cette méthode est justifié par les solides bases théoriques qui la soutiennent. Il existe en effet un lien direct entre la théorie de l'apprentissage statistique et l'algorithme d'apprentissage de SVM. La plupart des techniques du ML possèdent un (trop) grand nombre de paramètres d'apprentissage à fixer par l'utilisateur (structure d'un réseau de neurones, coefficient de mise à jour du gradient, . . .). De plus, avec ces méthodes, le nombre de paramètres à calculer par l'algorithme d'apprentissage est en relation linéaire, voire exponentielle, avec la dimension de l'espace d'entrée. La formulation élégante de SVM laisse très peu de place aux paramètres utilisateurs et le nombre de paramètres est linéaire en la taille du *training set*. SVM est donc une méthode de classification particulièrement bien adaptée pour traiter des données de très haute dimension.

II.5.2.1 Principe de SVM

Une SVM est un algorithme d'apprentissage, permettant d'apprendre un séparateur. Ceci ramène le problème à savoir ce qu'est un séparateur. Elle nous a donné un ensemble fini de vecteurs de \mathbb{R}^n , séparés en deux groupes, ou dit autrement en deux classes. L'appartenance à un groupe ou un autre est défini par une étiquette, associée à chacun des vecteurs, sur laquelle est inscrite « groupe 1 » ou « groupe 2 ». Trouver un séparateur revient à construire une fonction, qui prend un vecteur de notre ensemble, et peut dire de quel groupe il est. Les SVM sont une solution à ce problème, comme le serait un simple apprentissage par cœur des classes associées aux vecteurs de notre ensemble. Mais avec les SVM, on attend de bonnes propriétés de généralisation, à savoir que si un nouveau vecteur de présente, qui n'était pas dans l'ensemble, la SVM saura dire à quel groupe il est vraisemblable qu'appartient, au regard des attributions de

classes des vecteurs présents au départ. 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.

II.5.2.2 Notions de base

a. Hyperplan

Plaçons-nous dans le cas d'une classification binaire (i.e. les exemples à classifier réparties en 2 classes). On appelle *hyperplan séparateur* un hyperplan qui sépare les deux classes figure(II.15). En particulier il sépare leurs points d'apprentissage. Comme il n'est en général pas possible d'en trouver un, on se contentera donc de chercher un hyperplan discriminant qui est une approximation au sens d'un critère à fixer (maximiser la distance entre ces deux classes) [41].




Figure II.4 : L'hyperplan H qui sépare les deux ensembles de points [42].

b. Vecteurs supports

Pour une tâche de détermination de l'hyperplan séparable des SVM est d'utiliser seulement les points les plus proches (i.e. les points de la frontière entre les deux classes des données) parmi l'ensemble total d'apprentissage, ces points sont appelés vecteurs supports [41].




Figure II.5 : L'hyperplan H optimal, vecteurs supports et marge maximale [42].

c. Marge

Il existe une infinité d'hyperplans capable de séparer parfaitement les deux classes d'exemples.

Le principe des SVM est de choisir celui qui va maximiser la distance minimale entre l'hyperplan et les exemples d'apprentissage (i.e. la distance entre l'hyperplan et les vecteurs supports), cette distance est appelée la marge

II.5.2.3 Propriétés fondamentales

a. Pourquoi maximiser la marge ?

Intuitivement, le fait d'avoir une marge plus large procure plus de sécurité lorsqu'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.6, 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.




Figure II.6 : meilleur hyperplan séparateur [42].

II.5.2.4 Classificateur linéaire séparable

Un classificateur est dit linéaire lorsqu'il est possible d'exprimer sa fonction de décision par une fonction linéaire en x qui désignera un vecteur de \mathbb{R}^n . où n est le nombre de composantes des vecteurs contenant les données. On peut, en toute généralité, exprimer une telle fonction comme, ceci :

$$f(x) = (W, x_i) + b = \sum_{j=1}^n W_j x_i^j + b \quad (\text{II.4})$$

Où w est le vecteur de poids et b le biais, alors que x est la variable. X est l'espace d'entrée qui correspond \mathbb{R}^n ou n est le nombre d'attributs des vecteurs d'entrée. n 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 les signes de la Fonction de décision :

$$\left\{ \begin{array}{l} \langle w.x_i \rangle + b \geq 1 \text{ si } y_i = 1 \\ \langle w.x_i \rangle + b \leq -1 \text{ si } y_i = -1 \end{array} \right\} \quad (\text{II.5})$$

Ce qui est équivalent à :

$$y_i(\langle w.x_i \rangle + b) \geq 1 \text{ avec } i = 1 \dots n \quad (\text{II.6})$$

Trouver l'hyperplan optimal revient à maximiser la marge M et donc à maximiser la somme des distances euclidienne (d) des deux classes par rapport à l'hyperplan. Ainsi, la marge est donnée par l'expression suivante :

$$x_b = x_a - d \frac{w}{\|w\|}, \text{ avec } x_b, x_a, w \text{ sont des valeurs et } \frac{w}{\|w\|} \text{ vecteur unitaire } b \text{ étant un point de l'hyperplan } h,$$

alors il satisfait l'équation.

$$\langle w.x_i \rangle + b = 0 \quad (\text{II.7})$$

Dans ce cas, pour x_a qui est un point qui n'appartient pas à l'hyperplan on aura donc :

$$\langle w(x_a - d \frac{w}{\|w\|}) \rangle + b = 0 \quad (\text{II.8})$$

$$\langle w.x_a \rangle - d \frac{\|w.w\|}{\|w\|} + b = 0 \quad (\text{II.9})$$

$$\langle w.x_a \rangle - d \|w\| + b = 0 \quad (\text{II.10})$$

$$d = \frac{\langle w.x_a \rangle + b}{\|w\|} = \frac{f(x)}{\|w\|} \quad (\text{II.11})$$




Figure II.7 : Expression de la marge pour l'exemple xi [41]

II.5.2.5. Classificateur non linéaire séparable

Pour sur monter les inconvénients des cas non linéairement séparable, l'idée introduite par V. Vapnick et qui fait d'ailleurs le point fort des SVM est de projeter l'espace d'entrée sur un espace de plus grande dimension où les données deviennent linéairement séparables. Ce nouvel l'espace est appelé « espace de redescription ». Intuitivement, plus la dimension de l'espace de redescription est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples est élevée [43].

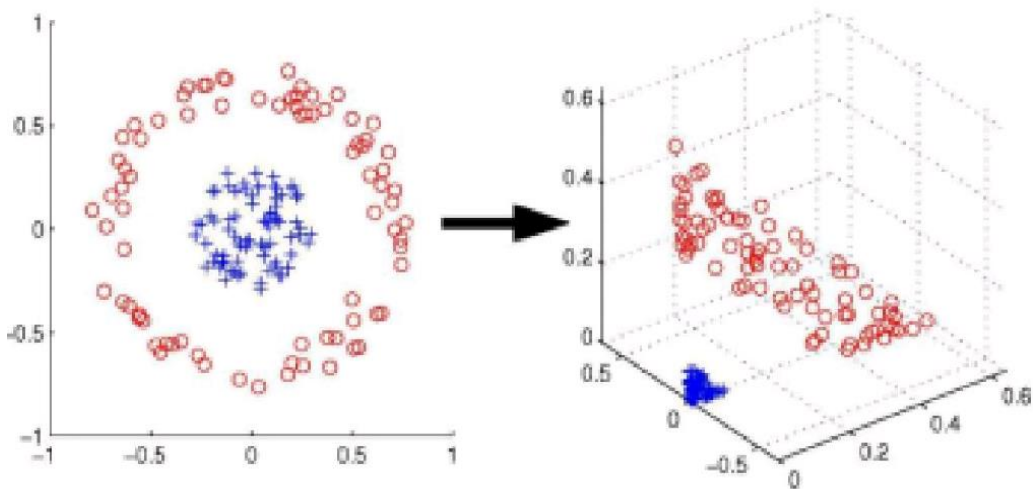


Figure II.8 : Exemple de projection dans un espace de redécritions [43].

II.5.3 Les réseaux de neurones

II.5.3.1 Les neurones artificiels

Les neurones artificiels sont un modèle simplifié de neurones biologiques (Fig. II.9), et ce modèle imite certaines fonctions des neurones biologiques, telles que la mémorisation associative, l'apprentissage et l'action parallèle. Elle est une fonction algébrique non linéaire, paramétrée, à valeurs bornées Le premier modèle d'un neurone artificiel a été présenté dans les années quarante par Mac Culloch et Pitts [44]. Par analogie avec le modèle électrochimique décrit ci-dessus :




Figure II.9 : Modèle de neurone artificiel de M. Culloch et Pitts [45].

II.5.3.2 réseaux de neurones biologiques

Les neurones biologiques sont les blocs de construction fonctionnels fondamentaux du système nerveux. Le cerveau humain contient environ 10 milliards de neurones qui ont une capacité unique à réaliser les propriétés des signaux électriques. Les neurones sont reliés entre eux par des connexions appelées axones, qui peuvent affecter plus d'une personne, le corps cellulaire d'une cellule nerveuse où se déclenche un mécanisme. Cellules axonales qui envoient des messages aux autres neurones (figure). Les neurones sont reliés les uns aux autres par des synapses, dont il existe environ 10 000 milliards. Cela signifie qu'un neurone moyen reçoit des déclenchements moyens de 1000 neurones et contient toutes les informations sur 1000 neurones différents).

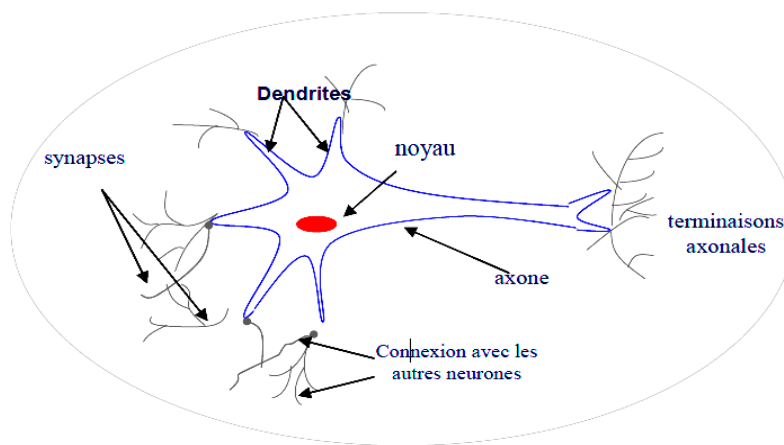


Figure II.10 : Modèle d’un réseau de neurone biologiques [46].

En résumant la modélisation de ces neurones dans le tableau (II.1) et la figure (II.11), nous pouvons clairement voir la transition des neurones biologiques aux neurones formels.

Nerveux biologique	RNA
Synapse	Poids de connexions
Dendrite	Signale d’entrée
Corps du neurone	Fonction d’activation
Axone	Signale de sortie

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

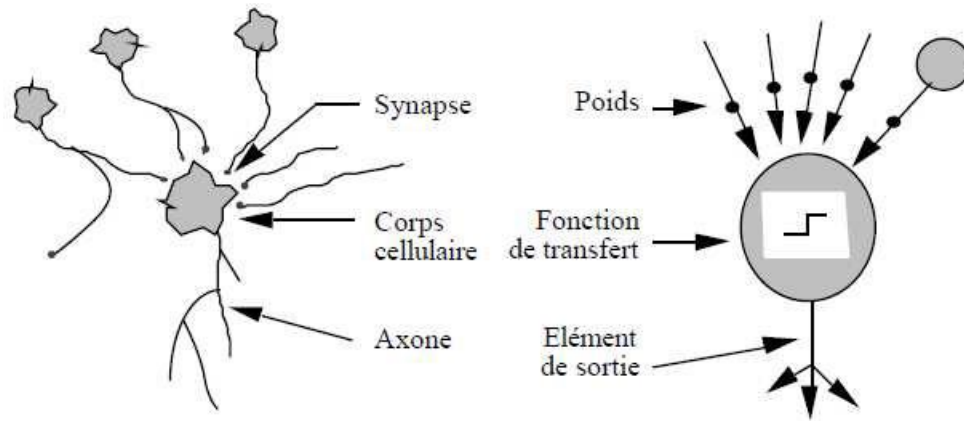


Figure II.11 : Mise en correspondance neurone biologique / neurone artificiel [46].

II.5.3.3 Fonctionnement des neurones artificiels

Le fonctionnement d'un réseau de neurones artificiels peut être complexe, mais il est possible de comprendre les principes de base en examinant comment les neurones sont interconnectés et comment les poids des connexions sont ajustés lors de l'apprentissage. En somme, un réseau de neurones artificiels apprend à effectuer des classifications en ajustant les poids de ses connexions de manière à minimiser l'erreur de classification[47]. Lors de l'apprentissage, les poids des connexions entre les neurones sont ajustés pour minimiser l'erreur dans la classification des données. Pour calculer les poids (w) et les biais (b) dans un réseau de neurones, il est important de comprendre leur rôle dans le processus d'apprentissage. Chaque poids (w_i) peut être interprété comme l'influence relative de l'entrée correspondante (x_i) sur la sortie du réseau de neurones. Ainsi, plus un poids n'est élevé, plus l'entrée correspondant à une influence importante sur la sortie finale du réseau. Quant aux biais (b), ils sont utilisés pour ajuster la sortie du réseau de neurones, en ajoutant un terme constant à la sortie pondérée des [48]. En résumé, pour calculer les poids et les biais dans un réseau de neurones, il est nécessaire de procéder à l'entraînement du réseau à l'aide d'algorithmes d'optimisation tels que la SGD. Le poids (w) détermine l'influence relative à chaque entrée sur la sortie, tandis que le biais (b) permet d'ajuster la sortie du réseau en ajoutant un terme constant à la sortie pondérée des entrées.

II.5.3.4. Modèle mathématique d'un neurone formel

Un neurone artificiel est un préprocesseur qui collecte un nombre variable d'entrées. C'est une fonction algébrique non linéaire et finie dont la valeur dépend initialement des poids (w) de la force de connexion dans chacune de ces entrées. Une sortie est affectée à chaque préprocesseur comme la montre dans la figure. II.12. Par la similitude avec le neurone biologique, la dynamique de neurone formel est modélisée par deux étapes [46] :

- Un opérateur de sommation, qui élabore le potentiel, pour calculer le seuil d'activation g ;
- Un opérateur non linéaire qui donne la limite d'activation de neurone (fonction de transfert)




Figure II.12 : Modèle d'un neurone formel [49].

Le neurone réalise trois opérations sur ses entrées [50]

- a) **Pondération** : multiplication de chaque entrée par un paramètre appelé poids de connexion.
- b) **Sommation** : une sommation des entrées pondérées est effectuée.

Dans cette figure (3), x_j sont les entrées du neurone i , w_{ij} c'est la valeur du poids synaptique des liaisons dirigées aux neurones i vers le neurone

Avec une condition les entrées peuvent être :

- Booléennes.
- Binaires (0,1) ou bipolaires (-1,1).
- Réelles.

Le calcul de la somme pondérée des entrées (s) selon l'expression suivante :

$$S_i = \sum (W_i \cdot X_i) \tag{II.12}$$

A partir de résultats tirés de la somme pondérée, une fonction de seuillage g calcule les paramètres de l'état de neurone, transmise aux neurones suivant, donnée par :

$$A_i = \sum (s_i - g_i) \tag{II.13}$$

A partir de cette valeur, une fonction seuil calcule la valeur de l'état du neurone :

$$Y_i = f(A_i) \tag{II.14}$$

Avec :

X_j : les entrées, qui peuvent être les états des neurones en amont.

W_i : le poids synaptique de la connexion entre les neurones et i .

S_i : la somme pondérée des entrées i .

A_i : l'activité du neurone i .

Y_i : l'état d'un neurone i .

- c) **Les fonctions d'activation** (fonction de transfert) :

Si vous remplacez la valeur de l'expression précédente dans la fonction de transfert qui Calcule la valeur d'état du neurone, c'est la valeur qui sera transmise au neurone en aval. Il y a Plusieurs formes de la fonction de transfert comme le montre la figure (II.13)




Figure II.13 : Fonctions d'activations : (a) du neurone « seuil » ; (b) du neurone « linéaire », et (c) du neurone « Sigmoide »[51]

Nom de la fonction	Relation entrée/sortie	Icône	Nom MATALB
Seuil	$y = 0$ si $s < 0$ $y = 1$ si $s > 0$		hardlim
Seuil symétrique	$y = -1$ si $s < 0$ $y = 1$ si $s > 0$		hardlims
Linéaire	$y = s$		purelin
Linéaire saturée	$y = 0$ si $s < 0$ $y = s$ si $0 < s < 1$ $y = 1$ si $s > 1$		satlin
Linéaire saturée symétrique	$y = -1$ si $s < -1$ $y = s$ si $-1 < s < 1$ $y = 1$ si $s > 1$		satlins
Linéaire positive	$y = 0$ si $s < 0$ $y = s$ si $s > 0$		poslin
Sigmoïde	$y = \frac{1}{1 + e^{-s}}$		logsig
Tangente hyperbolique	$y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$		compet

Tableau II. 2 : Différentes fonctions d'activations utilisées dans les RNA [51].

II.5.3.5 Types de modèles de neurones

a- Modèle d'un neurone à entré simple

Le scalaire d'entrée p est multiplié par le scalaire poids w pour former Wp , un des termes de la somme. L'autre entrée, 1, est multipliée par le biais b , puis introduite dans la somme. La somme de sortie n , souvent dénommée entrée du réseau, passe dans la fonction de transfert f qui produit le scalaire de sortie à voir Figure (II.14) [46].




Figure II.14 : Neurone à simple entrée

Le neurone de sortie est calculé par l'équation :

$$A = f(wp + b) \tag{II.15}$$

La fonction de transfert sélectionnée contrôle la sortie, et le biais et le poids sont approximativement les mêmes sauf qu'il a une valeur d'entrée fixe de 1. Cependant, il peut être contrôlé pour le supprimer ou le laisser en conséquence aux conditions choisies par l'utilisateur.

De plus, w et b sont des paramètres numériques qui peuvent être modifiés pour les neurones. Généralement

La fonction de transfert f est choisie par l'utilisateur et les paramètres w et b sont modifiés par apprentissage des lois afin d'adapter les neurones d'entrée/sortie à une cible précise

b- Neurone à entrées multiples

Typiquement, un neurone possède plus d'une entrée, comme la montre la figure ci-dessous [46].




Figure II.15 : Neurone à entrées multiples.

Les entrées individuelles X_1, X_2, \dots, X_N sont pondérées par les éléments $w_{1,1}, w_{1,2}, \dots, w_{1,N}$

de la matrice W .

Le neurone possède un biais b , sommé avec les entrées pondérées pour former l'entrée n du réseau

$$n = W_{1,1} * X_1 + W_{1,2} * X_2 + \dots + W_{1,R} * X_R + b \quad (II.16)$$

L'équation (III.2) peut être formulée sous forme matricielle

$$n = Wp + b \quad (II.17)$$

II.5.3.6 Le perceptron

Le perceptron est la forme la plus simple de réseau neuronal utilisée Classification de motifs dits linéairement séparables. En gros, c'est Il se compose d'un seul neurone avec des poids synaptiques ajustables et d'une base. Le nœud de sommation du modèle neuronal est calculé linéairement Une combinaison d'entrées appliquées à ses synapses, et il comprend également Bais appliqué à l'extérieur. La somme résultante, qui est appliquée à la constante Le déterminant en conséquence, le neurone a produit une sortie égale à +1 si la constante [51].

II.5.3.7 Architecture d'un réseau de neurones artificiel

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certaine régularité (réseau a connexion complète) [52].

a) Réseau de neurones non bouclé (Feed-forward)

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées, par composition des fonctions réalisées par chacun des neurones [50]. 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 ensuivant 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 [53].

b) Réseaux monocouche (SLP)

La structure d'un réseau monocouche est telle que des neurones organisés en entrée soient entièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids [52]. seules opérations permises pour ce type de neurone sont les opérations ET, OU, et NON, des opérations qui permettent de résoudre uniquement des problèmes linéairement séparables.

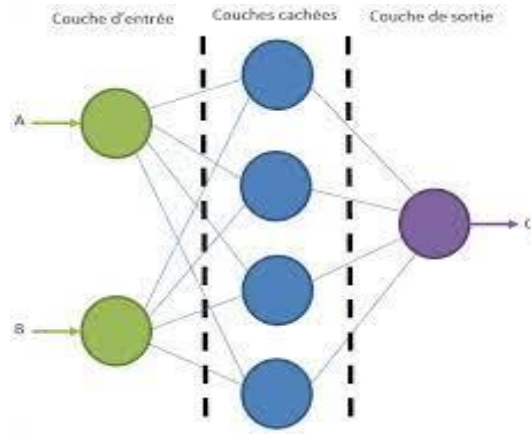


Figure II.16 : Réseaux de neurone monocouche.

Pour comprendre le fonctionnement d'un capteur monocouche, voici les exemples liés aux fonctions booléennes. Pour ce faire, nous allons utiliser les fonctions AND et OR. Qui, comme nous le verrons, sont des fonctions linéairement séparables et la fonction XOR logique c'est une fonction qui ne peut pas être séparée linéairement par un neurone Officiel. Nous allons voir comment l'ajout d'une deuxième couche peut résoudre ce genre de problème.

L'apprentissage supervisé sous la règle de correction d'erreurs est une méthode dont la principale contrainte est qu'elle ne peut résoudre que des problèmes linéairement séparables.

Pour comprendre les portes logiques ET et OU, ceci est présenté sous la forme d'une table de vérité. Nous nous pouvons voir, dans le tableau (II.2), les valeurs d'entrée et de sortie pour chacun des cas.

X_1	X_2	Sortie ET	Sortie OU
0	0	0	0
0	1	0	1
1	0	0	1
1	1	1	1

Tableau II.3 : Table de vérité (ET, OU) [54].

c) Réseaux multicouches (PMC)

Les «Feed-forward networks» : ce sont des réseaux à circulation de l'information vers l'avant, et dont lesquels l'organisation des neurones est en couches successives. Le calcul se fait en propageant les données de l'entrée vers la sortie. Dans cette catégorie on distingue les réseaux à une seule couche (exemple : le Perceptron) et les réseaux multicouches (possédant une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées). Dans ce type, chaque neurone est connecté à tous les neurones de la couche précédente. La figure suivante nous

montre bien son architecture [55].




Figure II.17 : structure d'un réseau neuronal multicouche Feed-Forward.

Ce réseau est considéré comme un système neuronal non linéaire statique. Il existe trois types de réseaux neuronaux multicouches de type Feed-forward qui sont : Le perceptron multicouche **PMC**, le réseau **RBNN** (Radial- Basis- Function Neural Network) et le réseau d'ondelettes **WNN** (Wavelet Neural Network) [56].

d) Réseaux à 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 [45]. 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 [56].

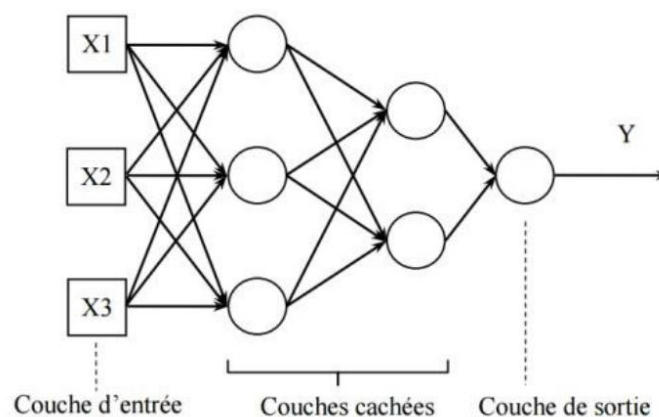


Figure II.18 : Structure d'un réseau de neurones de type RBF.

e) Réseaux récurrents (feed-back)

Appelés aussi « Réseau de neurones bouclé », ce sont des réseaux dans lesquels il y a retour en arrière de l'information. Ces réseaux ramènent l'information en arrière de manière inverse par rapport au sens de propagation défini dans un réseau Multicouche. Ces connexions sont les plus locales [57].

e.1 Les réseaux de Hopfield

C'est l'histoire de ces demandeurs où il y a un retard d'information. Affilier Les connexions entre les types de nerfs et les nerfs qu'ils contiennent sont montrées Cannabis en amont. Ainsi, la sortie d'un neurone du réseau pourrait en être une fonction Cependant, l'idée de temps présente le prix à l'esprit. A Chaque Une connexion d'un neurone en anneau à retard est attachée, un multiple entier de l'unité de temps spécifié. La figure (II.13) montre la structure de ce réseau :




Figure II.19 : Réseaux récurrents.

e.2 ART

Les réseaux ART sont utilisés comme détecteurs de caractéristiques. Pour les modèles dans un système donné avec une information de description interne. Ils Basé sur la théorie de la résonance adaptative (ART). Ces les réseaux peuvent acquérir de nouvelles connaissances sans perdre ce qui a été accumulé précédemment. Ce dernier est intéressant pour la formation continue avec des additifs donnés [46].

e.3 Le modèle de Kohonen

Ce modèle a été présenté par T. Kohonen en 1982 en se basant sur des constatations biologiques, Les cartes de Kohonen sont réalisées à partir d'un réseau à deux couches, une en entrée et une en sortie, les neurones se rassemblent à un niveau où chaque neurone est connecté les uns aux autres et aux neurones qui l'entourent. Connexion entre eux pour être deux neurones bidirectionnels chaque neurone de la couche de sortie possède des connexions latérales récurrentes dans sa couche (le neurone inhibe, les neurones éloignés et laisse agir les neurones voisins) [58].




Figure II.14 : Réseaux cellulaires.

II.6 Conclusion

Dans ce chapitre, nous allons explorer en détail les trois méthodes populaires d'apprentissage automatique utilisées pour la classification. Ainsi que les meilleures pratiques pour construire et évaluer un modèle de classification efficace.

Le chapitre suivant se concentre sur l'outil utilisé pour l'apprentissage automatique, il existe de nombreux outils et bibliothèques qui facilitent le développement, la mise en œuvre et l'évaluation des modèles. Ces outils offrent des fonctionnalités puissantes pour manipuler des données, construire des modèles, les entraîner et les évaluer.

Chapitre III

Étude de cas :
Boite de vitesse

Chapitre III

Étude de cas : Boite de vitesse

III.1 Introduction

Dans ce chapitre, nous allons explorer l'utilisation de KNIME, une plateforme logicielle puissante et polyvalente, pour détecter les dysfonctionnements de la boîte de vitesse à l'aide de méthodes d'apprentissage automatique. KNIME est un environnement de développement visuel qui permet de créer et d'exécuter des flux de travail d'analyse de données et de machine Learning.

III.2 Boite de vitesse

La transmission est une partie importante d'un véhicule à moteur, transmettant la puissance générée par le moteur aux roues. Son fonctionnement dépend du type de transmission utilisé, qui peut être manuelle, automatique ou à variation continue (CVT). Dans une transmission manuelle, le conducteur doit sélectionner manuellement le rapport approprié pour conduire. La boîte de vitesses se compose d'un ensemble d'engrenages qui transmet la puissance du moteur aux roues. Lorsque le conducteur change de vitesse, il engage et désengage l'embrayage pour déconnecter temporairement la transmission de la puissance du moteur. Il peut alors déplacer le levier de vitesses pour sélectionner le rapport souhaité, qui est transmis via l'arbre de transmission à la boîte de vitesses.




Figure III.1 : Boîte de vitesse manuelle

Dans une transmission automatique, un système de commande électronique sélectionne automatiquement le rapport approprié en fonction de la vitesse du véhicule et des conditions de conduite. La transmission se compose d'engrenages et d'un convertisseur de couple qui transfère la puissance du moteur aux roues. Le système de commande électronique utilise des capteurs pour détecter des paramètres tels que la vitesse du véhicule et la position de l'accélérateur et sélectionne le rapport approprié en conséquence.




Figure III.2 : Boîte de vitesse automatique

III.3 Fonctionnement de la boîte de vitesse

La boîte de vitesses est un élément clé du système mécanique ou hydraulique qui permet de faire avancer ou reculer un véhicule en transmettant la puissance et le couple moteur. Le fonctionnement de la boîte de vitesses peut varier en fonction du type de boîte de vitesses, mais en général, il fonctionne selon un principe de sélection de vitesses pour différentes conditions de conduite, telles que le départ arrêté, l'escalade d'une colline ou la croisière sur des routes planes.

[59]. Le principe de fonctionnement de la boîte de vitesses consiste à effectuer une friction entre le baladeur et le pignon afin qu'ils s'approchent de leurs vitesses respectives]. Lorsque le conducteur change la vitesse, la boîte de vitesses utilise une série d'engrenages pour ajuster la vitesse de rotation des roues par rapport à celle du moteur. Par exemple, si le conducteur souhaite passer à une vitesse supérieure, la boîte de vitesses déplace le pignon et le baladeur pour permettre une transmission plus rapide du mouvement de rotation du moteur aux roues. D'autre part, si le conducteur souhaite ralentir ou réduire la vitesse, la boîte de vitesses utilise un processus inverse pour ralentir la rotation des roues. En terme simple, la boîte de vitesses est un élément essentiel du système mécanique ou hydraulique d'un véhicule, qui permet de transmettre la puissance et le couple moteur pour faire avancer ou reculer le véhicule. Le fonctionnement de la boîte de vitesses implique une sélection de vitesses pour différentes conditions de conduite et utilise un principe de friction pour réguler la vitesse de rotation des roues par rapport à regime du moteur.

III.4 Plateforme « Kaggle »

Kaggle est une plateforme disponible en ligne, dont le but de présenté des sources d'informations sous forme des données (DataSet), l'objectif de cette plateforme (fondée en 2010 par Anthony Goldbloom et Jeremy Howard et acquise par Google en 2017) est d'aider les professionnels et les apprenants à atteindre leurs objectifs dans leur parcours en science des données grâce aux puissants outils et ressources qu'elle fournit. À ce jour 2023, il y a plus de 13 millions d'utilisateurs enregistrés sur cette plateforme [60], en plus des fonctions de réseautage plus générales, cette communauté organise des concours d'apprentissage automatique qui se concentrent sur le phénomène de l'utilisation des réseaux de neurones et d'autres outils d'apprentissage automatique pour faciliter les derniers modèles de programmation linéaires et déterministes. Aussi Kaggle gère des ensembles de données publics pour les projets d'apprentissage et de science des données, elle est en train de devenir un endroit où les scientifiques des données et les professionnels connexes font des affaires c-à-d un endroit où l'innovation a lieu et où les gens travaillent vers des objectifs communs impliquant des progrès dans certaines des technologies les plus dynamiques et intéressantes qui composent l'industrie technologique d'aujourd'hui [61].

III.5 KNIME Analytics Platform

Est une plateforme open source dédiée à l'apprentissage automatique, ou machine Learning, et à l'exploration de données. Elle est compatible avec plusieurs langages (notamment R et Python) et systèmes d'exploitation (Windows, Linux...). Son interface permet de modéliser graphiquement des pipelines d'ingestion de données et d'apprentissage machine [61].

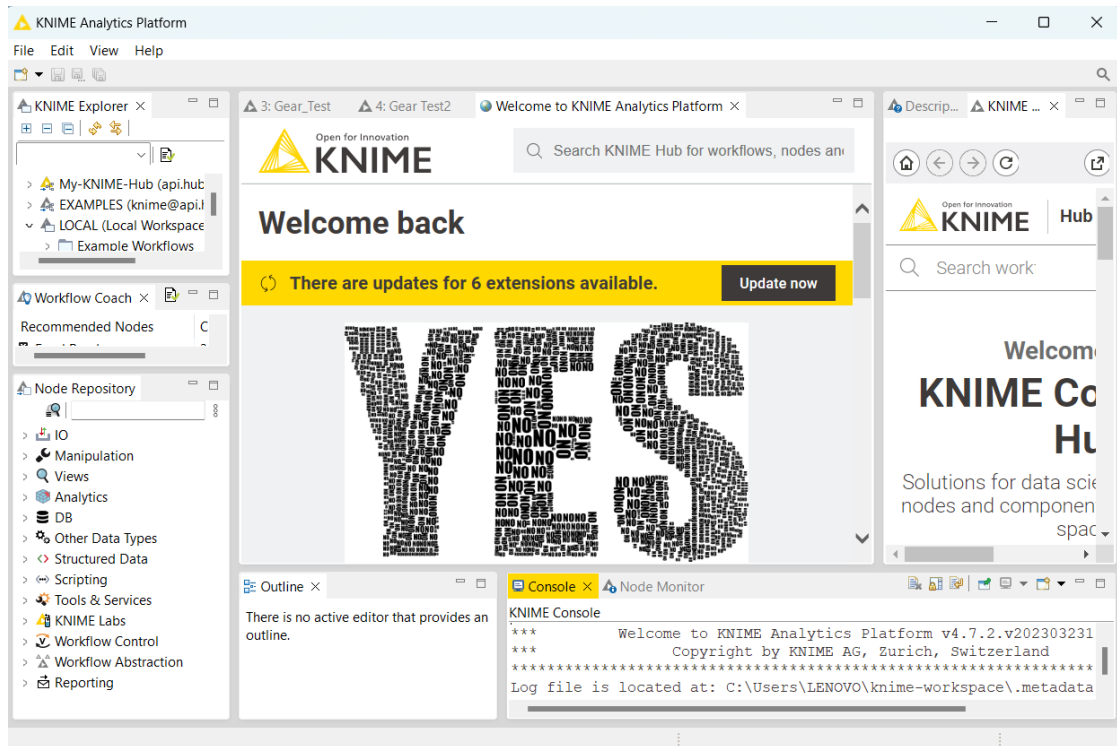


Figure III.3 : KNIME analytique plate-forme .

III.5.1 Les caractéristiques clés de KNIME

L'une des principales caractéristiques est qu'il est gratuit et open source, ce qui signifie que les utilisateurs ont accès à tous les outils d'analyse de données sans aucun coût [63]. Une autre caractéristique clé est son générateur de flux de travail visuel, qui permet aux utilisateurs de créer des solutions de science des données à l'aide d'une interface glisser-déposer. Cela permet aux utilisateurs de créer facilement des flux de travail complexes sans avoir à écrire de code. De plus, KNIME propose un grand nombre de nœuds prédéfinis pour la transformation, l'analyse et la visualisation des données, ce qui permet aux utilisateurs de démarrer facilement leurs projets d'analyse de données. KNIME a également la capacité de mettre en production des solutions de science des données, ce qui signifie que les utilisateurs peuvent facilement déployer leurs flux de travail sous forme de services Web ou de processus par lots. Cette fonctionnalité permet aux utilisateurs d'automatiser leurs workflows d'analyse de données, ce qui facilite le traitement de grandes quantités de données et l'obtention rapide d'informations. De plus, KNIME prend en charge une large gamme de formats de données, notamment les bases de données CSV, Excel et SQL. Il prend également en charge une large gamme d'algorithmes d'apprentissage automatique, ce qui en fait un excellent outil pour les scientifiques des données et les ingénieurs en apprentissage automatique.

III.5.2 Les mesure de performances utilisées

Recall : Il s'agit du nombre exact de Résultats positifs divisé par la somme de positifs corrects et

négatifs incorrect.

$$Recall = \frac{TP}{TP + FN} \quad (III.1)$$

Precision : Il s'agit du nombre exact de Résultats positifs divisé par la somme de positifs corrects et positifs incorrect

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

Sensitivity : Il s'agit du nombre exact de Résultats positifs divisé par la somme de positifs corrects et négatifs incorrect

$$Sensitivity = \frac{TP}{TP + FN} \quad (III.3)$$

Specificity : Il s'agit du nombre exact de Résultats positifs divisé par la somme de positifs corrects et positifs incorrect

$$Specificity = \frac{TP}{TP + FP} \quad (III.4)$$

- Positifs correcte (TP) : est le nombre de services assigne à leur classe correcte
- Négative incorrecte (FN) : est le nombre de ceux pour lesquels le modèle prédit incorrectement leur classe positive comme négative
- Positifs incorrect (FP) : se référé au nombre de services pour lesquels le modèle prédit incorrectement que leurs classes négatives sont positives.

F-measure : Le F-measure est une moyenne harmonisée de précision et de recall. La plage du score F1 est [0, 1]. Il vous indique la précision de votre classificateur (combien de cas il classe correctement), ainsi que sa robustesse (il ne manque pas un nombre significatif de cas). Une précision élevée mais une récupération plus faible vous donne une précision extrême, mais manque alors beaucoup de cas difficiles à classer.

$$F - measure = \frac{2 \times Précision \times Recall}{Précision + Recall} \quad (III.5)$$

III.6 Description du DataSet utilisé

Il existe peu d'ensembles de données sur le génie mécanique, en particulier consacrés à l'application du Machine Learning en milieu industriel. Cet ensemble de données n'était pas encore présent dans Kaggle [60]. D'après kaggle, nous avons extrait un ensemble de données de diagnostic de panne de boîte de vitesses comprend l'ensemble de données de vibration enregistré à l'aide du simulateur de diagnostic de panne de boîte de vitesses de SpectraQuest. L'ensemble de données a été enregistré à l'aide de 4 capteurs de vibrations placés dans quatre directions

différentes et sous une variation de charge de '0' à '90' %. Deux scénarios différents sont inclus :

- Condition saine ;
- Condition de dent cassée.

Il y a 20 fichiers au total, 10 pour une boîte de vitesses saine et 10 pour une cassée. Chaque fichier correspond à une charge donnée de 0 à 90 % par pas de 10 % [60].

III.6.1 DataSet pour le premier cas

Nous avons trouvé dans le kaggle deux fichiers Excel (Panne et pas de Panne) contenant des informations sous forme des fichiers CSV, donc nous avons passé par le filtrage afin de le fusionner à un seul fichier avec les lignes mélangées.

Nbre	Capteur_1 (a1)	Capteur_2 (a2)	Capteur_3 (a3)	Capteur_4 (a4)	Charge moteur	Panne
1	4.779007341	4.518664057	4.063815883	4.636720516	60	1
2	7.105110703	4.219316934	3.989114979	4.0882252	30	0
3	6.149801265	3.736379246	3.361014376	3.297892087	20	0
4	4.826126076	4.579222514	3.919540294	4.717166466	60	1
5	3.866532866	3.89480336	3.35246772	3.89128607	30	1
6	3.269779191	3.375491917	2.698889608	2.900419987	0	1
.
.
.
995	7.820400786	4.266139795	4.43234135	5.396607826	90	0
996	5.903900796	3.948290226	3.146915688	2.95912116	0	0
997	7.508921112	4.365999027	4.19031293	5.042253257	60	0
998	3.776250553	4.120661352	3.34468733	3.33086816	0	1
.
.
.
1368	7.177950729	4.277677267	4.304255124	4.51765391	50	0
1369	5.641183061	4.040197658	3.30507276	3.086484631	0	0
1370	3.938346043	4.227683578	3.55146818	3.871279085	10	1
1371	5.371741131	4.9111259	4.236183173	5.306835977	70	1
.
.
.
2004	7.482585367	4.540170035	4.559027564	4.658617442	80	0
2005	4.558813126	4.23869532	3.799222607	4.639284052	30	1
2006	5.864841287	5.257890975	4.483446827	5.230313771	70	1
2007	5.397482404	4.83760373	4.032436157	5.181940105	50	1
2008	8.210566541	4.765412382	4.572069565	5.214145801	70	0
2009	6.441423533	4.742827877	3.455775729	3.654751051	10	0
2010	3.754655674	3.818720231	3.319166386	3.575999944	20	1

Tableau III.1 : Aperçu sur les données du premier DataSet_1.

III.6.1.1 Apprentissage par le Réseau Bayésien

La figure ci-dessous représente un flux d'apprentissage pour la construction et l'évaluation d'un réseau bayésien, le premier nœud utilisé est le nœud « CSV Reader ». Ce nœud permet d'importer les données à partir d'un fichier CSV ou d'une autre source de données. Le flux continu en créant deux sous-ensembles de données « Train » et « Test ». Le nœud *NBL* prend en entrée le premier sous ensemble des données pour entrainer le modèle *NB* et permettre de générer les prédictions à l'aide du nœud « *NB_Predictor* ». Le reste des nœuds présents dans le flux servent à quantifier et présenter les Résultats de classification.

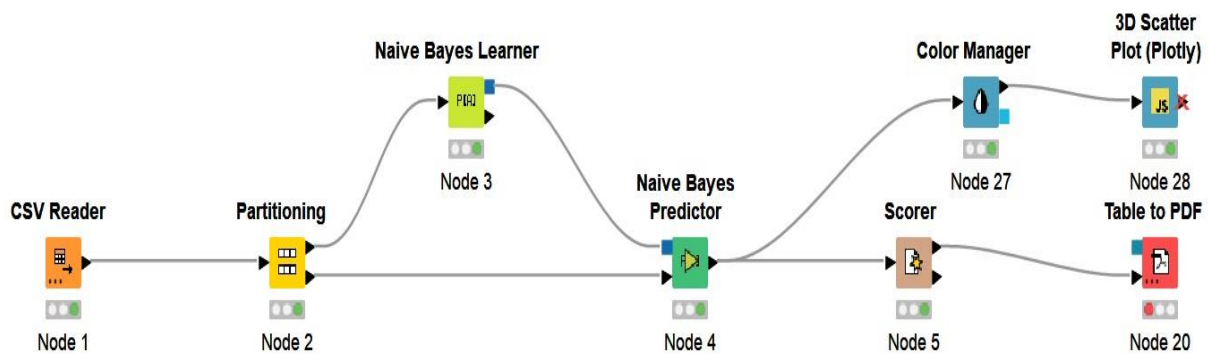


Figure III.4 : Flux d'apprentissage KNIME adopté pour Réseau bayésien

Le tableau III.1 illustre la matrice de confusion pour le modèle *RB* utilisée, il s'agit d'une matrice qui montre le nombre de prédictions correctes et incorrectes effectuées par un modèle de classification. La matrice de confusion permet de visualiser les performances du modèle en termes de vrais positifs, vrais négatifs, faux positifs et faux négatifs.

	1 (panne)	0 (pas de panne)
1	192	7
0	19	184

Tableau III.2 : Matrice de confusions pour *RB*

Recall	1	0.9901478
Precision	0.9648241	0.906403941
Sensitivity	0.9099526	0.963350785
Specificity	0.9648241	0.906403941
F-measure	0.9064039	0.964824121

Tableau III.3 : Statistiques de classifications pour Réseau Bayésien

Accuracy	0.935323383
Cohen'skappa	0.870710769

Tableau III.4 : Résultat de classification globale pour réseau bayésien




Figure III .5 : Résultat de classification sur trois capteurs en 3D

III.6.1.2 Apprentissage par Machines à Vecteurs Supports (SVM)

La figure ci-dessous représente un flux d'apprentissage pour la construction et l'évaluation pour le SVM, le premier nœud représente l'importation des données à partir d'un fichier CSV ou d'une autre source de données. Cela signifie que les données nécessaires pour construire et évaluer le SVM sont récupérées à partir d'une source externe. Ensuite, le flux se divise en deux sous-ensembles de données distincts appelés "Train" et "Test". Cette division est généralement effectuée dans le but d'évaluer les performances du SVM sur des données non vues auparavant. Le sous-ensemble "Train" est utilisé pour entraîner le SVM, tandis que le sous-ensemble "Test" est utilisé pour évaluer sa précision et sa performance une fois qu'il est entraîné. Nous avons adapté 80% pour l'ensemble d'entraînement et 20% pour l'ensemble de test.

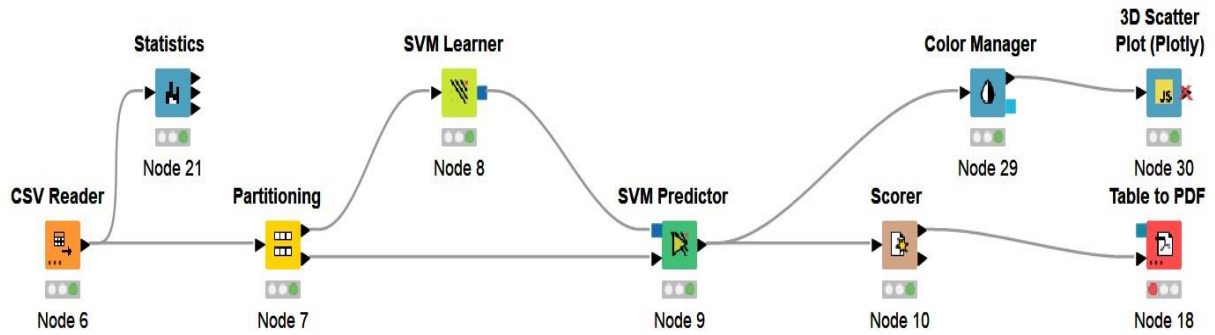


Figure III.6 Flux d'apprentissage KNIME adopté pour le SVM

	1 (Panne)	0 (pas de Panne)
1	199	0
0	0	203

Tableau III.5 : Matrice de confusions pour SVM

<i>Recall</i>	1	1
<i>Precision</i>	1	1
<i>Sensitivity</i>	1	1
<i>Specificity</i>	1	1
<i>F-measure</i>	1	1

Tableau III.6 : les statistiques de classification pour SVM

<i>Accuracy</i>	1
<i>Cohen'skappa</i>	1

Tableau III.7 : Résultat de classification globale pour SVM




Figure III.7 : Résultat de classification les trois capteurs en 3D

III.6.1.3 Apprentissage par Réseau de Neurone

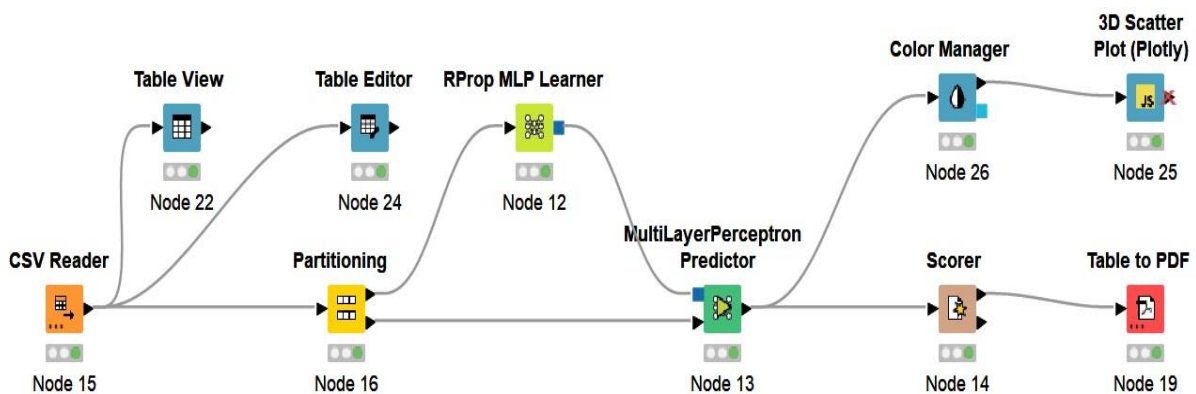


Figure III.8 : Flux d'apprentissage KNIME adopté pour le réseau de neurone

	1 (Panne)	0 (pas de Panne)
1	199	0
0	2	201

Tableau III.8 : Matrice de confusions pour réseau de neurone

Recall	1	0.9901478
Precision	0.9900498	1
Sensitivity	1	0.9901478
Specificity	0.9901478	1
F-measure	0.995	0.9950495

Tableau III.9 : les statistiques de classification pour réseau de neurone

Accuracy	0.995024876
Cohen'skappa	0.990049751

Tableau III.10 : Résultat de classification globale pour réseau neurone




Figure III .9 : Résultat de classification sur les trois capteurs en 3D

III.6.2 DataSet pour le deuxième cas

<i>Nbre</i>	<i>Capteur_1 (a1)</i>	<i>Capteur_2 (a2)</i>	<i>Capteur_3 (a3)</i>	<i>Capteur_4 (a4)</i>	<i>Charge moteurs</i>	<i>Panne</i>
1	12.9319	-1.57425	-3.49169	1.27731	30	0
2	2.10472	-2.82465	0.963435	0.527854	40	1
3	5.98777	-0.153287	0.667509	6.42404	50	0
4	-1.60398	0.208559	2.91099	-0.389152	20	0
5	-36.1813	-9.01271	8.37018	-7.15134	40	0
6	-4.3919	-2.28304	3.48093	-2.99844	10	1
.
.
.
7892	0.314389	-3.4502	-3.23167	2.92783	10	1
7893	-2.70227	4.23483	-2.218	5.25675	0	0
7894	-3.04013	0.352884	-0.0218868	-1.78318	10	0
7895	2.75907	3.00922	0.673788	7.18369	90	1
.
.
.
748982	-3.88709	-2.08533	0.582175	-0.631451	30	1
748983	1.2697	1.22484	2.76459	-3.76787	20	1

748984	5.19088	-1.4601	0.271938	-1.17111	10	1
748985	6.35185	0.375966	-1.92396	-3.36627	50	0
.
.
.
1048566	-3.19735	3.46846	-2.72855	0.256054	90	1
1048567	-1.32225	2.21605	0.718551	-0.45819	20	1
1048568	2.5936	-6.80552	-1.20857	-6.83668	20	0
1048569	-3.09	-0.203311	4.52237	-1.07712	60	0
1048570	8.16752	0.502605	2.78242	1.05185	70	0
1048571	-0.743653	-1.4961	-0.645221	5.27884	80	1
1048572	5.73172	-1.9719	-6.52006	-4.54486	40	1
1048573	2.8851	-4.66344	-1.78503	-3.10449	40	1
1048574	-3.37706	7.17494	-2.28105	2.15027	20	0

Tableau.III.11 : Aperçu sur les donnes du deuxième DataSet_2

III.6.2.1 Apprentissage par réseau bayésien

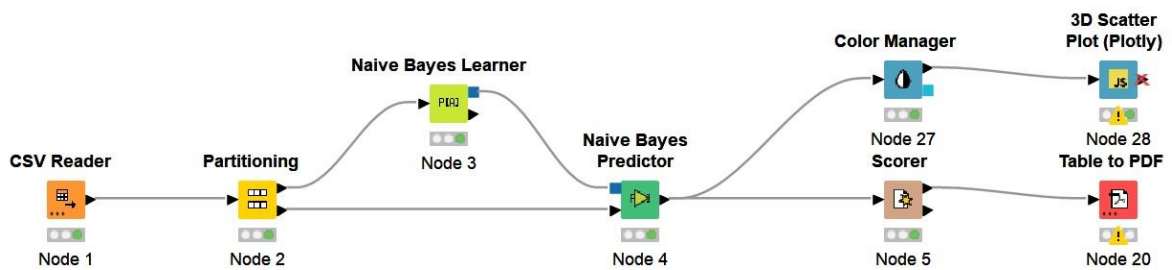


figure III.10 : Flux d'apprentissage knime adopté pour le réseau bayésien

	1 (Panne)	0 (pas de Panne)
1	73814	157963
0	43383	129064

Tableau III.12 : Matrice de confusions pour réseau bayésien

Recall	0,36383442	0,784535089
Precision	0,62982841	0,550341954
Sensitivity	0,36383442	0,784535079
Specificity	0,784535079	0,363834423
F-measure	0,461229399	0,646894894

Tableau III.13 : les statistiques de classification pour réseau bayésien

Accuracy	0,573387528
Cohen's kappa	0,148131498

Tableau III.14 : Résultat de classification globale pour réseau bayésien




Figure III .11 : Résultat de classification sur les trois capteurs en 3D

III.6.2.2 Apprentissage par SVM

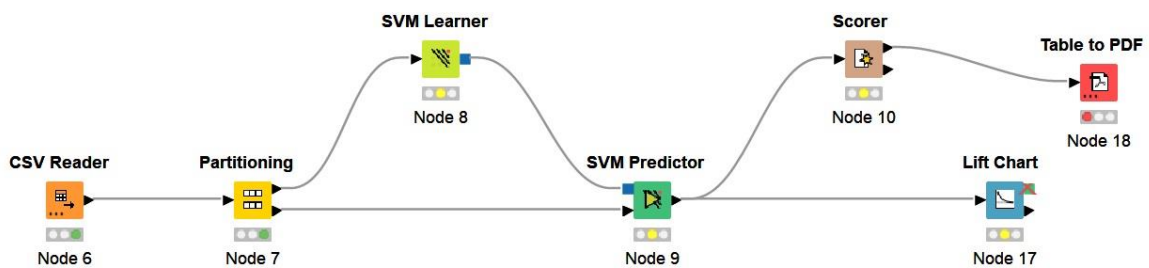


Figure III.12 : Flux d'apprentissage KNIME adopté pour le SVM

III.6.2.3 Apprentissage par réseau de neurone

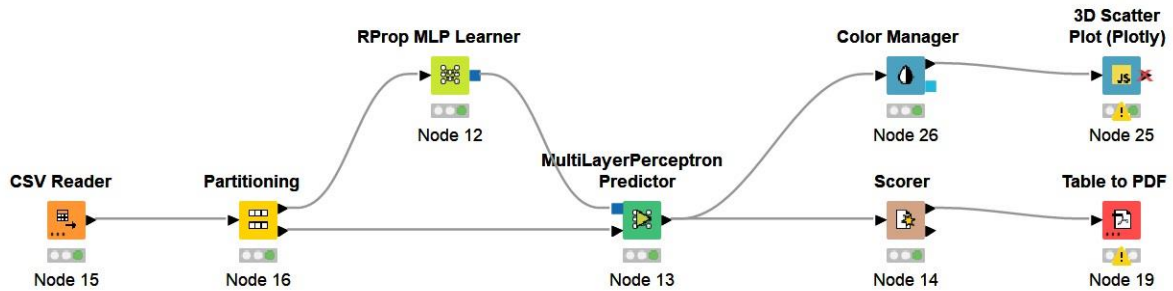


Figure III.13 : Flux d'apprentissage KNIME pour le réseau de neurone

	1 (Panne)	0 (pas de Panne)
1	107095	130544
0	70802	95783

Tableau III.15 : Matrice de confusions pour réseaux de neurone

<i>Recall</i>	0.527878824	0,64835656
<i>Precision</i>	0.602005655	0,576793754
<i>Sensitivity</i>	0.527878824	0,64835656
<i>Specificity</i>	0.64835656	0,527878824
<i>F-measure</i>	0.562510669	0.610485114

Tableau III.16 : les statistiques de classification pour réseaux de neurone

<i>Accuracy</i>	0.587889388
<i>Cohen'skappa</i>	0.176152866

Tableau III.17 : Résultat de classification globale pour réseaux de neurone




Figure III .14 : Résultat de classification les trois capteurs en 3D

III.6.2.4 Comparaison entre les deux DataSets

Le tableau III.18 ci-dessous montre une comparaison entre les deux DataSet utilisé dans cette étude, d’après les Résultats obtenus, nous remarquons que le SVM a été très bien classifié toutes les observations présentes sur le premier DataSet. Le SVM a réussi à faire la classification avec un avantage moyen de 0.49 % par rapport au réseau RProp MLP et de 6.34% comparé aux réseaux bayésiens Naïfs, sur toutes les mesures de performances.

<i>DataSet_1</i>	<i>Recall</i>	<i>Precision</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>F-measure</i>
<i>Naive Bayes Learner</i>	0.9648241	0.9099526	0.9648241	0.9064039	0.936585366
<i>SVM</i>	1	1	1	1	1
<i>RProp MLP Learner</i>	1	0.9900498	1	0.9901478	0.995

Tandis que, sur le deuxième DataSet le SVM n’a pas pu converger dû à la taille du DataSet et des dimensions générées pour séparer les deux classes. Mais la méthode RProp MLP a réussi à faire la classification avec un avantage moyen de 10.90 % par rapport au réseau bayésiens Naïfs.

<i>DataSet_2</i>	<i>Recall</i>	<i>Precision</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>F-measure</i>
<i>Naive Bayes Learner</i>	0.36383442	0.62982841	0.36383442	0.784535079	0.461229399
<i>SVM</i>	N/A	N/A	N/A	N/A	N/A
<i>RProp MLP Learner</i>	0.527878824	0.602005655	0.527878824	0.64835656	0.562510669

Tableau III.18 : Comparaison entre les deux DataSet

III.7 Conclusion

Dans ce chapitre nous avons vu les trois méthodes de classification Rb (Réseaux bayésiens), SVM (Support Vector Machines) et RN (Réseau de Neurone), nous avons aussi étudié trois approches différentes pour résoudre des problèmes de classification. Chacune de ces méthodes présente des avantages et des inconvénients. Les Réseaux bayésiens sont flexibles et peuvent modéliser des dépendances complexes, mais ils peuvent être sensibles à la taille des données et nécessitent une estimation précise des paramètres. Les SVM offrent une bonne capacité de généralisation, mais peuvent être sensibles aux valeurs aberrantes et nécessitent un réglage minutieux des hyperparamètres. Le Naive Bayes est simple et rapide, mais son hypothèse naïve peut limiter sa capacité à modéliser des relations complexes entre les variables.

Conclusion Générale et Perspectives

Conclusion générale

Dans ce travail, notre objectif principal a été de mettre en œuvre un outil d'apprentissage automatique appelé KNIME. Nous avons choisi KNIME comme outil d'apprentissage automatique en raison de sa facilité d'utilisation, de sa flexibilité et de ses fonctionnalités intégrées. Il offre une interface conviviale avec des nœuds préconfigurés qui permettent de réaliser facilement des tâches telles que l'importation des données, le prétraitement, la construction et l'évaluation des modèles, ainsi que la visualisation des résultats.

Nous avons choisi une DataSet d'une boîte de vitesse et nous appliquons les méthodes de l'apprentissage automatique, à cet effet une étude comparative a été faite pour voir les capacités de chaque méthode de classification RB (Réseaux Bayésiens), SVM (Support Vector Machines) et RN (Réseau Neurone), nous avons constaté que le choix entre ces méthodes de classification dépendra du contexte spécifique du problème, de la nature des données et des objectifs de la classification. Comme nous avons conclu qu'il faut tester plusieurs approches et de comparer leurs performances sur un ensemble de validation ou à l'aide de mesures d'évaluation appropriées avant de prendre une décision finale.

Dans un travail de futur, nous espérons élargir le domaine d'étude en considérant d'autres types de causes et pannes.

Bibliographie

Bibliographie

- [1] **S. Belhamdi** « Diagnostic des défauts de la machine Asynchrone contrôlé par différentes techniques de commande » Thèse doctorat, Université Mohamed Khider de Biskra, 2014.
- [2] **L. Benali** « Maintenance industrielle » Office des Publications Universitaires place centrale de Ben Aknoun, Alger, 2006.
- [3] **N. Belhdj, F. Belmahdi** « Application des réseaux de neurones à la détection et la classification des défauts dans les machines tournantes », Mémoire de master, Université Mouloud Mammeri de Tizi-Ouzou, 2010.
- [4] **O. Salmi, M. Bouhafs** « Surveillance et diagnostic des systèmes électroniques par l'analyse fonctionnelle et le réseau neurone Artificiel », Mémoire de master université Mohamed Boudiaf de M'sila, 2020.
- [5] **J-M. Auberville** « Maintenance industrielle de l'entretien de base à l'optimisation de la sureté », Edition Ellipses, Paris, 2004.
- [6] **W. Aliouat** « Le problème conjoint de l'ordonnancement de la production et de planification de la maintenance : cas du Flow Shop Flexible », Mémoire de magister Université M'Hamed Bougera de Boumerdes, 2014.
- [7] https://fac.umc.edu.dz/fstech/cours/G%20transport/L2_GT%20Aca_chapitre%20partie%2001.pdf, site web consulté le mars 2023.
- [8] **D. Racoceanu** « Contribution à la surveillance des Systèmes de Production en utilisant les Techniques de l'intelligence Artificielle », Thèse de doctorat, Université de Franche Comte de Besançon, 2006.
- [9] **E. Deloux** « Politiques de maintenance conditionnelle pour un système à dégradation continue soumis à un environnement stressante », Thèse de doctorat, Université de Nantes, 2008.
- [10] **J. Héng** « Pratique de la maintenance préventive » Dunod, 4ème Edition, 2017.
- [11] **K. A. Nguyen** « Développement de stratégie de maintenance prévisionnelle de système prévisionnelle de système multi-composant ou avec structure complexe », Thèse doctorat, Université Technologie de Troyes, 2015.
- [12] **R. W. Peters** « Maintenance Benchmarking and Best Practices», Edition Mc Grawhil, 2006.
- [13] **M. Abdallah** « Optimisation de la maintenance préventive des systèmes de production incorporant la dépendance par les méta-heuristiques », Thèse doctorat, Université Djilali Liabes de Sidi Bel Abbes, 2015.
- [14] **F. Bnadou** « Diagnostique de panne d'un système pompage photovoltaïque », Mémoire de magister, Université Mouloud Mammeri de Tizi-Ouzou, 2010.
- [15] **S. Bensaada, D. Feliachi** « La maintenance industrielle », Office des Publications Universitaires place centrale de Ben Aknoun, Alger, 2015.
- [16] **D. Halimi** « Contribution à l'amélioration de la maintenance préventive des machines dynamiques dans l'industrie des hydrocarbures », Thèse de Doctorat Université Mohamed Bougara de Boumerdes, 2014.

- [17] **S. Beleulmi, A. Bellaouar** « Cours de fiabilité maintenabilité disponibilité », Université Constantine, 2013.
- [18] **N. Mekroud** « Intégration des techniques du Data mining dans le processus de gestion des connaissances ces basée sur le raisonnement à partir de cas : Application à la maintenance industrielle », Mémoire magister, Université Ferhat Abbas de Sétif, 2009.
- [19] **M. B. Gemmour** « Introduction aux techniques de détection des défaillances », Cours, Université Ibn Khaldoun de Tiaret, 2023.
- [20] **D. Frihi** « Maintenance industrielle », Cours, Université de Guelma, 2015.
- [21] **P. Ribot** « Vers l'intégration diagnostic-pronostic pour la maintenance des systèmes complexes », Thèse doctorat, Université de Toulouse, 2009.
- [22] **M. Ben Rahmoune** « Diagnostic des défaillances d'une turbine à gaz à base des réseaux de neurones artificiels pour l'amélioration de leur système de détection des vibrations », Thèse de doctorat, Université de Djelfa, 2017.
- [23] **G. Didier** « Modélisation le diagnostic de la machine asynchrone en présence de défaillances » thèse de doctorat, Université Henri Poincaré, Nancy1, 2004.
- [24] **T. Boumegoura** « Recherche de Signale électromagnétique des défauts dans une machines asynchrones et synthèse d'observateurs en vue du diagnostic », Thèse de doctorat, Ecole centrale de Lyon France, 2001.
- [25] **B. Dubuisson** « Diagnostic et Reconnaissance des Formes », Série diagnostic et Maintenance, Editions Hermès, Paris, 1990.
- [26] **M. R. Zemmour** « Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamique », Thèse de doctorat, Université de franche comté, 1990.
- [27] **D.Hadiouche, H. Razik et A. Rezzoug**, « Modelling of a double-star induction motor with an arbitrary shift angle between its three phase windings », EPEPEMC. 2000.
- [28] **D. Nauck** « Fuzzy Neural Systems: Review and Prospects », *Conference on Intelligent Technology and Screening Computing*, Aachen, Sep 8-11, 1997.
- [29] **N. Zerari** « Les algorithmes en maintenance », Mémoire magister, Université de Batna 2, 2006.
- [30] **A. Chentouf, B. Imeklef** « Etude de diagnostic intelligent des défauts mécaniques dans les machines tournantes », Mémoire de master, Université Mohamed Seddik Benyahia-Jijel, 2021.
- [31] <https://blog.clevy.io/fr/le-machine-learning-decrypte-3-3-types-dapprentissage-et-limites/> , site web consulté le 10 mai 2023.
- [32] <https://fr.linedata.com/quese-ce-que-lapprentissage-supervise>, site web consulté le 05 juin 2023.
- [33] Classification supervisée Aperçu de quelques méthodes avec le logiciel R, http://www.math.univangers.fr/~labatte/classification_nsupervisee.pdf, site web consulté le 02 avril 2023.
- [34] <https://mobiskill.fr/blog/consiels-emploi-tech/apprentissage-suoervise-vs-apprentissage-non-supervise>, site web consulté en avril 2023.
- [35] <https://www.ibm.com/fr-fr/topics/unsupervised-learning>, site web consulté en avril 2023.
- [36] <https://fr.mathworks.com/discovery/cluster-analysis.html>, site web consulté en avril 2023.
- [37] <https://24pm.com/117-definitions/338-reduction-de-dimensionnalite>, site web consulté en

avril 2023.

- [38] **C. A. Azencott** « Introduction au Machine Learning », Editions Dunod, 2018.
- [39] <https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1501333-deep-learning-definition-et-principes-de-l-apprentissage-profond/>, site web consulté en avril 2023.
- [40] **A. Guenninche** « Prédiction des propriétés des matériaux par apprentissage automatique », Mémoire de master, Université Abou-Bekr Belkaid de Tlemcen, 2019.
- [41] **N. Marref** « Apprentissage incrémental et Machines à vecteurs supports », Mémoire de magister, Université Hadj Lakhdar de Batna 2, 2013.
- [42] **S. M. Mostefaoui** « Classification des documents par apprentissage » Mémoire de magister Université Ibn Khaldoun de Tiaret, 2010.
- [43] **R. Lekhal** « Application des SVM pour la reconnaissance d'extrasystoles » Mémoire de master Université Mouloud Mammeri Tizi-Ouzou 2015.
- [44] **G. Dreyfus** « Réseaux de neurones méthodologie et application », Edition Eyrolles, 2002.
- [45] **B. Ammar** « Détection des défauts par les réseaux de neurones Artificiels de la machine asynchrone contrôlée par la technique du flux orienté », Mémoire d'ingénieur, Université Mohamed Boudiaf de M'sila, 2007.
- [46] **T. Claude** « Les réseaux de neurones artificiels-Introduction au connexionnisme », Editions la Machotte, 2016.
- [47] <https://datascientest.com/fonctionnement-des-reseaux-neurones>, site web consulté en mai 2023.
- [48] <https://www.miximum.fr/blog/introduction-au-deep-learning-1>, site web consulté en mai 2023.
- [49] **M. Y. Ammar** « Mise en œuvre de réseaux de neurones pour la modélisation de cinétique réactionnelle en vue de la transposition Batch/Continu » Thèse de doctorat, Ecole Nationale d'Ingénieurs de Sfax, Tunisie 2007.
- [50] **M.M. Al-Mushiaa, Z. Aoukli** « Technique de diagnostic des défauts dans les systèmes électriques par les réseaux de neurones (machine asynchrone) », Mémoire de magister, Université de Mohamed El-Bachir El-Ibrahimi-Bordj Bou Arreridj, 2022.
- [51] **Z. Falah** « Advanced Intelligent Applications-Perceptron Neural Network », cours, Babylon University-Science College for Women, Iraq, 2022.
- [52] **D. Kadous** « Utilisation des réseaux de neurones comme outil du datamining : Génération de modèle comportemental d'un processus physique à partir de données », Mémoire de master, Université Abou-Bakr Belkaid de Tlemcen, 2012.
- [53] **M.C. Laoubi** « Contrôle d'un pendule inversé par un réseau de neurones artificiels » Mémoire de master, Université Akli Mohand Oulhadj de Bouira, 2018.
- [54] **M. Djouada** « Etude des performances de la classification par couplage réseaux de neurones artificiels - algorithmes génétiques : application au diagnostic vibratoire », Mémoire de magister, Université Ferhat Abbas de Sétif 1, 2018.
- [55] **I. Mellal** « Implémentation d'un réseau de neurones d'un micro capteur sur un FPGA » Mémoire de master Université Mouloud Mammeri de Tizi-Ouzou, 2010.
- [56] **Y. Djeriri** « Les Réseaux de Neurones Artificiels », Mémoire de magister. Université de Sidi-Bel-Abbès, 2017.
- [57] **E. M. Brakni** « Réseaux de neurones artificiel appliqués à la méthode électromagnétique

- transitoire Infini » Mémoire de magister, Université du Québec, 2011.
- [58] **M. T. Khadir** « Principe de base des réseaux de neurones artificiels et apprentissage », Mémoire de magister, Université de Annaba, 2009.
- [59] <https://www.unevoiture.com/rudiments/le-fonctionnement-de-la-boite-de-vitesse-manuelle> site web consulté en avril 2023.
- [60] <https://www.datacamp.com/blog/what-is-kaggle> (La dernière consultation mai2023)
- [61] <https://www.kaggle.com> site web consulté en avril 2023.
- [62] <https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1505649-knime> site web consulté en mai 2023.
- [63] <https://www.knime.com/> site web consulté en mai 2023.

ملخص:

الهدف من هذه الأطروحة هو مراقبة علبة سرعة لسيارة بواسطة أداة ناتجة عن آلة التعلم، وذلك من خلال ثلاثة طرق، شبكات العصبية، شبكات بايزي، نظام الدعم الالي وتعتبر هذه الأدوات من أفضل الأشكال المستخدمة في التفكير غير المؤكد. من أجل مراقبة هذا النظام الميكانيكي، قمنا بمقارنة هذه النماذج من خلال التعلم من البيانات التاريخية التي تم جمعها من مراقبة سلوك علبة السرعة. يسمح نموذجنا بمعرفة حالة علبة السرعة للنظام المرصود من خلال استنتاج يعتمد على الأحداث المرصودة. أثبتت النتائج التي تم الحصول عليها من خلال الدراسة أن هذه النماذج لها تأثير قوي جدًا وتعطي نتائج مرضية في مجال الصيانة الصناعية.

الكلمات المفتاحية: الصيانة ، النمذجة ، شبكات العصبية ، شبكات بايزي ، نظام الدعم الالي

Résumé :

L'objectif de ce mémoire est de surveiller la boîte de vitesses d'une voiture au moyen d'un outil d'apprentissage automatique, à travers trois méthodes, Réseau Bayésien, Machine à Vecteurs de Support, Réseau de neurone ces outils sont parmi les meilleures formes de pensée incertaine.

Afin de surveiller ce système mécanique, nous avons comparé ces modèles en apprenant des données historiques recueillies à partir de l'observation du comportement de la boîte de vitesses. Notre modèle permet de connaître l'état de la boîte de vitesses du système observé grâce à une inférence basée sur les événements observés.

Les résultats obtenus grâce à cette étude ont prouvé que ces modèles ont un effet très fort et donnent des résultats satisfaisants dans le domaine de la maintenance industrielle.

Mots clés : Maintenance, Modélisation, Réseau de Neurone, Réseau bayésien, Machine à Vecteurs de Support.

Abstract:

The objective of this thesis is to monitor the gearbox of a car by means of a machine learning tool, through three methods, Neurol network, Bayesian networks, Support vector machines, these tools are among the best forms of uncertain thinking.

In order to monitor this mechanical system, we compared these models by learning from historical data gathered from observing the behavior of the gearbox. Our model makes it possible to know the state of the gearbox of the observed system thanks to an inference based on the observed events.

The results obtained through this study have proven that these models have a very strong effect and give satisfactory results in the field of industrial maintenance.

Keywords: Maintenance, Modeling, Neurol Network, Bayesian Networks, Support Vector Machine.