

République Algérienne Démocratique et Populaire

الجمهورية الجزائرية الديمقراطية الشعبية

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

وزارة التعليم العالي و البحث العلمي



UNIVERSITE MOHAMED SEDDIK BEN YAHIA - JIJEL

Faculté des Sciences et de Technologie

Département de Génie Mécanique



Projet de fin d'étude

Pour l'obtention du diplôme de Master

En Génie Mécanique

Option (Construction Mécanique)

Thème

Etude de diagnostic intelligent des défauts mécaniques
dans les machines tournantes

Les membres du jury :

M. Y. SAADALLAH

M. H. FENINECHE

M. R. BELHADEF

Président

Encadreur

Examineur

Présenté par :

IKHLEF Bilal

CHENTOUF Abdelmoumin

Promotion 2021

Remerciement

Nous remercions avant tout Dieu le tout puissant de nous avoir guidé et illuminer notre chemin afin de dépasser tous les obstacles que nous avons rencontrés. Sa bénédiction nous a beaucoup aidés pour mener à bien ce travail.

Nos plus sincères remerciements et reconnaissances vont spécialement à notre directeur de mémoire fin d'étude Mr. FENNINECHE Hocine pour la qualité de son encadrement, sa confiance, ses encouragements, ses orientations et son suivi malgré ses occupations.

Nous tenons à remercier également l'ensemble du jury qui nous ont honorés avec leur présence dans cette soutenance et d'avoir accepté d'examiner et d'évaluer ce travail.

Nous exprimons notre gratitude à tous les enseignants du département de génie mécanique pour leur dévouement et leur assistance tout au long de notre cursus universitaire.

Dédicace

Je dédie ce modeste travail à :

Mes chers parents pour leurs encouragements tout au long de mon parcours, leur soutien et leurs sacrifices,

Toute ma famille,

Mes frères et,

Mon binôme : Abdou,

Mes amis et tous mes collègues.

BILAL

Dédicace

A mes très chers parents,

*Rien au monde ne vaut les efforts fournis jour et nuit
pour mon éducation*

*Ce travail est le fruit des sacrifices que vous avez
consentis pour ma formation,*

Toute ma famille,

Mes frères et ma sœur Soumia,

Mon binôme ; Bilal,

Mes amis, tous mes collègues et surtout

Youcef et Nasro.

ABDELMOUMIN

Tableau des matières.

INTRODUCTION GENERALE.....	1
----------------------------	---

CHAPITRE I

ETUDE BIBLIOGRAPHIQUE SUR LE DIAGNOSTIC DES MACHINES TOURNANTES

I.1	Introduction.....	4
I.2	Machines tournantes	4
I.3	Défauts mécaniques des machines tournantes	5
I.3.1	Défauts de Roulement	5
I.3.1.1	Mode de défaillance des roulements.....	6
I.3.2	Défauts d'engrenage.....	6
I.3.3	Défauts liés aux arbres	7
I.3.3.1	Le Déséquilibre (défaut de balourd)	7
I.4	Diagnostic	8
I.5	Les méthodes de diagnostic	9
I.5.1	Les méthodes Classiques.....	9
I.5.1.1	La thermographie infrarouge	10
I.5.1.2	L'émission acoustique.....	10
I.5.1.3	L'analyse Des huiles	10
I.5.1.4	L'analyse vibratoire	11
I.5.1.4.1	Analyse temporelle.....	12
I.5.1.4.2	Analyse fréquentielle	13
I.5.2	Diagnostic intelligent	14
I.5.2.1	Machine Learning	15
I.5.2.2	Système expert.....	15
I.6	Conclusion	16

CHAPITRE II

DIAGNOSTIC BASE SUR LA METHODE MACHINE LEARNING

II.1	Introduction.....	18
II.2	Définition d'une machine learning [9].....	18
II.3	Ingrédients de la machine learning	19
II.4	Fonctionnement du Machine Learning	20
II.4.1	Apprentissage supervisé	20

II.4.2	Apprentissage non supervisé	21
II.5	Diagnostic basé sur la méthode Machine learning	22
II.5.1	Les Réseaux Bayésiens.....	23
II.5.2	Réseau neuronal artificiel	24
II.5.2.1	Fonctionnement	26
II.5.2.2	Modèle biologique	26
II.5.3	Les machines à vecteurs supports.....	27
II.5.4	Arbre de décision.....	29
II.5.4.1	Définition d'Arbre de décision	29
II.6	Conclusion	31
CHAPITRE III APPLICATION SUR DES SIGNAUX REELS		
III.1	Introduction.....	33
III.2	Description de la boîte outils	33
III.3	Description du banc d'essai	36
III.4	Présentation des signaux	37
III.5	L'analyse temporelle et spectrale.....	38
III.5.1	Les indicateurs temporels	38
III.5.2	Les indicateurs fréquentiels	40
III.6	Classification des indicateurs.....	40
III.6.1	Préparation des données a classifié	41
III.6.2	Classification par l'application classification Learner :	42
III.6.2.1	Etape 1 : Création et entraînement d'un modèle avec Machine Learning ..	42
III.6.2.2	Etape 2 : Validation du modèle de classification	44
III.6.2.3	Etape 3 : Test du modèle	45
III.6.3	Interprétation des résultats.....	46
III.7	Conclusion	50
Conclusion générale		51

Tableau des figures.

FIGURE I.1 : Composants de la machine tournante.....	4
FIGURE I.2 : Section d'un roulement à billes avec (n) billes.	5
FIGURE I.3 : schéma de défauts d'engrenage.	7
FIGURE I.4 : Tolérances d'usinage sur un rotor.	7
FIGURE I.5 : défaut de balourd.....	8
FIGURE I.6 : Spectre théorique d'un défaut de balourd.	8
FIGURE I.7 : Différentes méthodes d'analyse.	9
FIGURE I.8 : Technique infrarouge appliqué au moteur électrique.	10
FIGURE I.9 : Exemple de diagnostic avec l'analyse des vibrations.	12
FIGURE I.10 : Structure d'un système de diagnostic intelligent.	14
FIGURE I. 11 : Architecture d'un système expert.....	15
FIGURE II.1 : L'apprentissage supervisé et l'apprentissage non supervisé sont deux techniques de Machine Learning [16].	20
FIGURE II.2 : Le clustering identifie des modèles cachés dans vos données [10].	22
FIGURE II.3 : Principe de l'algorithme Naïve Bayes [17].	23
FIGURE II.4 : Organigramme de l'algorithme Naïve Bayes [17].....	24
FIGURE II.5 : L'architecture d'un réseau de neurones.....	25
FIGURE II.6 : Modèle d'un neurone artificiel.....	25
FIGURE II.7 : Représentation simplifiée de neurone.....	27
FIGURE II.8 : Principe de l'algorithme SVM [17].	28
FIGURE II.9 : Organigramme de l'algorithme SVM [17].	29
FIGURE II.10 : Arbre de décision [17].	31
FIGURE III.1 : Interface MATLAB.	34
FIGURE III.2 : Les icônes disponibles au APPS.	34
FIGURE III.3 : La fenêtre de Classification learner.	35
FIGURE III.4 : La fenêtre de « New Session from workspace ».	35
FIGURE III.5 : Banc d'essai des roulements.	36
FIGURE III.6 : Signaux temporels, différents diamètres du défaut sur la bague intérieure.	37
FIGURE III.7 : Schéma descriptif de la méthode Machine Learning (création du modèle, Test).....	41
FIGURE III.8 : La fenêtre de « New Session from workspace ».	42

FIGURE III.9 : La fenêtre de « classification learner ».	43
FIGURE III.10 : Fenêtre « workspace », le modèle de classification.	43
FIGURE III.11 : Le programme de travail « fonction » affiche dans la fenêtre editor.	44
FIGURE III.12 : L'application des étapes de prédiction avec les données de test.....	45
FIGURE III.13 : L'application des étapes de prédiction avec les données de validation.	46
FIGURE III.14 : Nuage de points (scatter plot).	47
FIGURE III.15 : Na matrice de confusion (confusion matrix).....	48
FIGURE III.16 : N'arbre de décision.	49

Liste des tableaux

Tableau I.1 : Résumé ces modes de défaillance.....6

Tableau III. 1 : Les indicateurs temporelle pour le coupler 3HP avec diamètres de défaut...39

Tableau III. 2 : Les énergies dans les bandes de fréquence du spectre d'enveloppe.....40

INTRODUCTION GENERALE

Les machines tournantes de toutes sortes : pompes, moteurs, ventilateurs, engrenages... etc., ont une grande importance dans tous les domaines industriels, en raison de leur rôle efficace dans tous les processus industriels et surtout dans la transmission de puissance.

Pour éviter tout temps d'arrêt de ces machines, il est nécessaire de surveiller en permanence ces équipements, tous les signes avant-coureurs de pannes, avant qu'il ne soit trop tard.

La méthode d'analyse vibratoire fait partie des méthodes bien connues de diagnostic des machines tournantes. Le principe de base de cette méthode est d'étudier les différents types de vibrations émanant des machines tournantes, et de les analyser dans plusieurs cas de fonctionnement de ces machines, tout en comparant les résultats de l'analyse.

Le maintien de l'état du bon fonctionnement de la machine pendant les travaux est nécessaire pour développer des méthodes et des moyens de maintenance et de diagnostic des défauts mécaniques, c'est ce qui a conduit à l'émergence de nombreuses méthodes classiques de diagnostic des machines industrielles.

Avec l'invention de l'intelligence artificielle, il est devenu possible d'exploiter les moyens de diagnostiquer automatiquement des défauts mécaniques, ainsi que de les prédire, grâce à la possibilité de l'apprentissage automatique.

Ce mémoire est décomposé en trois chapitres, au premier chapitre nous allons définir les machines tournantes ainsi que leurs types, leurs défauts. On parle également des deux types de diagnostic, classique et intelligent.

Au deuxième chapitre, nous allons présenter les notions de bases de machine Learning, leurs ingrédients, ainsi que leur principe de fonctionnement, et leurs différents types.

Le dernier chapitre est consacré à l'application du diagnostic intelligent par la méthode de l'arbre de décision sur les défauts mécaniques d'un moteur électrique. Les données utilisées sont des signaux vibratoires issus du banc d'essai de roulements avec et sans

défauts. Nous calculons les indicateurs de surveillance correspondant aux états de fonctionnement de la machine.

Ainsi, nous présentons les résultats de la classification par l'arbre de décision en utilisant l'application classification Learner sous MATLAB2018. Enfin nous terminons par une conclusion générale, ainsi que quelques perspectives d'amélioration de ce travail.

CHAPITRE I

ETUDE BIBLIOGRAPHIQUE SUR LE DIAGNOSTIC DES MACHINES TOURNANTES

I.1 Introduction

Les machines tournantes jouent généralement un rôle stratégique dans le processus de fabrication, ce qui nécessite la sélection d'un bon processus pour maintenir les machines industrielles en bon état de fonctionnement et prolonger leur durée de vie, économisant ainsi beaucoup de temps et d'argent de maintenance. Pour cette raison, la compréhension des pièces mécaniques et de leurs défaillances peut aider à atteindre cet objectif.

Ce chapitre présente les défauts mécaniques des machines tournantes, et les différentes méthodes utilisées au diagnostic de ces défauts.

I.2 Machines tournantes

En générale une machine tournante comprend essentiellement une partie tournante le rotor et une partie fixe le stator (FIGURE I.1). Et pour qu'il y ait une rotation facilitée, il faudrait des guidages et liaisons en rotation (coussinet, roulements), Dans le domaine des machines électriques, il existe quelques principes généraux de fonctionnement. La classification classique fait apparaitre les grandes familles suivantes [1].

- Machines à courant continu.
- Machines synchrones et alternateurs.
- Machines asynchrone.
- La pompe.
- La turbine.




FIGURE I.1 : Composants de la machine tournante.

I.3 Défauts mécaniques des machines tournantes

Une machine tournante n'est en fait qu'un jeu de mécanismes mobiles entre eux, et d'organes combinés dans le but d'effectuer une tâche précise, transformer une énergie, transmettre un mouvement . . . etc. Une panne dans une machine tournante n'est que la résultante d'une avarie ou d'une suite d'avarie sur l'un ou plusieurs de ses organes.

I.3.1 Défauts de Roulement

Le roulement, organe de base pouvant assurer à lui seul plusieurs fonctions parmi lesquelles la liaison mobile en rotation avec un minimum de frottement entre deux éléments, tout en supportant des charges radiales ou axiales plus ou moins importantes, il peut être aussi utilisé pour assurer un positionnement précis de l'arbre, et corriger des défauts d'alignement. Selon le type de roulement utilisé [2].

Le roulement est composé des éléments suivants dans la FIGURE I.2 :




FIGURE I.2 : Section d'un roulement à billes avec (n) billes.

I.3.1.1 Mode de défaillance des roulements

Tableau I.1 : Résumé des modes de défaillance.

Organe	Mode de défaillance
Roulement	<ul style="list-style-type: none">- Blocage- Bruit- Ecaillage- Echauffement- Fuites- Grippage des bagues- Laminage- Rupture de la cage- Usure- Matage- Centrifugation

I.3.2 Défauts d'engrenage

L'engrenage est un des mécanismes élémentaires les plus utilisés pour transmettre du mouvement, et adapter les vitesses de rotation entre organes moteurs et récepteurs. Il est constitué de deux roues dentées mobiles autour d'axes de rotation, et dont l'une entraîne l'autre par l'action de dents successivement en contact.

Les engrenages sont parmi les organes les plus sensibles de la chaîne cinématique et peuvent être soumis à un grand nombre d'avaries apparaissant lors du fonctionnement, et dont les causes sont multiples. Mis à part les défauts de fabrication et de montage, on distingue principalement deux catégories de défauts pouvant atteindre un jeu d'engrenage, les défauts généralisés et localisés (FIGURE I.3) [3].

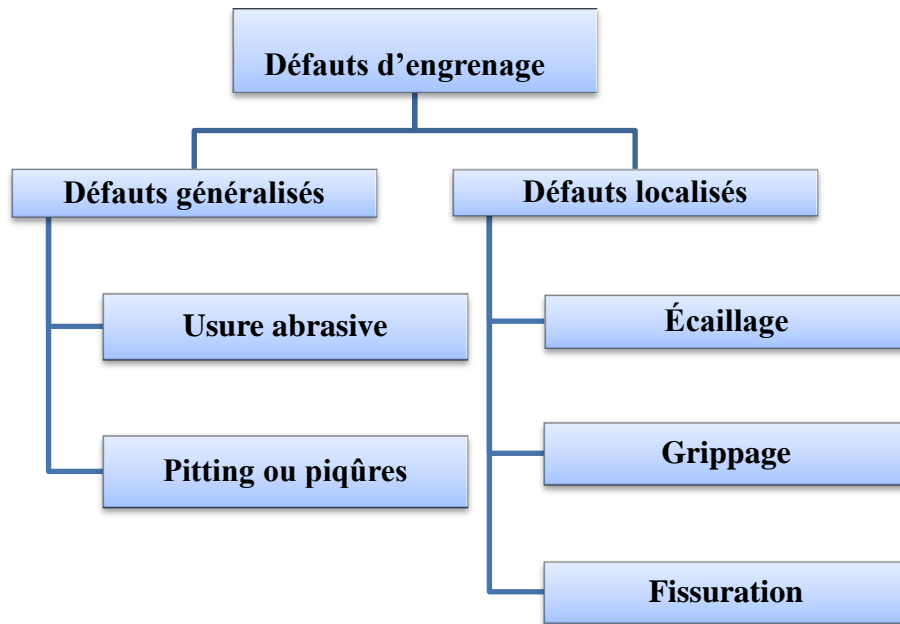


FIGURE I.3 : Schéma de différents défauts d'engrenage.

I.3.3 Défauts liés aux arbres

I.3.3.1 Le Déséquilibre (défaut de balourd)

Quel que soit le soin apporté à la construction des machines, il n'est pas possible de faire coïncider l'axe de rotation avec le centre de gravité de chaque tranche élémentaire du rotor (FIGURE I.4).




FIGURE I.4 : Tolérances d'usinage sur un rotor.

Ce balourd (FIGURE I.5) provient généralement de défauts d'usinage, d'assemblage et de démontage, ou bien il est la conséquence :

- D'une altération mécanique qui peut être due à une perte d'ailette, érosion ou encrassement.
- altération thermique qui peut provenir d'une déformation suite à des

dilatations différentes des matériaux constituant le rotor ou a des différences de température localisées Généralement, le spectre issu d'une mesure prise radialement.




FIGURE I.5 : défaut de balourd.

Le balourd va induire, dans un plan radial, une vibration dont le spectre présente une composante dont la fréquence de base correspond à la fréquence de rotation F_r .

Elle représente alors le pic le plus élevé avec des pics d'amplitudes plus faibles sur les harmoniques de F_r (FIGURE I.6) [4].




FIGURE I.6 : Spectre théorique d'un défaut de balourd.

I.4 Diagnostic

Dans le domaine d'industrie Charbonnaud définit le diagnostic comme étant « un acte intelligent qui se doit de trouver dans un système physique les dysfonctionnements et surtout les causes de la situation de panne » [5].

Le diagnostic c'est l'ensemble des actions menées pour la détection de la panne, sa localisation et l'identification de la cause. [Afnor, 2001] Au niveau de l'industrie le diagnostic

l'identification de la cause probable de la ou les défaillances à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle, ou d'un test. [NFX60-010]. Cette définition résume les deux tâches essentielles en diagnostic [5].

I.5 Les méthodes de diagnostic

Il existe plusieurs méthodes de diagnostic des défauts mécaniques dans les machines tournantes, et qu'on peut les classer en deux grandes approches :

I.5.1 Les méthodes Classiques

La surveillance d'un équipement de machine est assurée en relevant périodiquement un indicateur d'état de dégradation ou de performance, il existe différentes techniques d'analyse (FIGURE I.7) tels que l'analyse vibratoire, l'émission acoustique, la thermographie, l'analyse des huiles et des lubrifiants, la variation de résistance dans un circuit électrique, etc...

Le choix de l'indicateur dépend du type de machine à étudier et du type de défaillance que l'on souhaite détecter. Pour les machines tournantes, un indicateur de type vibratoire permet de détecter la plupart des défauts, on établit une courbe d'évolution de l'indicateur au cours du temps. Sur cette courbe, on définit différents seuils correspondant à un niveau d'alerte, à une alarme, à un niveau de défaillance, ces niveaux sont établis soit par expérience soit en appliquant une norme pour les roulements, on utilise des abaques de sévérité vibratoire pour définir les différents seuils [6].

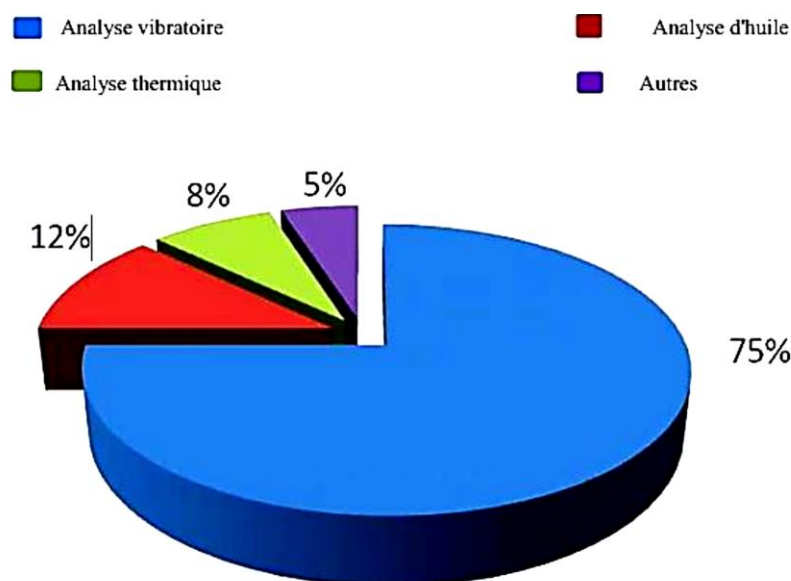


FIGURE I.7 : Différentes méthodes d'analyse [6].

I.5.1.1 La thermographie infrarouge

La thermographie infrarouge part du principe que tout corps dont la température est supérieure à 0°C émet une énergie sous forme de rayonnement électromécanique.

Cette énergie est fortement corrélée avec sa température de surface. La thermographie infrarouge consiste à relever ce rayonnement, le quantifier et, s'il est bien calibré, le reconstituer avec une cartographie des températures à la surface de l'objet observé [7].




FIGURE I.8 : Technique infrarougeappliqué au moteur électrique.

I.5.1.2 L'émission acoustique

L'émission acoustique est une technique de surveillance qui tend à se généraliser, surtout avec l'apport de techniques avancées pour le traitement et le dé- bruitage des signaux.

Bien qu'elle se soit avérée efficace, notamment pour le diagnostic des défauts de roulements et d'engrenages à un stade précoce, elle a aussi montré certains inconvénients. En plus de sa forte sensibilité au bruit, l'émission acoustique s'atténue à travers les différentes interfaces, ce qui requiert un placement des capteurs au plus près de l'installation à surveiller pour une acquisition fiable.

I.5.1.3 L'analyse Des huiles

L'analyse des huiles est d'une importance primordiale dans tout programme de maintenance des machines industrielles. La mise en œuvre de cette analyse est simple et presque tous les mécanismes lubrifiés sont susceptibles d'être sujets à ce diagnostic.

L'huile est en contact permanent avec les pièces en mouvement. Elle fournit de nombreuses informations sur l'état de la machine.

L'analyse des huiles permet de suivre dans le temps les caractéristiques physico-chimiques du lubrifiant. Cela permet d'apprécier son état de dégradation et donc son aptitude à remplir sa fonction dans la machine.

I.5.1.4 L'analyse vibratoire

Une machine tournante en fonctionnement engendre forcément l'apparition d'efforts plus ou moins variables. Ces efforts peuvent être cause de défaillances ultérieures comme ils peuvent être conséquence de défaillances antérieures.

Les vibrations des machines sont considérées comme la réponse de la fonction de transfert de leurs structures aux différents efforts auxquels elles sont sollicitées. La surveillance des vibrations de ces structures peut permettre donc de déceler l'apparition d'efforts perturbateurs à un stade précoce, permettant par la même occasion, de détecter ou d'avorter l'apparition de défaillances. En plus de son efficacité, la facilité relative de son installation rend l'analyse des signaux vibratoires une des techniques les plus utilisées pour la surveillance et le diagnostic des défauts des machines tournantes.

Lors de l'acquisition de l'information vibratoire, le choix des éléments constitutifs de la chaîne de mesure ne doit pas être négligé, et ce afin de pouvoir enregistrer des signaux englobant l'information vibratoire la plus complète. Les techniques d'exploitation et de traitement des signaux vibratoires diffèrent d'un cas à l'autre en fonction de la dynamique et de la cinématique de la machine surveillée ainsi que de la nature des défauts soupçonnés. Dans les sections suivantes, seront décrites dans cet ordre la chaîne de mesure des signaux vibratoires ainsi que les principales techniques de leurs exploitations.

Les vibrations ressenties ou mesurées sur une machine ne sont en fait que la réponse de la structure à la somme des excitations internes ou externes, la Figure I.9 présente un exemple de diagnostic avec l'analyse des vibrations [8].




FIGURE I.9 : Exemple de diagnostic avec l'analyse des vibrations.

I.5.1.4.1 Analyse temporelle

L'analyse temporelle permet d'extraire des paramètres indicateurs de défauts à partir de données brutes du capteur. Les paramètres décrits ici sont appelés « paramètres statistiques » car ils sont basés sur une analyse des caractéristiques temporelles du signal enregistré.

On peut citer par exemple :

La valeur efficace : la valeur efficace (dite aussi valeur RMS, de l'anglais Root Mean Square, ou moyenne quadratique) d'un signal, est la racine carrée du moment d'ordre deux (ou variance) du signal :

$$RMS = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}} \quad (1,1)$$

x_i : Le signal temporel,

\bar{x} : La valeur moyenne des amplitudes,

N : Le nombre d'échantillons prélevés dans le signal.

C'est l'un des paramètres le plus utilisé dans l'analyse temporelle. Une augmentation de la valeur du RMS indiquera une dégradation de l'état de santé du système.

Kurtosis : le Kurtosis noté Skurt représente le moment statique d'ordre 4. Il mesure le degré d'écrasement de la distribution du signal vibratoire enregistré et est défini comme étant le rapport entre le moment d'ordre quatre centré et le carré de la variance.

$$S_{\text{kurt}} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^2} \quad (1, 2)$$

x_i : Le signal temporel,

\bar{x} : La valeur moyenne des amplitudes,

N : Le nombre d'échantillons prélevés dans le signal.

Un système en bon état engendre un signal vibratoire avec un Kurtosis voisin de 3. Pour un système dégradé, l'amplitude du signal est modifiée et le Kurtosis devient supérieur ou égal à 4.

Facteur de crête : c'est un indicateur de surveillance simple à calculer, car c'est le rapport entre la valeur de crête du signal et sa valeur efficace (RMS), comme il peut se calculer par le rapport entre la valeur maximale du signal et son écart type.

$$F_c = \frac{v_{\text{crete}}}{\text{RMS}} \quad (1, 3)$$

v_{crete} : La valeur crête,

RMS : La valeur efficace.

Cet indicateur est utilisé pour la détection spécifique d'impulsions ou de choc présents dans le signal vibratoire.

I.5.1.4.2 Analyse fréquentielle

L'analyse dans ce domaine est basée sur la transformation du signal du domaine fréquentiel, l'avantage de l'analyse dans ce domaine par rapport au domaine temporel, est son aptitude à l'identification et à l'isolation facile de certains composants fréquentiels d'intérêt.

Ainsi cette analyse de spectre permet de mettre en évidence les différentes périodicités dans le signal original. Pour obtenir le spectre $X(f)$ de $x(t)$, on applique la définition mathématique de la transformée de Fourier:

$$X(f) = \int_{-\infty}^{+\infty} x(t) \cdot e^{-i2\pi ft} \cdot dt \quad (1,4)$$

$X(f)$: La transformée de Fourier,

t : La variable temps,

f : La variable fréquence.

I.5.2 Diagnostic intelligent

Les méthodes intelligentes dépendent principalement de la disponibilité des données de mesure autres que les méthodes basées sur un modèle physique de la connaissance a priori sur le système est nécessaire. La Figure I.10 donne le schéma conceptuel du diagnostic intelligent.

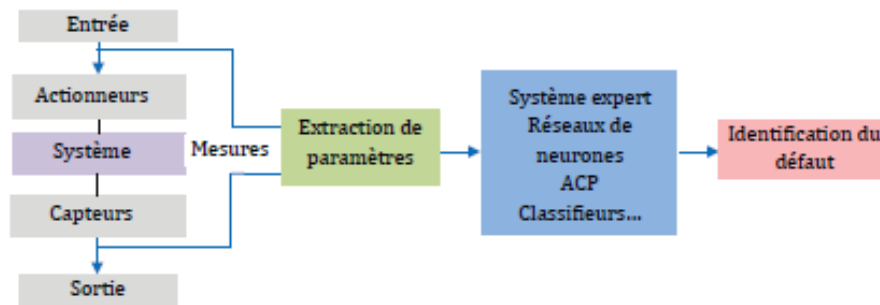


FIGURE I.10 : Structure d'un système de diagnostic intelligent.

L'Intelligence Artificielle (IA) est définie par l'un de ses créateurs, Marvin Lee Minsky, comme « la construction de programmes informatiques qui s'adonnent à des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisante par des êtres humains car elles demandent des processus mentaux de haut niveau tels que: l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique».

En général, un outil pertinent de l'IA est caractérisé par:

- La possibilité de traiter les informations symboliques et les informations numériques;
- La possibilité de résolution d'un problème dont on ne connaît pas à priori d'algorithmes classiques conduisant à une solution;
- La capacité de transférer des connaissances à un niveau externe (le monde réel) vers un système d'information numérique et de les représenter symboliquement.
- La capacité de gérer les problèmes et de trouver des solutions même en l'absence de données complètes.
- La capacité à faire face à des données contradictoires ou entraînant des incertitudes.
- La capacité d'apprentissage qui représente l'intelligence de ce type d'outil.
- La séparation des connaissances de leur mécanisme d'exploitation.

On peut classer les méthodes à base d'IA en deux grandes catégories: les méthodes à base de systèmes experts et les méthodes à bases neuronales.

I.5.2.1 Machine Learning

Le Machine Learning est une technologie d'intelligence artificielle permettant aux ordinateurs d'apprendre sans avoir été programmés explicitement à cet effet. Pour apprendre et se développer, les ordinateurs ont toutefois besoin de données à analyser et sur lesquelles s'entraîner. De fait, le Big Data est l'essence du Machine Learning, et c'est la technologie qui permet d'exploiter pleinement le potentiel du Big Data.

I.5.2.2 Système expert

Un système expert est défini comme: « un programme informatique intelligent qui utilise une base de connaissances et un moteur d'inférence pour résoudre les problèmes qui sont d'une complexité telle qu'ils possèdent une importante expertise humaine pour leur solution», la Figure.11 présente l'architecture d'un système expert [9].




FIGURE I.11 : Architecture d'un système expert.

- L'utilisation de systèmes experts aide beaucoup à diagnostiquer les défauts, en raison de leur caractéristique importante qui est de pouvoir restituer à des non-experts les connaissances acquises par les spécialistes d'un domaine technique précis.
- la base de faits, qui recueille les informations initiales liées au domaine qui s'enrichit progressivement de conclusions ou de nouveaux faits déduits par le moteur d'inférence.
- la base de règles, qui sert à combiner la connaissance et le savoir-faire de l'expert, pour former ensuite la base de connaissances.
- le moteur d'inférence, un programme spécial qui travaille sur la réalisation des déductions logiques à partir de la base de faits et de la base de règles.

-Les règles sont utilisées pour manipuler les faits et aboutir à des conclusions. Le moteur d'inférence produit lors de son mécanisme de raisonnement de nouveaux faits qui sont mémorisés dans la base de faits, les modules d'interface pour la consultation et la mise à jour du système expert.

- Ce module de consultation est dédié à une utilisation par le non-spécialiste du domaine et fait souvent appel à un dialogue homme / machine proche du langage naturel,

- le module de développement, lui, est réservé à l'introduction de nouvelles connaissances dans la base de connaissances.

-La richesse des faits et le volume de la base des connaissances qui en découle, la définition et la description des différentes situations importent beaucoup pour l'efficacité et la qualité d'un diagnostic par systèmes experts.

I.6 Conclusion

Le diagnostic par différentes méthodes permet de détecter les défauts mécaniques pouvant affecter les différents composants des machines tournantes. C'est pourquoi les institutions œuvrant dans le domaine de la production industrielle ont l'intention de développer ces techniques de surveillance dans le but de réparer les pannes et de remettre la machine défectueuse dans son performance dans sa chaîne de travail.

Le travail de développement de ces technologies est passé par étapes de la phase classique à la phase d'intelligence artificielle lequel, à son tour de faciliter la tâche de diagnostic et augmente la précision du processus de surveillance, et avec l'avancement de la science dans le domaine de l'intelligence artificielle, les tâches de ces derniers augmentent et la dépendance à son égard augmente davantage dans le domaine du diagnostic.

Dans ce chapitre, on a présenté un aperçu théorique sur les principaux défauts mécaniques dans les machines tournantes et les différentes méthodes de diagnostic classiques et intelligentes. Cette dernière méthode sera expliquée en détail dans le prochain chapitre.

CHAPITRE II

DIAGNOSTIC BASE SUR LA

METHODE MACHINE

LEARNING

II.1 Introduction

La machine learning, également appelée apprentissage machine ou apprentissage artificiel est un domaine très important, résultant de nombreuses disciplines telles que les statistiques, l'optimisation, l'algorithmique ou le traitement du signal, et elle est considérée comme un domaine d'étude en développement rapide et beaucoup de changements au fil du temps, et sa présence à s'implanter solidement dans divers domaines de notre vie. Dans le domaine de la maintenance industrielle, la machine learning est utilisée comme un moyen d'automatisation de la décision sur l'état de fonctionnement des différents organes et composants des systèmes étudiés. Ce chapitre porte sur la définition de la machine learning et de son utilisation dans la détection des défauts mécaniques.

II.2 Définition d'une machine learning [10]

Parmi les branches de l'intelligence artificielle on trouve La machine learning, 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, aborde en outre les sciences psychologiques, la neurobiologie, la logique, le matériel, la conception, etc. Probablement à la lumière du fait que l'expression «conscience artificielle» est plus innovante, dans tous les cas, elle est progressivement utilisée à la place de l'intelligence artificielle.

L'apprentissage est une question qui intéresse les professionnels des mathématiques et de l'informatique, ainsi que les neurologues, pédagogues, philosophes ou artistes. Une définition qui s'applique à un programme informatique comme à un robot, un animal de compagnie ou un être humain est celle proposée par Fabien Benureau (2015):« L'apprentissage est une modification d'un comportement sur la base d'une expérience ».

A cause d'un programme PC, on parle de l'intelligence artificielle, ou machine learning, lorsque ce programme a la capacité d'apprendre sans que cette altération ne soit modifiée sans équivoque. Cette définition est celle donnée par Arthur Samuel (1959). On pourrait ainsi aller à l'encontre d'un programme exemplaire, qui utilise une technique et les informations qu'il obtient comme contribution pour créer des réactions comme rendement, à

un programme d'intelligence artificielle, qui utilise les informations et les réactions pour livrer la méthode qui permet d'obtenir les secondes des initiales.

La machine learning peut servir à résoudre des problèmes

- que l'on ne sait pas résoudre ;
- que l'on sait résoudre, mais dont on ne sait formaliser en termes algorithmiques ;
- que l'on sait résoudre, mais avec des procédures beaucoup trop gourmandes en ressources informatiques (c'est le cas par exemple de la prédiction d'interactions entre molécules de grande taille, pour lesquelles les simulations sont très lourdes).

La machine learning est donc utilisé quand les données sont abondantes (relativement), mais les connaissances peu accessibles ou peu développées. Ainsi, la machine learning peut aussi aider les humains à apprendre : les modèles créés standard des algorithmes d'apprentissage peuvent révéler l'importance relative de certaines informations ou la façon dont elles interagissent entre elles pour résoudre un problème particulier [10].

II.3 Ingrédients de la machine learning

La machine learning repose sur deux piliers fondamentaux :

- d'un point de vue, les informations, qui sont les modèles dont le calcul apprendra.
- puis encore, le calcul d'apprentissage, qui est le système que nous allumons sur ces informations pour créer un modèle. La préparation s'appelle l'exécution d'un calcul d'apprentissage sur un ensemble de données.

Ces deux colonnes sont également significatives. D'un certain point de vue, aucun calcul d'apprentissage ne voudra réellement créer un modèle décent à partir d'informations qui ne sont pas pertinentes

- C'est la pensée « *garbage in* », « *garbage out* » qui précise qu'un calcul d'apprentissage auquel sont données des informations de faible qualité ne peut faire que des prédictions de faible qualité. Ne pas être de qualité acceptable. Ce livre est centré sur la deuxième de ces colonnes- apprentissage des calculs. Tout bien considéré, il ne faut pas oublier qu'un élément important de la bataille de machine learning ou du data scientist est une bataille de conception consistant à mettre en place les informations pour supprimer les exceptions, pour traiter les informations manquantes. , sélectionnez une représentation importante, etc.

De cette manière, la machine learning est d'un point de vue de la science, et en particulier des insights, en ce qui concerne la tournure des événements et l'induction à partir d'informations, puis encore le traitement, en ce qui concerne la représentation de l'information et l'exécution viable de calculs de rationalisation. De plus, la mesure de l'information accessible nécessite l'utilisation de calculs disséminés et de constructions d'ensembles de données [9].

II.4 Fonctionnement du Machine Learning

L'apprentissage automatique repose sur deux types de techniques (FIGURE II.1): l'apprentissage supervisé, qui implique de former des modèles sur des données d'entrée et de sortie connues pour prédire les résultats futurs; l'apprentissage non supervisé, qui reconnaît les modèles cachés ou les structures internes dans les données d'entrée [11].

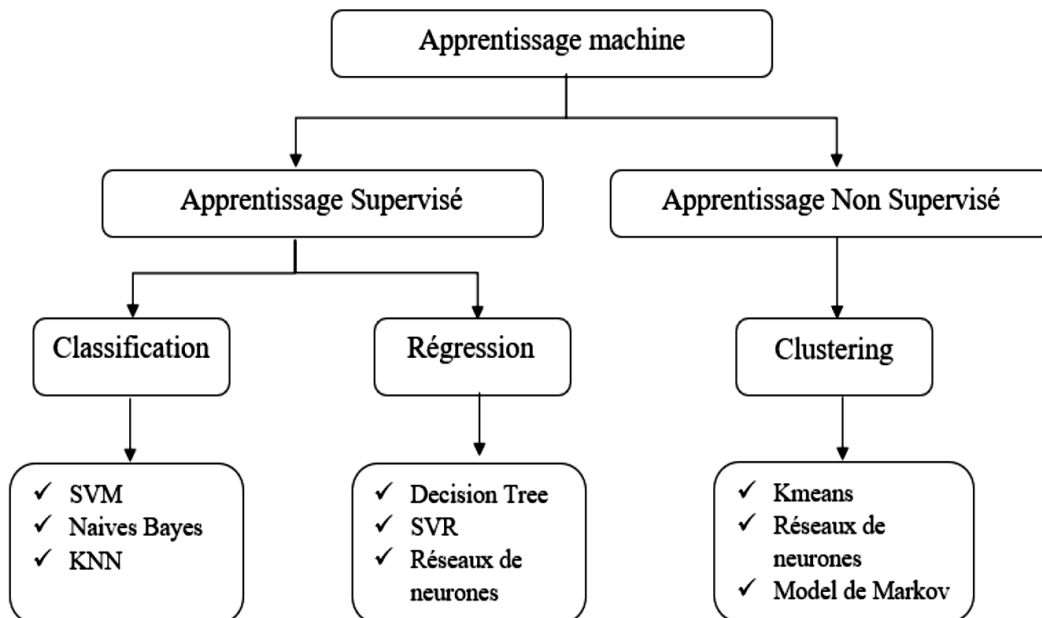


FIGURE II.1: L'apprentissage supervisé et l'apprentissage non supervisé sont deux techniques de Machine Learning [17].

II.4.1 Apprentissage supervisé

L'apprentissage automatique supervisé construit un modèle qui fait des prédictions basées sur des preuves dans l'incertitude. Les algorithmes d'apprentissage supervisé appliquent un ensemble de données d'entrée connues et de réponses connues aux données (résultats), et entraînent le modèle pour générer des prédictions raisonnables de la réponse aux

nouvelles données. Si vous connaissez les données du résultat que vous souhaitez prédire, utilisez l'apprentissage supervisé.

L'apprentissage supervisé utilise des techniques de classification et de régression pour développer des modèles prédictifs.

Les techniques de classification fournissent des variables discrètes. Par exemple, ils déterminent si l'e-mail est authentique ou un spam, ou si la tumeur est cancéreuse ou bénigne. Le modèle de classification classe les données d'entrée. Les applications typiques sont l'imagerie médicale, la reconnaissance vocale et la notation de crédit.

Si vous pouvez étiqueter, classer ou diviser les données en groupes ou classes spécifiques, utilisez la classification. Par exemple, les applications de reconnaissance de l'écriture manuscrite utilisent la classification pour reconnaître les lettres et les chiffres. Dans le traitement d'image et la vision par ordinateur, une technologie de reconnaissance de formes non supervisée est utilisée pour la détection d'objets et la segmentation d'image.

Les algorithmes couramment utilisés pour la classification incluent notamment les machines à vecteurs de support (SVM), le boosting/bagging d'arbres de décision, la méthode des k plus proches voisins, la classification naïve bayésienne, l'analyse discriminante, la régression logistique et les réseaux de neurones.

Les techniques de régression peuvent prédire des variables continues, telles que les changements de température ou les fluctuations de la demande d'énergie. La prévision de la charge de puissance et le trading algorithmique sont des applications classiques.

Si vous devez utiliser une certaine plage de données, ou si vous voulez essayer de prédire que la réponse est un nombre réel, comme la température ou la prochaine fois que l'appareil tombe en panne, utilisez des techniques de régression [11].

II.4.2 Apprentissage non supervisé

L'apprentissage non supervisé identifie des modèles cachés ou des structures intrinsèques dans les données. Il est utilisé pour tirer des conclusions à partir d'ensembles de données composés de données d'entrée sans réponses labellisées (FIGURE II.2).

Le **clustering** est la technique d'apprentissage non supervisé la plus répandue. Le clustering est utilisé pour effectuer une analyse exploratoire des données afin de trouver des modèles cachés ou des regroupements dans les données. L'analyse de séquence génomique,

l'étude de marché et la reconnaissance d'objets sont des exemples d'applications d'analyse de cluster.

Les algorithmes couramment utilisés pour le clustering incluent la méthode des k-moyennes et k-médoides, le clustering hiérarchique, les modèles de mélanges gaussiens, les modèles de Markov cachés, les cartes auto-organisatrices, le clustering c-moyennes flou et le clustering soustractif [11].



FIGURE II.2 : Le clustering identifie des modèles cachés dans vos données [11].

II.5 Diagnostic basé sur la méthode Machine learning

Le diagnostic rapide des défauts de processus fournit un avantage clé pour aider les entreprises de fabrication à rester compétitifs en les temps d'arrêt des machines, car de plus en plus de clients exigeants des fabricants rapides qu'ils présentent les produits, à faible coût et avec une qualité élevée. De plus, pendant les temps d'arrêt de la machine, la plupart du temps passé est consacré à la localisation de la panne plutôt qu'à l'exécution de la correction proprement dite, car le diagnostic de panne est la phase la plus difficile des réparations de la machine[12]; Cela a conduit les entreprises à rechercher de nouvelles améliorations de leur processus d'analyse des causes profondes des pannes. Avec l'amélioration actuelle de la technologie des capteurs, le stockage des données et les vitesses Internet, les usines deviennent plus intelligentes et davantage de données de processus sont générées. Les projets de recherche se concentrent sur la manière d'utiliser ces « mégadonnées » pour améliorer la compétitivité de la fabrication.

De nombreux efforts ont été faits dans ce sens dans le but d'utiliser des techniques d'apprentissage automatique pour améliorer la détection des défauts mécanique dans les machines.

II.5.1 Les Réseaux Bayésiens

Un réseau bayésien est un système représentant la connaissance et permettant de calculer des probabilités conditionnelles apportant des solutions à différentes sortes de problématiques. La structure de ce type de réseau est simple : un graphe dans lequel les **nœuds** représentent des variables aléatoires, et les arcs (le graphe est donc orienté) reliant ces dernières sont rattachées à des probabilités conditionnelles. Notons que le graphe est acyclique : il ne contient pas de boucle. Les arcs représentent des relations entre variables qui sont soit déterministes, soit probabilistes. Ainsi, l'observation d'une ou plusieurs causes n'entraîne pas systématiquement l'effet ou les effets qui en dépendent, mais modifie seulement la probabilité de les observer. L'intérêt particulier des réseaux bayésiens est de tenir compte simultanément de connaissances a priori d'experts (dans le graphe) et de l'expérience contenue dans les données. Les domaines d'application du BN varient selon les industries manufacturières. Dans l'industrie des semi-conducteurs. D'autres domaines d'application incluent l'industrie automobile où utilisée pour diagnostiquer un défaut de montage dans un ensemble de feux arrière et dans l'usinage où utilisée pour diagnostiquer un défaut de rugosité de surface. Les sources de données comprennent les systèmes de gestion de la qualité (SMQ), les systèmes d'exécution de la fabrication (MES), les systèmes de gestion des recettes (RMS), les systèmes informatisés de gestion de la maintenance (GMAO) et les machines de mesure coordonnée (CMM)... [13], les Figures II.3 et II.4 montrent le Principe de l'algorithme Naïve Bayes et leur Organigramme.




FIGURE II.3 : Principe de l'algorithme Naïve Bayes [18].

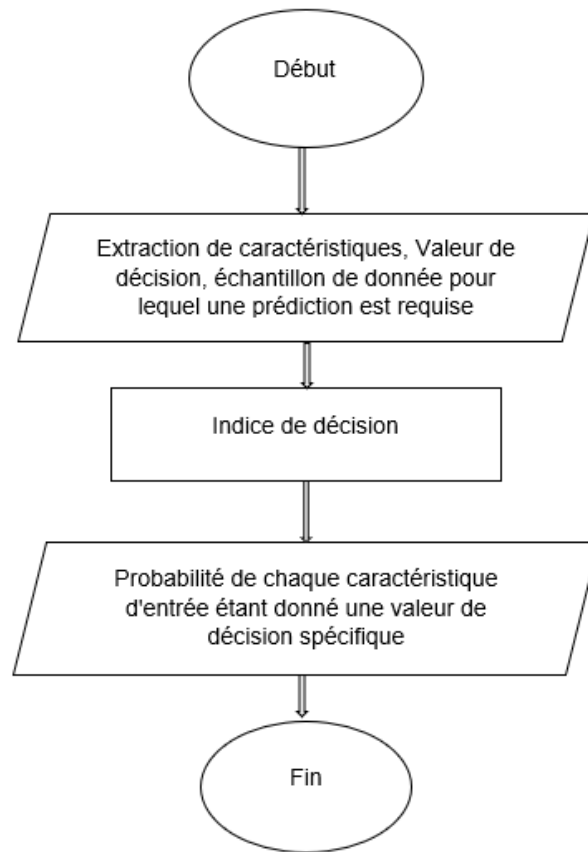


FIGURE II.4: Organigramme de l'algorithme Naïve Bayes [18].

II.5.2 Réseau neuronal artificiel

Les réseaux de neurones, utilisés pour le diagnostic des défauts, peuvent être classés selon : l'architecture du réseau, et la méthode d'apprentissage [14]. Il y a eu un certain nombre de documents qui abordent le problème du diagnostic des défauts par des réseaux de neurones. En génie chimique, [15] ont été parmi les premiers chercheurs à démontrer l'utilité des réseaux de neurones pour le diagnostic. Leur force réside dans l'aptitude à apprendre et à capturer les relations entre l'entrée du réseau de neurones et sa sortie même si ces relations sont inconnues ou difficiles à décrire. Cependant, leur principal inconvénient réside dans l'acquisition et la disponibilité des données d'apprentissage [16]. PMC permet une bonne généralisation. Après un apprentissage réussi, elle peut donner de bons résultats pour les données d'entrée invisibles au sein d'un même espace d'entrée.




FIGURE II.5 : L'architecture d'un réseau de neurones.

L'architecture d'un réseau de neurones et le modèle neuronique dont la forme la plus simple est représentée par les FIGURES II.5 et II.6 :

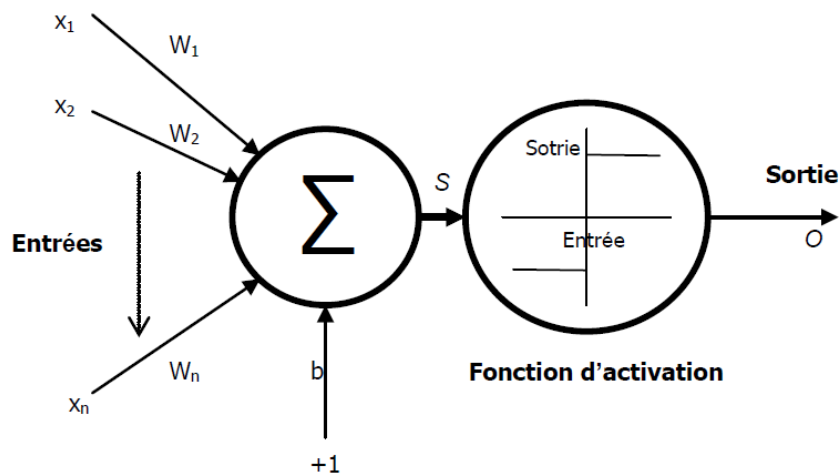


FIGURE II.6: Modèle d'un neurone artificiel.

La Figure II.6 : représente l'architecture générale d'un neurone artificiel, y compris la différente couche qui le constitue, la couche d'entrée, la couche cachée et la couche de sortie [17].

$$O = f(\sum_{i=1}^n w_i x_i + b) = f([w_1 \dots w_n b] \cdot [x_1 x_2 \dots x_n 1]^T) \quad (2,1)$$

- X_i : les entrés du neurone.
- O : la sortie du neurone.
- f : la fonction d'activation associée au neurone.
- W_i : le poids de la connexion entre les neurones.

- b : le poids de la connexion entre le neurone biais (+1) et les neurones i .

II.5.2.1 Fonctionnement

Le mécanisme de fonctionnement d'un neurone est de recevoir, grâce à ces dendrites, les signaux émis par les autres neurones, puis décider, à partir des données reçues, d'émettre ou non un signal à ses semblables le long de son axone.

Plus précisément, le soma recueille l'ensemble des informations reçues par les dendrites et effectue la sommation dite spatiaux-temporelle. En raison de sa dimension, l'intégration somatique est aussi temporelle. Si le potentiel somatique dépasse un certain seuil, il y a émission d'un potentiel d'action ou Spike. Le signal, très bref (lms), est transmis sans atténuation le long de l'axone et réparti sur le neurone cible [18].

II.5.2.2 Modèle biologique

Le bloc principal du système nerveux est le neurone. Il transmet l'information reçue vers les diverses parties du corps. Il est constitué;

- D'un corps cellulaire nommé soma
- Des plusieurs épines semblables propagées dans le corps cellulaires nommées dendrites.

Leur rôle est de capter les signaux qui proviennent du neurone.

- D'une seule fibre nerveuse nommé axone, qui sert à connecter le corps cellulaire aux autres neurones. L'axone est un moyen de transport pour les signaux émis par le neurone.
- Les connexions entre les neurones se font par l'intermédiaire du corps cellulaire ou les dendrites en jonctions nommées synapses. Les synapses servent à limiter plus ou moins l'amplitude des signaux qui passent d'un neurone à un autre, comme est illustré dans la FIGURE II.7 [18].

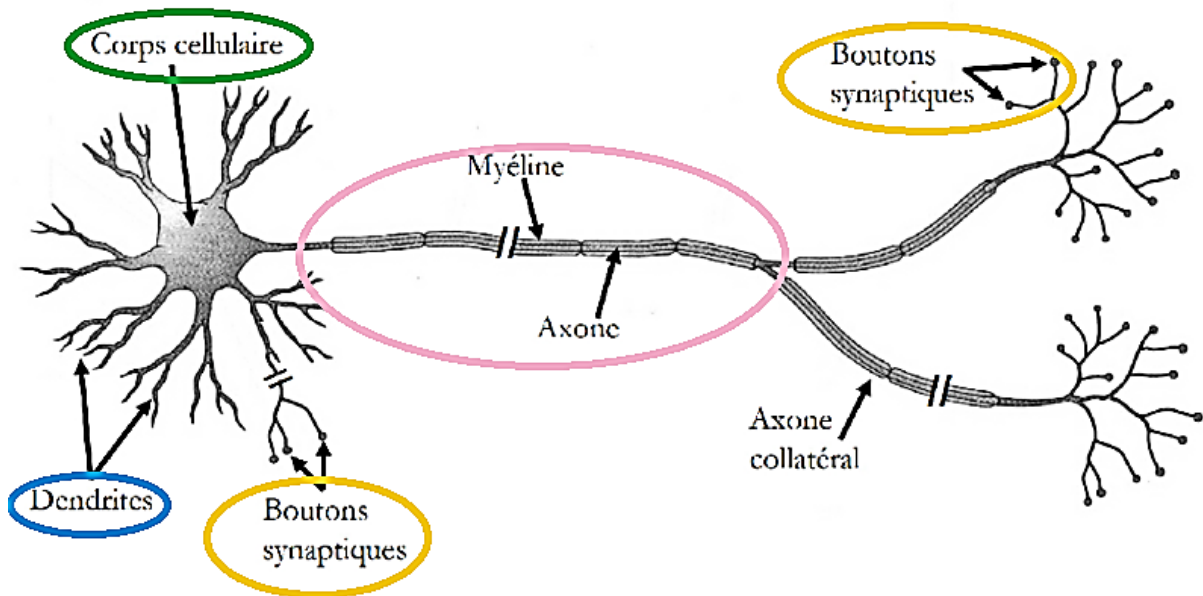


FIGURE II.7: Représentation simplifiée de neurone.

II.5.3 Les machines à vecteurs supports

Les machines à vecteurs de support (SVM) ont été développées à l'origine par Vapnik et ses collègues en 1992 sur la base de la théorie de l'apprentissage statistique de Vapnik & Chervonenkis dans les années 1960. Le SVM a été appliqué avec succès dans de nombreuses applications, notamment la reconnaissance manuscrite, la prédiction de séries chronologiques, la reconnaissance vocale, le problème de séquence protéique, le diagnostic du cancer du sein et bien d'autres [17].

Les machines à vecteur de support (SVM) sont utilisées lorsque les données ont exactement deux classes. L'algorithme SVM classe les données en trouvant le meilleur hyperplan qui sépare tous les points de données d'une classe de ceux de l'autre classe (le meilleur hyperplan pour un SVM est celui avec la plus grande marge entre les deux classes). L'algorithme SVM peut aussi être utilisé avec plus de deux classes, auquel cas le modèle créera un ensemble de sous-ensembles de classification binaire.

Il y a quelques avantages importants à utiliser l'algorithme SVM. Tout d'abord, il est extrêmement précis et n'a pas tendance à sur adapter les données. Deuxièmement, les machines à vecteurs de support linéaire sont relativement faciles à interpréter. Parce que les modèles SVM sont très rapides, une fois que votre modèle a été formé, vous pouvez supprimer les données de formation si vous avez une capacité de mémoire disponible limitée. Il a également tendance à très bien gérer les classifications complexes et non linéaires en utilisant une technique appelée « astuce du noyau ». Cependant, les algorithmes SVM doivent

être formés et réglés à l'avance, vous devez donc investir du temps dans le modèle avant de pouvoir commencer à l'utiliser. De plus, sa vitesse est fortement affectée si vous utilisez le modèle avec plus de deux classes.

L'algorithme SVM est un classificateur dit linéaire, ça veut dire que, dans le cas parfait, les données doivent être linéairement séparables. Il permet de trouver le meilleur séparateur (ligne, plan ou hyperplan) qui sépare le mieux les deux classes [18].

La FIGURE II.8 représente le principe de l'algorithme SVM, et la FIGURE II.9 donne leur Organigramme.

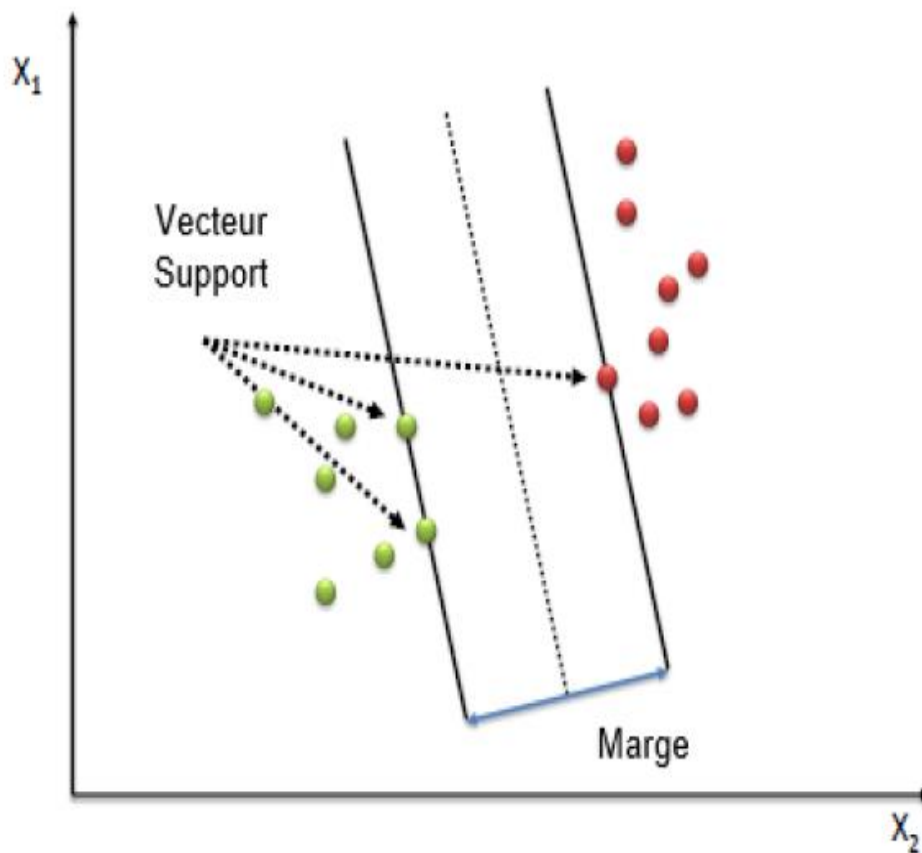


FIGURE II.8: Principe de l'algorithme SVM [18].

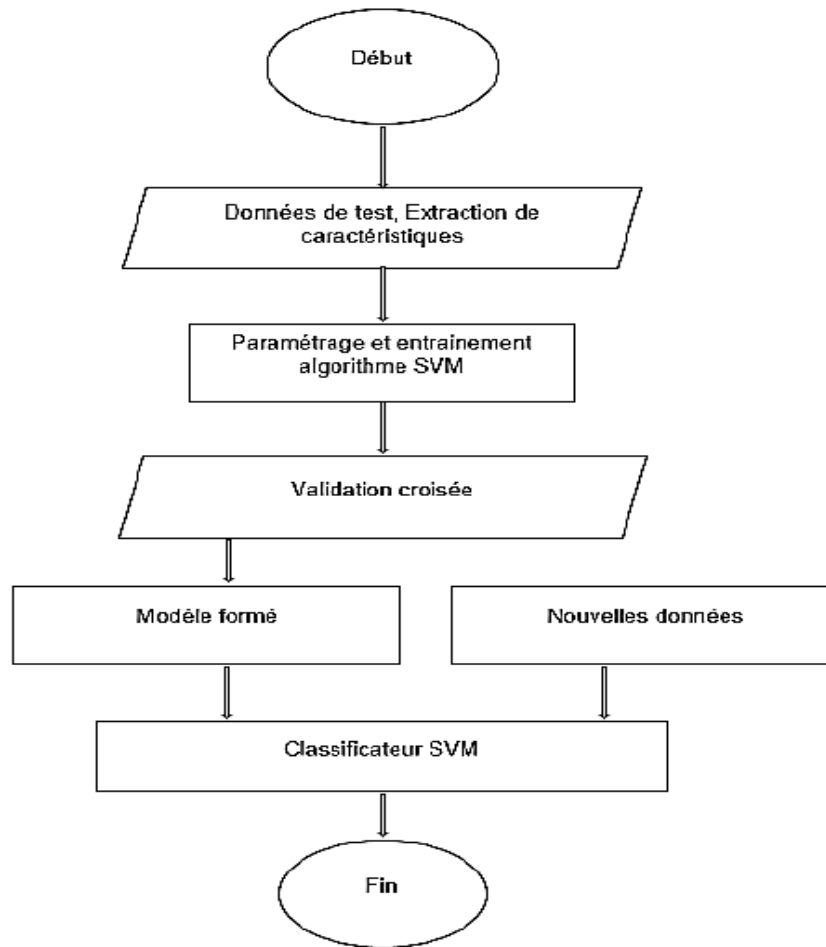


FIGURE II.9 : Organigramme de l'algorithme SVM [18].

II.5.4 Arbre de décision

L'arbre de décision est l'une des méthodes les plus importantes utilisées pour diagnostiquer les défauts avec l'intelligence artificielle, et il est connu comme une méthode d'apprentissage automatique.

II.5.4.1 Définition d'Arbre de décision

Un arbre de décision est un enchaînement hiérarchique de règles logiques ou de production construite de manière automatique à partir d'un ensemble de données. La construction de l'arbre de décision consiste à utiliser les descripteurs, pour subdiviser progressivement l'ensemble en sous-ensembles de plus en plus fins. L'algorithme estime la probabilité qu'une observation se trouve dans le nœud t en utilisant la formule :

$$P(T) = \sum_{j \in T} w_j \quad (2,2)$$

Où :

- w_j = Poids des observations.
- T = Ensemble de tous les indices d'observation du nœud t .
- n = Égale au nombre d'observations.

Les arbres de décision sont des algorithmes de classification de données reposant sur un apprentissage supervisé. Comme son nom l'indique, la structure de ces algorithmes ressemble à des arbres constitués de nœuds, de branches et de feuilles (FIGURE II.10). La construction de ces arbres est réalisée à l'aide d'une base de données brute (vecteur des caractéristiques et classes) et de lois qui permettent de déterminer les variables discriminantes pour la classification efficace des futures données. Chacun des nœuds constituant l'arbre représente une règle de classification préalablement déterminée de manière récursive.

Dans les domaines de l'informatique décisionnelle et du forage de données, ce type d'algorithmes est très utilisé, car ils permettent de construire automatiquement des classifications et leur vitesse d'exécution surpasse tous les autres types des algorithmes. Cependant, ils ne permettent pas d'obtenir de bons résultats quand les données sont complexes. Pour voir comment un arbre de décision prédit une réponse, il faut suivre les décisions dans l'arbre du nœud racine (début) jusqu'au nœud feuille qui contient la réponse. Les arbres de classification donnent des réponses nominales, tel que vrai ou faux et les arbres de régression donnent des réponses numériques. Les arbres de décision sont relativement rapides et faciles à suivre dans leur résolution ; vous pouvez voir une représentation complète du chemin parcouru de la racine à la feuille. Cela est particulièrement utile si vous devez partager les résultats avec des personnes intéressées par la manière dont une conclusion a été tirée [18].

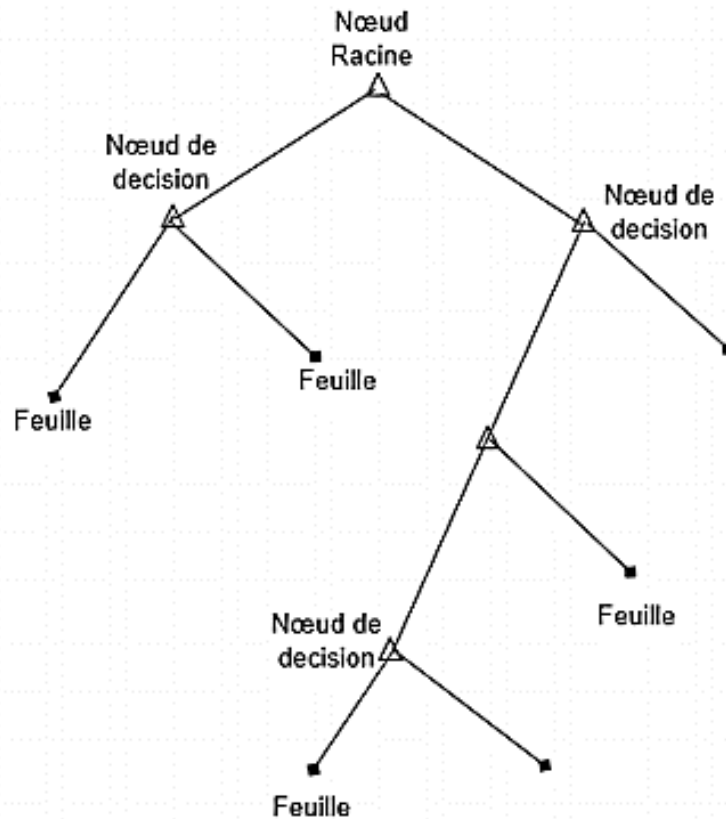


FIGURE II.10 : Arbre de décision [18].

II.6 Conclusion

Le machine learning est un champ assez vaste, et dans ce chapitre nous avons parlé des plus grandes classes de problèmes auxquels il s'intéresse, et en fait, le domaine du machine learning 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.

Le machine Learning donne une grande capacité à surveiller et prédire ce qui en fait le meilleur choix de l'industrie en tant qu'excellent outil d'intelligence artificielle utilisé pour surveiller l'état des machines industrielles pendant leur cycle de vie et connaître les défauts qui peuvent les affecter en temps opportun. Manière, ce qui le rend très important pour maintenir les performances de la machine dans le domaine de son travail.

CHAPITRE III

APPLICATION SUR DES SIGNAUX

REELS

III.1 Introduction

Les méthodes de l'intelligence artificielle Par leur pouvoirs d'apprentissage automatique et de généraliser tous les cas et les défauts possibles, deviennent un moyen efficace pour résoudre le problème de la prise des décisions rapides et précises de l'état de santé des systèmes étudiés.

Ce chapitre est dédié à l'utilisation de l'arbre de décision comme un outil de diagnostic intelligent des défauts mécaniques d'un moteur électrique. L'étude est basée sur l'analyse des signaux réels issus du banc d'essai. Tout d'abord on va calculer les différents indicateurs de surveillance vibratoire. Puis, nous présentons les résultats de diagnostic par l'application classification Learner sous MATLAB R2018a.

En général le principe de travail dans cette partie expérimentale est de classifier les différents états de fonctionnement du banc d'essai avec la classification Learner, pour créer un modèle de classification par arbre de décision qui sera utilisé pour prédire l'état de la machine en utilisant des nouvelles données de surveillance.

III.2 Description de la boîte outils

L'application Classification Learner entraîne des modèles pour classer les données. À l'aide de cette application, vous pouvez explorer l'apprentissage automatique supervisé par les divers classificateurs. Vous pouvez explorer vos données, sélectionner des fonctionnalités, spécifier des schémas de validation, entraîner des modèles et évaluer les résultats. Vous pouvez effectuer une formation automatisée pour trouver le meilleur type de modèle de classification, y compris les arbres de décision, l'analyse discriminante, la SVM, la régression logistique, les voisins les plus proches et la classification d'ensemble.

Nous utilisons l'application de classification Learner sous MATLAB. Liste des applications qui s'affichent à partir de l'icône d'applications « APPS » dans MATLAB, permet d'accéder à l'application Classification Learner.

Les Figures III.1 et III.2 représentent respectivement l'interface MATLAB et les icônes disponibles au APPS

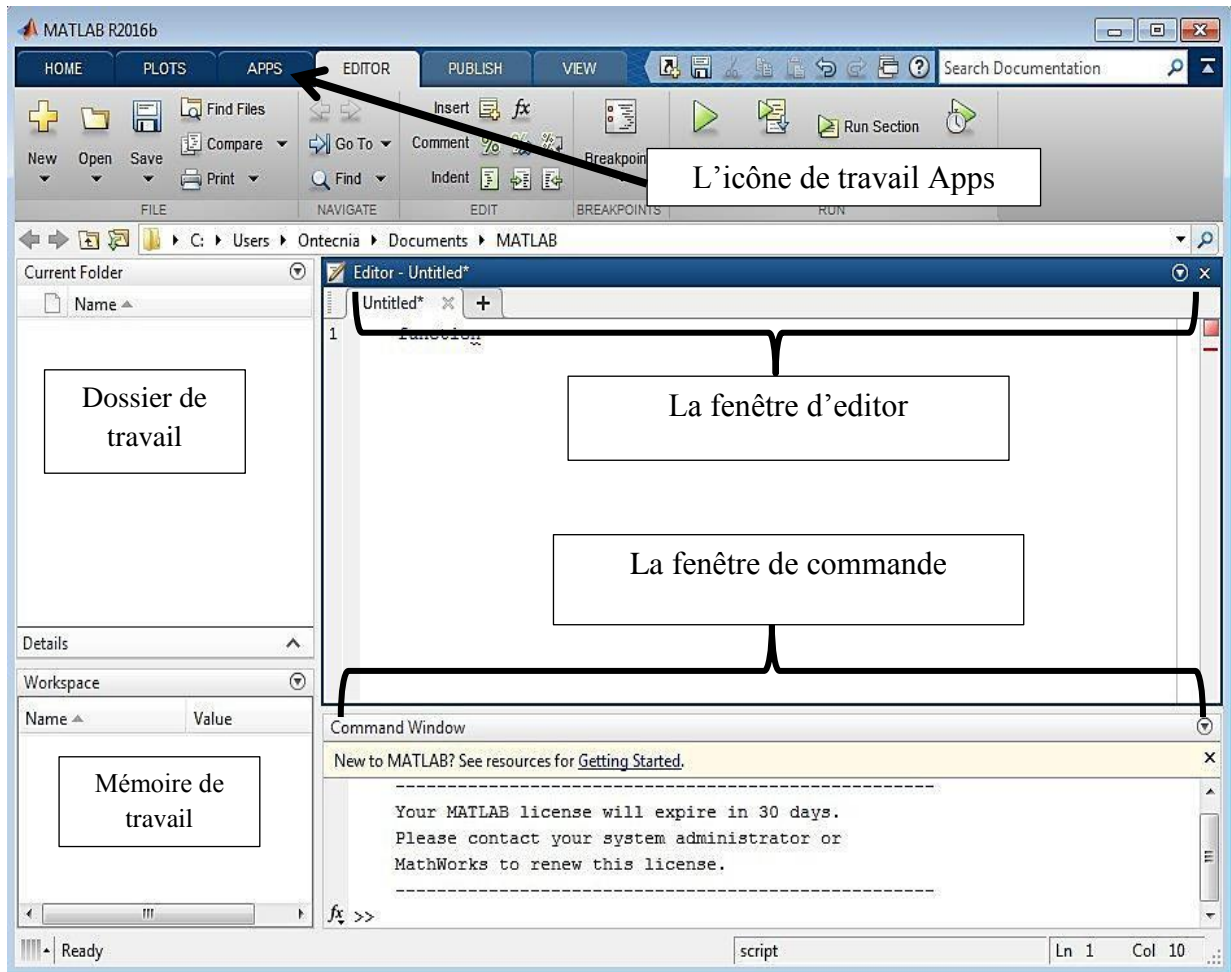


FIGURE III.1 : Interface MATLAB.

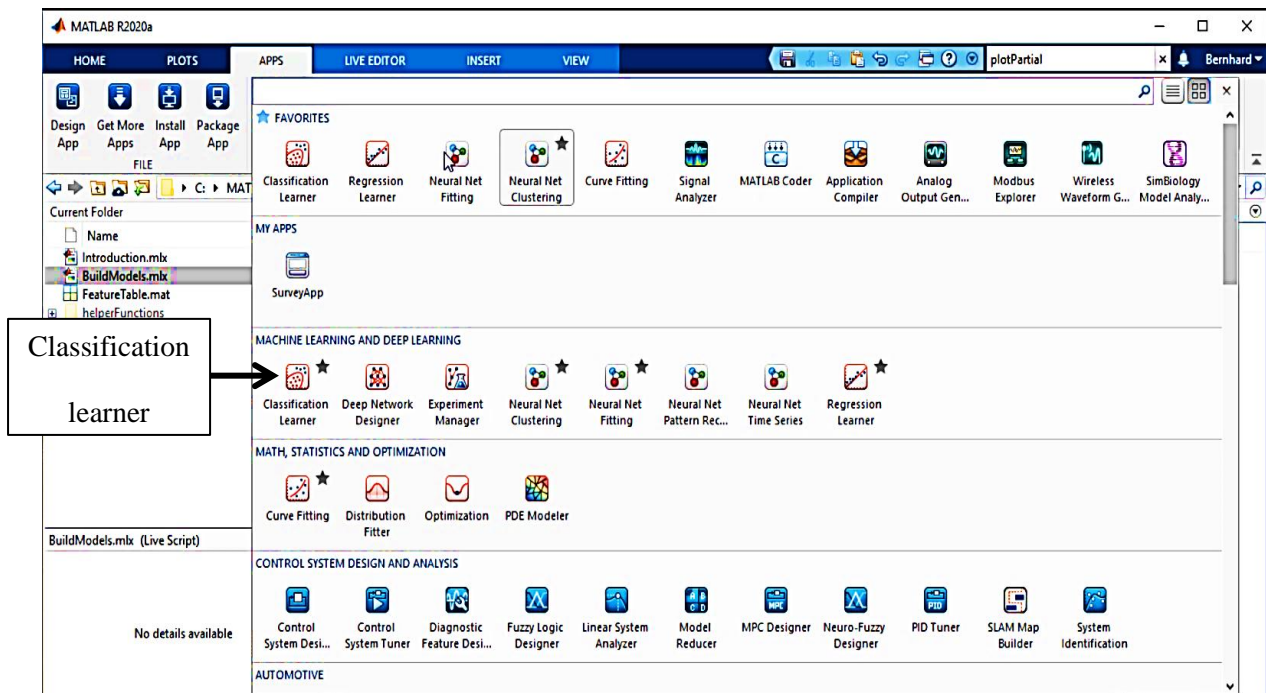


FIGURE III.2 : les icônes disponibles au APPS.

-L'icône A Figure III.3 permet d'insérer la base des données qui contient les indicateurs à classer.

-Les icônes B Figure III.3 permet de choisir le type du classifieur.

-Les icônes C Figure III.3 permet de dessiner l'ensemble des indicateurs sous forme des classes.

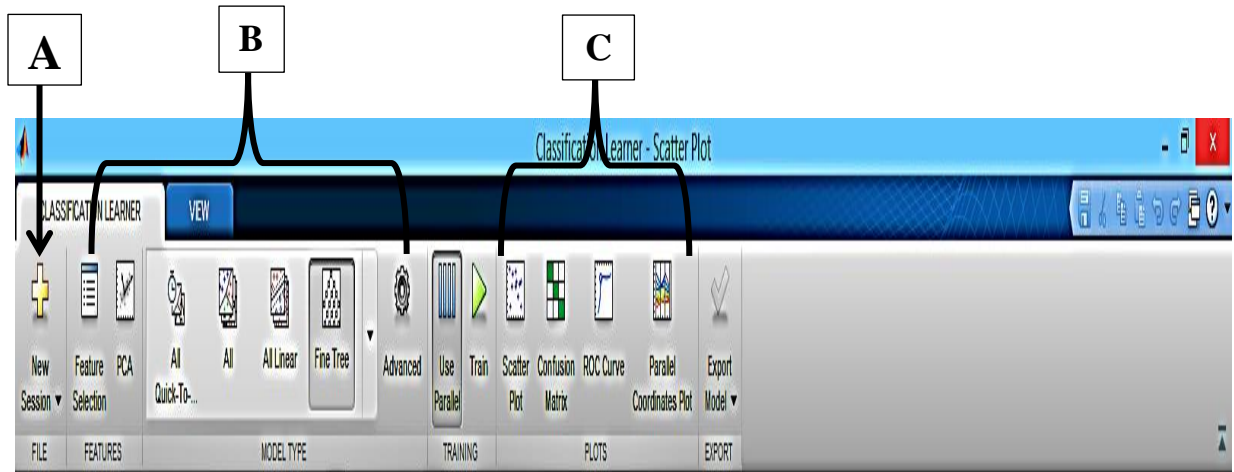


FIGURE III.3 : la fenêtre de Classification learner.

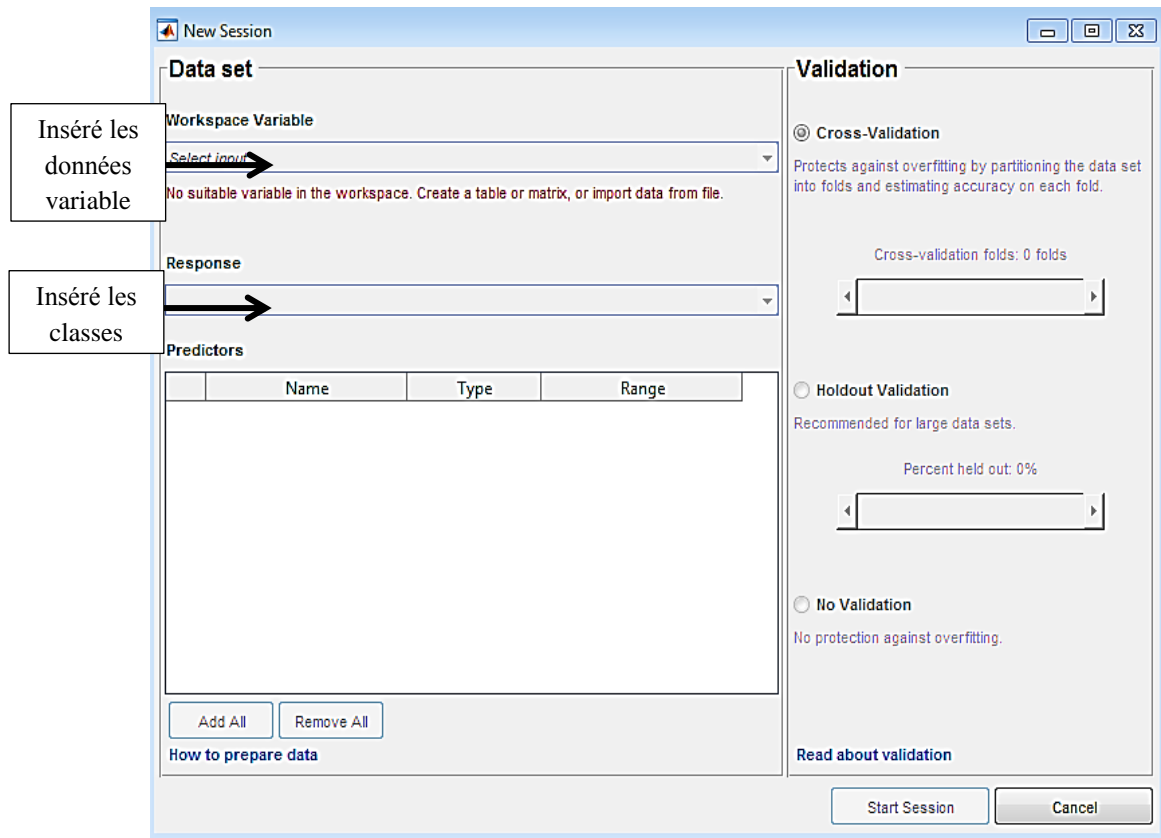


FIGURE III.4 : la fenêtre de « New Session from workspace ».

Dans la fenêtre « New session from workspace », Le tableau des variables est inséré avec l'icône « select input », et les classes de classification inséré avec l'icône « response ».

III.3 Description du banc d'essai

Les signaux de vibration applicables au cours de ce travail ont été obtenus à partir de « *the Case Western Reserve University-Bearing Data Center* »; base de données des essais de roulements à billes normaux ou défectueux, recueillis sur un banc d'essai très simple, composé d'un moteur, un accouplement et une génératrice. De simples défauts sous forme de points « de différent diamètres et profondeurs » ont été créés sur les différents organes composants les roulements d'essais [19].

Le banc d'essai (voir figure III.5) se compose d'un moteur "3 HP" (à gauche), d'un accouplement (centre), d'un dynamomètre (droit) et des circuits commande (non montrés). Les roulements testés soutiennent l'arbre du moteur des deux côtés (coté entraînement et coté ventilateur).




FIGURE III.5 : Banc d'essai des roulements.

Dans notre travail, nous utilisons les résultats obtenus dans les références [20] et [21] qui traitent et analysent les indicateurs de surveillance temporels et fréquentiels les plus adéquats correspondant aux différents états de fonctionnement du banc d'essai.

Les signaux ont été enregistrés à l'aide des accéléromètres, qui ont été fixés à la cage du moteur par aimant. Ces capteurs ont été placés à la position 12 heures "vertical" des deux côtés « accouplement et ventilateur » de la cage du moteur.

Les fréquences caractéristiques des éléments du roulement sont des multiples de la vitesse de rotation f_r :

$$\text{Fréquence de la bague intérieure : } f_{bi} = 5,415 \cdot f_r$$

$$\text{Fréquence de la bague extérieure : } f_{be} = 5,584 \cdot f_r$$

$$\text{Fréquence de la cage : } f_c = 0,3982 \cdot f_r$$

$$\text{Fréquence de la bille : } f_b = 5,7135 \cdot f_r$$

III.4 Présentation des signaux

Nous proposons d'étudier les signaux enregistrés pour les défauts de la bague intérieure (BI) dans les domaines temporel et fréquentiel pour les 5 modes de fonctionnement : Sans défaut, Défaut de 0.007 cm, Défaut de 0.014 cm, Défaut de 0.021 cm, Défaut de 0.028 cm.

La FIGURE III.6 montre les signaux temporels (l'amplitude ($m.s^{-2}$) en termes de temps (s)), pour les différents diamètres de défaut, réalisés sur la bague intérieure, pour le couple moteur 3HP. Il faut tenir compte que ces signaux sont ceux recueillis du côté de l'accouplement.




FIGURE III.6 : Signaux temporels, différents diamètres du défaut sur la bague intérieure.

III.5 L'analyse temporelle et spectrale

III.5.1 Les indicateurs temporels

Le tableau III.1 représente les indicateurs temporels calculés dans 5 bandes fréquentielles issues de la décomposition de la bande d'analyse "6 kHz" en 4 sous bandes adjacentes plus la bande totale. Dans chaque bande on a choisis de calculer 4 indicateurs qui sont : le STD, le facteur de crête (Fc), la valeur crête à crête (Fcc) et le kurtosis (K). On trouve aussi les énergies dans les bandes de fréquence du spectre d'enveloppe calculés dans 6 bandes fréquentielles issues de la décomposition de la bande d'analyse "6 kHz" en 5 sous bandes adjacentes plus la bande totale.

Les échantillons représentés dans le tableau suivant sont issus des résultats obtenus dans chaque mode de fonctionnement (avec défaut et sans défaut). Le tableau est constitué par les 4 indicateurs temporels dans les 5 bandes fréquentielles et les données spécifique pour tous les cas.

Ø (cm)	Charge (HP)	0000 Hz – 1500 Hz				1500 Hz – 3000 Hz			
		STD	Fc	Fcc	K	STD	Fc	Fcc	K
Sans défaut	3	0.054	3.269	0.360	2.935	0.032	2.051	0.128	1.683
Ø B.I 0,007	3	0.116	4.035	0.909	3.535	0.148	4.174	1.192	3.880
Ø B.I 0,014	3	0.057	3.798	0.444	2.776	0.08	7.391	1.233	1.657
Ø B.I 0,021	3	0.092	4.138	0.746	4.540	0.329	5.046	3.308	6.568
Ø B.I 0,028	3	0.551	3.521	3.727	2.849	0.481	3.769	3.816	3.182

Ø (cm)	Charge (HP)	3000 Hz – 4500 Hz				4500 Hz – 6000 Hz			
		STD	Fc	Fcc	K	STD	Fc	Fcc	K
Sans défaut	3	0.0019	4.281	0.016	3.406	0.0018	3.369	0.013	3.237
Ø B.I 0,007	3	0.235	5.128	2.390	6.096	0.01	4.856	0.144	3.855
Ø B.I 0,014	3	0.129	7.518	1.968	1.589	0.009	7.545	0.145	1.001
Ø B.I 0,021	3	0.213	5.912	2.598	6.815	0.011	5.645	0.123	6.051
Ø B.I 0,028	3	0.196	3.980	1.612	3.202	0.0130	4.742	0.120	3.677

Ø (cm)	Charge (HP)	0000 Hz – 6000 Hz			
		STD	Fc	Fcc	K
Sans défaut	3	0.064	3.309	0.434	2.871
Ø B.I 0,007	3	0.135	4.738	3.037	5.226
Ø B.I 0,014	3	0.173	9.207	3.156	1.630
Ø B.I 0,021	3	0.456	6.547	5.426	8.196
Ø B.I 0,028	3	0.817	3.812	6.508	3.315

Tableau III.1 : Les indicateurs temporelle pour le coupler 3HP avec diamètres de défaut.

III.5.2 Les indicateurs fréquentiels

Le tableau III.2 montre des échantillons de calcul effectué pour les énergies du spectre d'enveloppe, et cela dans 5 bandes adjacentes de 1000 Hz chacune, plus la bande d'analyse totale (0-6 kHz).

\emptyset (cm)	Charge (HP)	Bande 0-1000 Hz	Bande 1000-2000 Hz	Bande 2000-3000 Hz	Bande 3000-4000 Hz	Bande 4000-5000 Hz	Bande 0-6000 Hz
Sans défaut	3	-17305	-18340	-22067	-23410	-23533	-13322
\emptyset B.I 0,007	3	-10899	-121038	-12191	-14958	-18600	-93687
\emptyset B.I 0,014	3	-10662	-13475	-14064	-17264	-20289	-98050
\emptyset B.I 0,021	3	-8430	-11800	-10992	-15938	-18158	-88521
\emptyset B.I 0,028	3	-7281	-7781	-8544	-11820	-15580	-70686

Tableau III.2 : Les énergies dans les bandes de fréquence du spectre d'enveloppe.

III.6 Classification des indicateurs

Notre étude explique comment créer un arbre de décision à l'aide de l'application de classification, et exporter des modèles formés vers "workspace", et aussi montrer comment faire des prédictions pour les nouvelles données, on a utilisé la boîte outils « Classification Learner », disponible sur MATLAB R2018a, la FIGURE III.7 représente un schéma descriptif de la méthode Machine Learning.

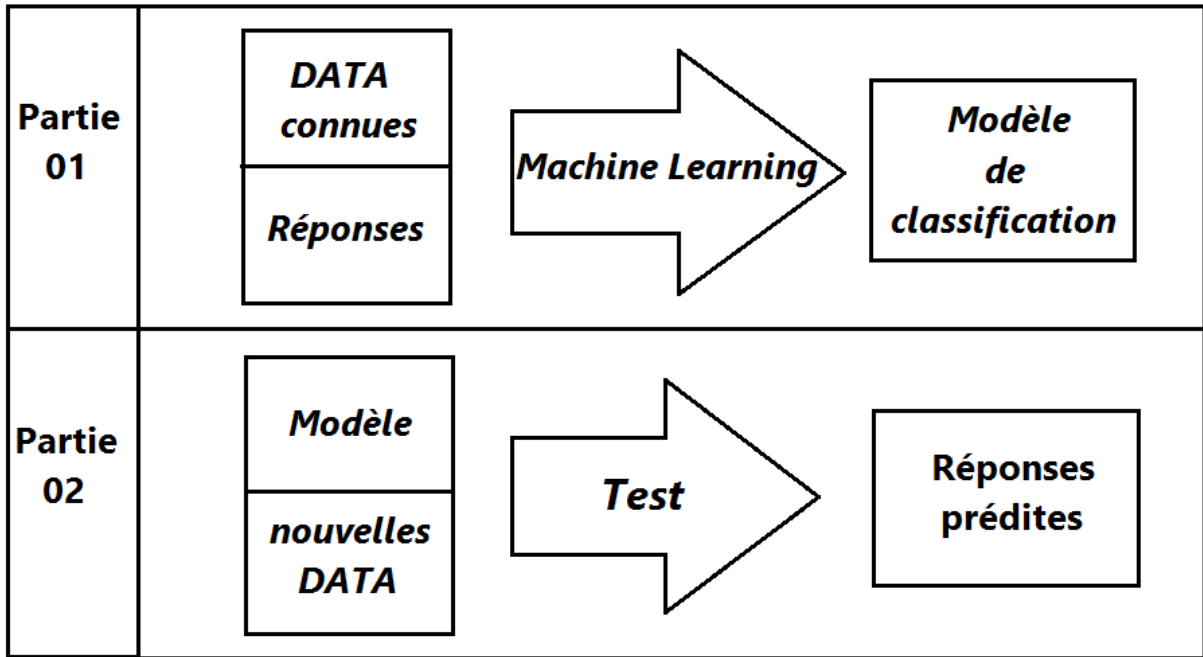


FIGURE III.7 : Schéma descriptif de la méthode Machine Learning (création du modèle, Test).

III.6.1 Préparation des données a classifié

Après le calcul des indicateurs, correspondant aux différents états de fonctionnement et aux différents diamètres de défaut. On les a enregistrés dans une matrice (BDTOT) de dimensions N*M, avec :

N=140 est le nombre des signaux (28 signaux pour chaque classe) :

M=26 est le nombre des indicateurs, plus la colonne des classes :

- Le nombre des bandes fréquentielles = 5.
- Le nombre des indicateurs temporels pour chaque bande fréquentielle = 4.
- Le nombre des indicateurs fréquentielles = 6.

Les données de cette étude ont été divisées en trois parties pour former trois types de données pour chaque cas de fonctionnement :

- 1- Données d'entraînement : BDTOTTRAIN (70 lignes*27 colonnes).
- 2- Données de validation : BDTOTCONF (50 lignes*27 colonnes).
- 3- Données de test : BDTOTTEST (20 lignes*26 colonnes).

III.6.2 Classification par l'application classification Learner :

III.6.2.1 Etape 1 : Création et entraînement d'un modèle avec Machine

Learning

À partir de la fenêtre « New Session from workspace » représentée dans la FIGURE III.8, une session est lancée « Start Session », pour créer un nouveau modèle de classification, avec les données d'apprentissage.

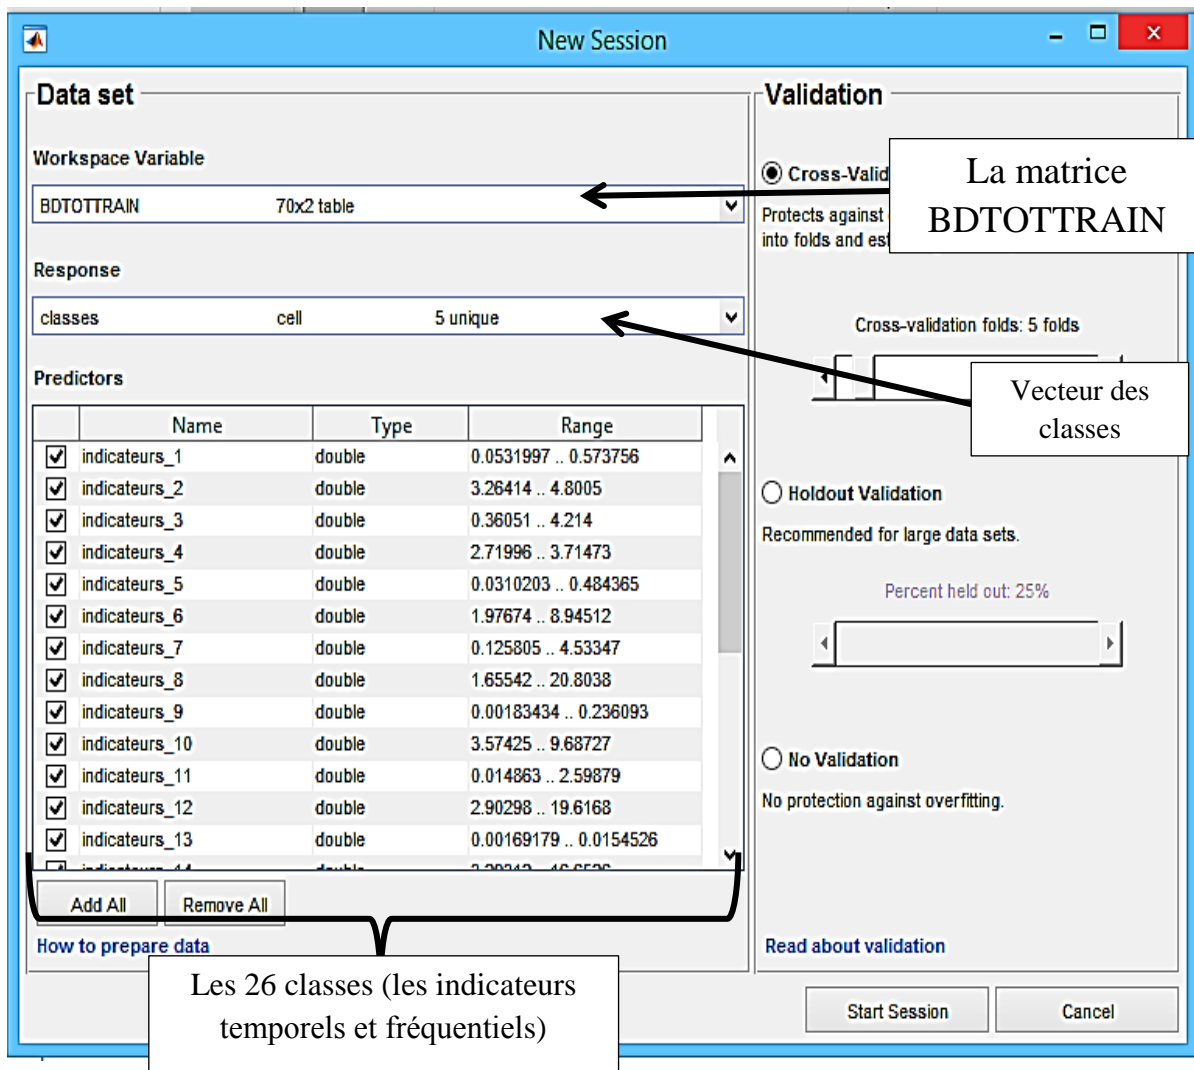


FIGURE III.8 : la fenêtre de « New Session from workspace ».

- 1- Dans la fenêtre de classification Learner (FIGURE III.9) on exécute le travail avec les icones « train » et « exporte model », Pour obtenir le modèle de classification « trainedModel ».

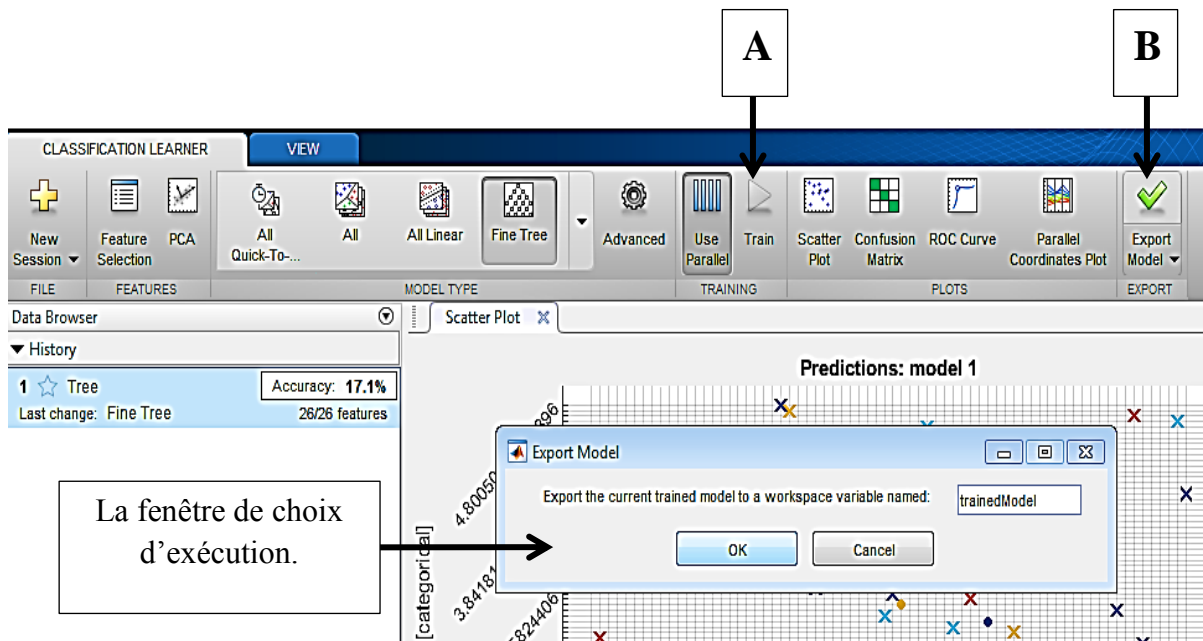


FIGURE III.9 : la fenêtre de « classification learner ».

- L'icône A : permet de démarre l'entrainement d'un modèle de classification.
- L'icône B : permet de démarre l'exportation de modèle.

2- Le modèle de classification apparaît dans la fenêtre « workspace » (montrer dans la FIGURE III.10) immédiatement après la fin du processus d'entrainement.

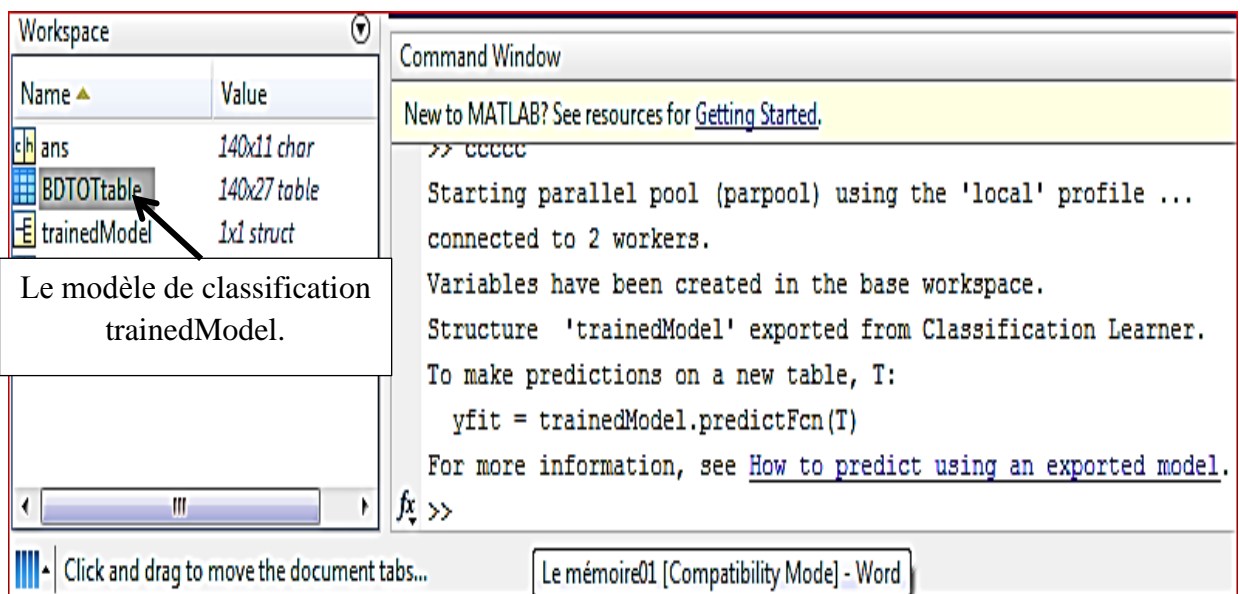


FIGURE III.10 : fenêtre « workspace », le modèle de classification.

- 3- Il est possible d'obtenir le programme de travail, sous forme d'une "fonction" dans la fenêtre "editor" :
 - En retournant à la fenêtre de "classification Learner".
 - En sélectionnant "generate a code" parmi les choix de l'icône "exporte a model", Pour mettre le programme dans la FIGURE III.11.

```

1 function [trainedClassifier, validationAccuracy] = trainClassifier(trainingData)
2 [trainedClassifier, validationAccuracy] = trainClassifier(trainingData)
3 % returns a trained classifier and its accuracy. This code recreates the
4 % classification model trained in Classification Learner app. Use the
5 % generated code to automate training the same model with new data, or to
6 % learn how to programmatically train models.
7 %
8 % Input:
9 %   trainingData: a table containing the same predictor and response
10 %   columns as imported into the app.
11 %
12 % Output:
13 %   trainedClassifier: a struct containing the trained classifier. The
14 %   struct contains various fields with information about the trained
15 %   classifier.
16 %
17 %   trainedClassifier.predictFcn: a function to make predictions on new
18 %   data.
19 %
20 %   validationAccuracy: a double containing the accuracy in percent. In
21 %   the app, the History list displays this overall accuracy score for
22 %   each model.
23 %
24 % Use the code to train the model with new data. To retrain your
25 % classifier, call the function from the command line with your original
26 % data or new data as the input argument trainingData.

```

Le programme de travail « fonction »

FIGURE III.11 : Le programme de travail « fonction » affiche dans la fenêtre editor.

- 4- Pour obtenir l'arbre de décision, nous utilisons la commande MATLAB :

« view (trainedModel.classificationtree,'mode','graph') ».

III.6.2.2 Étape 2 : Validation du modèle de classification

Le modèle de classification et le programme de travail obtenu permettent la création des prédictions afin de répondre à toute nouvelle donnée. Ceci peut être réalisé avec les étapes suivantes :

- 1- Exporter Le modèle de classement « trainedModel » à la fenêtre « workspace ».

- 2- Exporter les nouvelles données de validation « BDTOTCONF » à la fenêtre «workspace ».
- 3- L'application de la fonction « yfit » dans la fenêtre « Command Window » permet de créer le vecteur des classes prédites à la fenêtre « Workspace ».

Les étapes sont également aussi montrées dans la FIGURE III.12.

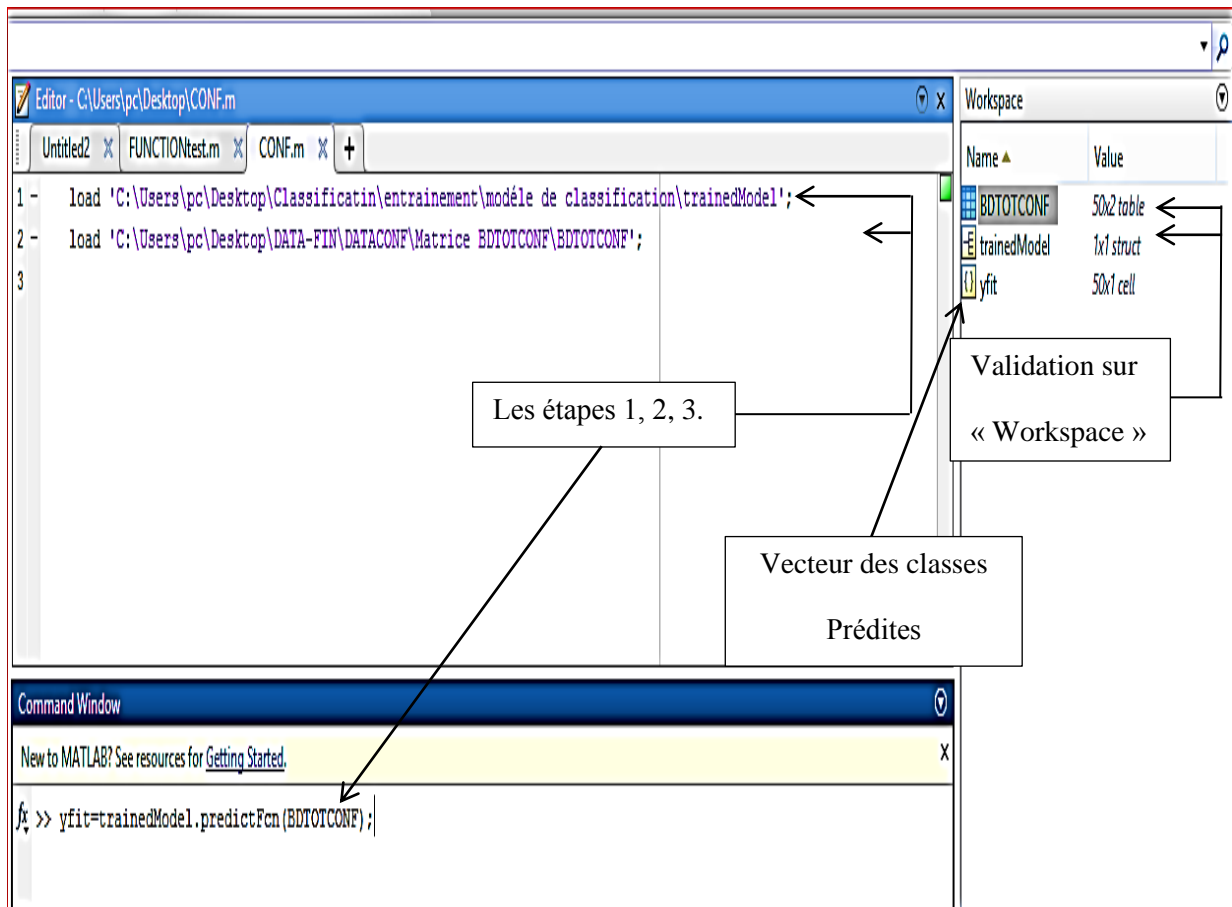


FIGURE III.12 : l'application des étapes de prédiction avec les données de test.

III.6.2.3 Étape 3 : Test du modèle

Nous utilisons les données de test (BDTOTTEST) qui ne contiennent pas la colonne des classes pour faire la prédiction, nous suivons les mêmes étapes de l'étape 2 : Test du modèle de classification.

En conséquence, nous obtenons le vecteur colonne des variables (classes) prédites pour les nouvelles données. Le vecteur montré dans la figure suivante :

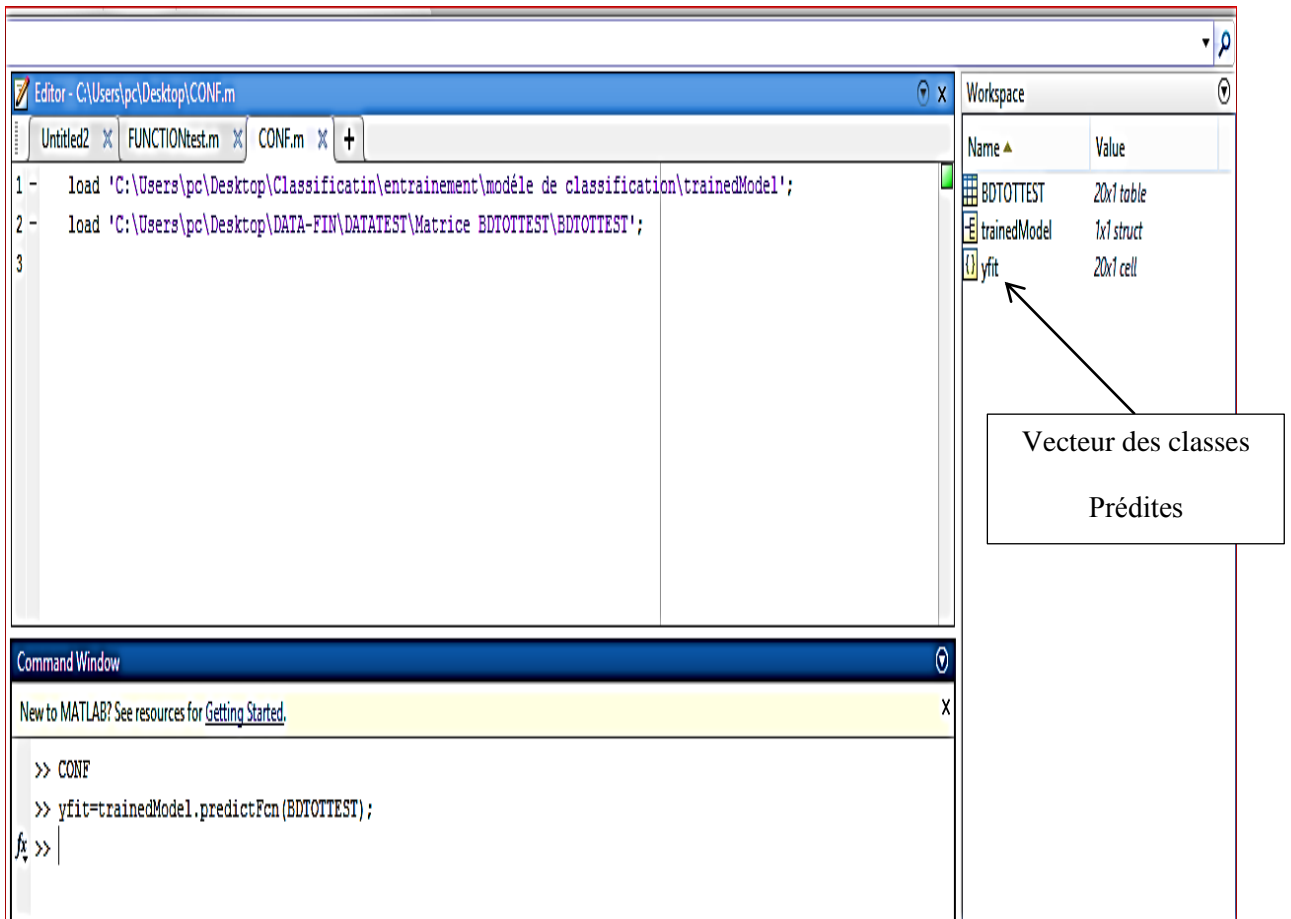


FIGURE III.13 : l'application des étapes de prédiction avec les données de validation.

III.6.3 Interprétation des résultats

D'après les résultats de test du modèle (Etape 3), nous pouvons conclure que ce processus permet de classifier automatiquement et de prendre une décision sur l'état (classe) correspondant aux nouvelles données, et de fournir les réponses prédites avec un degré élevé de précision, ce qui en fait une méthode typique de diagnostic intelligent.

Les Figures III.14 et III.15 représentent les deux schémas de classification des états de fonctionnement avec la classification Learner :

La Figure III.14 : nuage de points (scatter plot), représente les données dépendantes de plusieurs variables. Elle permet de mettre en évidence le degré de corrélation entre au moins deux indicateurs liés.

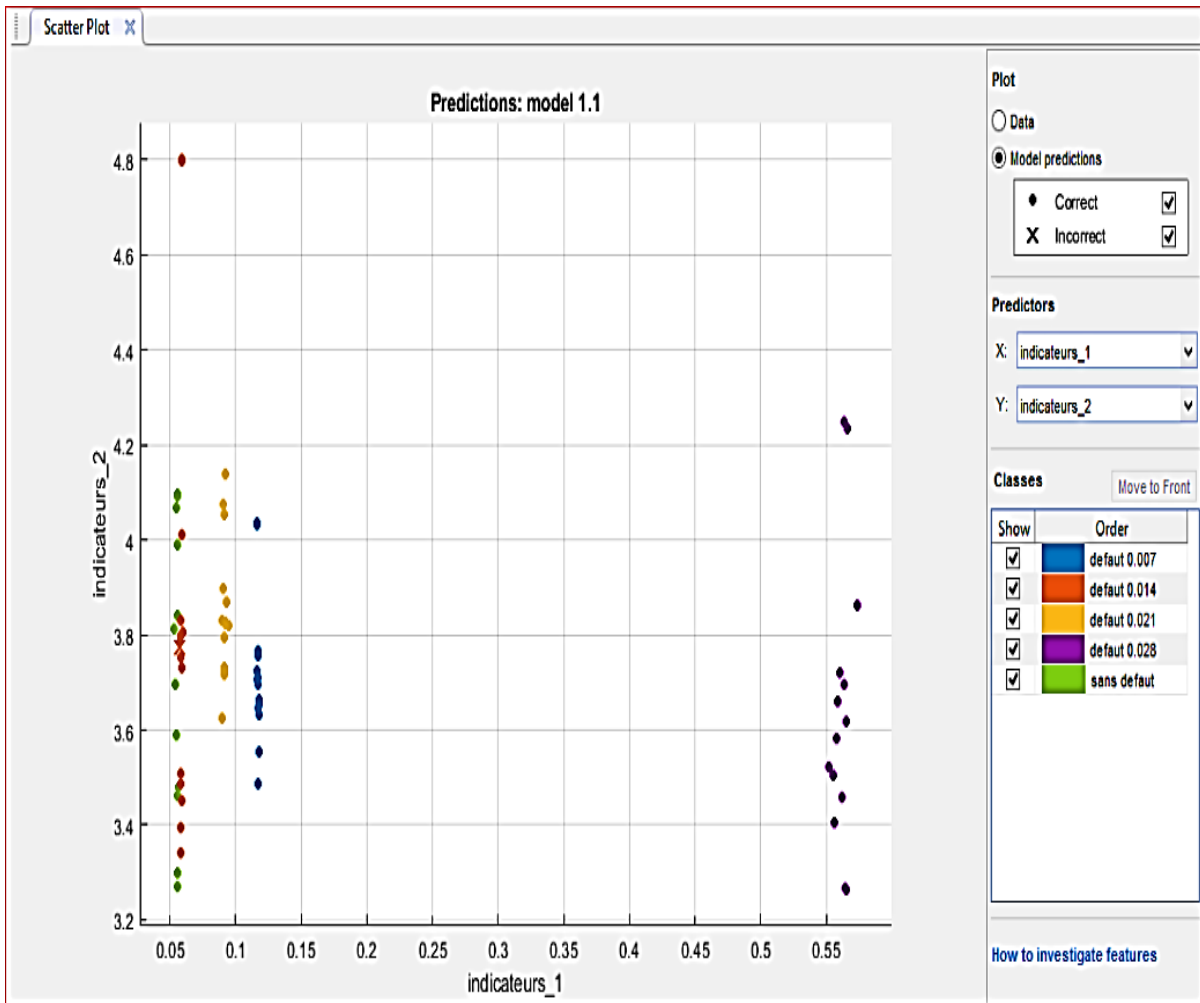


FIGURE III.14 : nuage de points (scatter plot).

La Figure III.15 représente la matrice de confusion (confusion matrix), elle a pour but de comparer les indicateurs entre les différents cas de fonctionnement.

Le schéma de nuages de points obtenus à partir du processus de classification met en évidence le degré de corrélation entre les indicateurs 1 et 2 (STD, Fc).




FIGURE III.15 : la matrice de confusion (confusion matrix).

On constate que :

- Les différents états de fonctionnement du système étudié sont bien classés et avec une précision (Accuracy) de 98.6%.
- Une seule erreur a été enregistrée lors du processus de classification, en raison de la confusion entre les valeurs des indicateurs du cas sans défaut et du cas défaut 0.014, L'erreur est indiquée par une croix dans le schéma.

Cette erreur peut être vue dans le schéma de la matrice de confusion, affiché dans la case qui représente une comparaison entre les valeurs des indicateurs du cas sans défaut et du cas défaut 0.014.

L'arbre de décision permet de montrer comment le machine Learning prend la décision, en suivant les nœuds et les branches de l'arbre structuré jusqu'à atteindre les réponses à prévoir (défaut, sans défaut...).

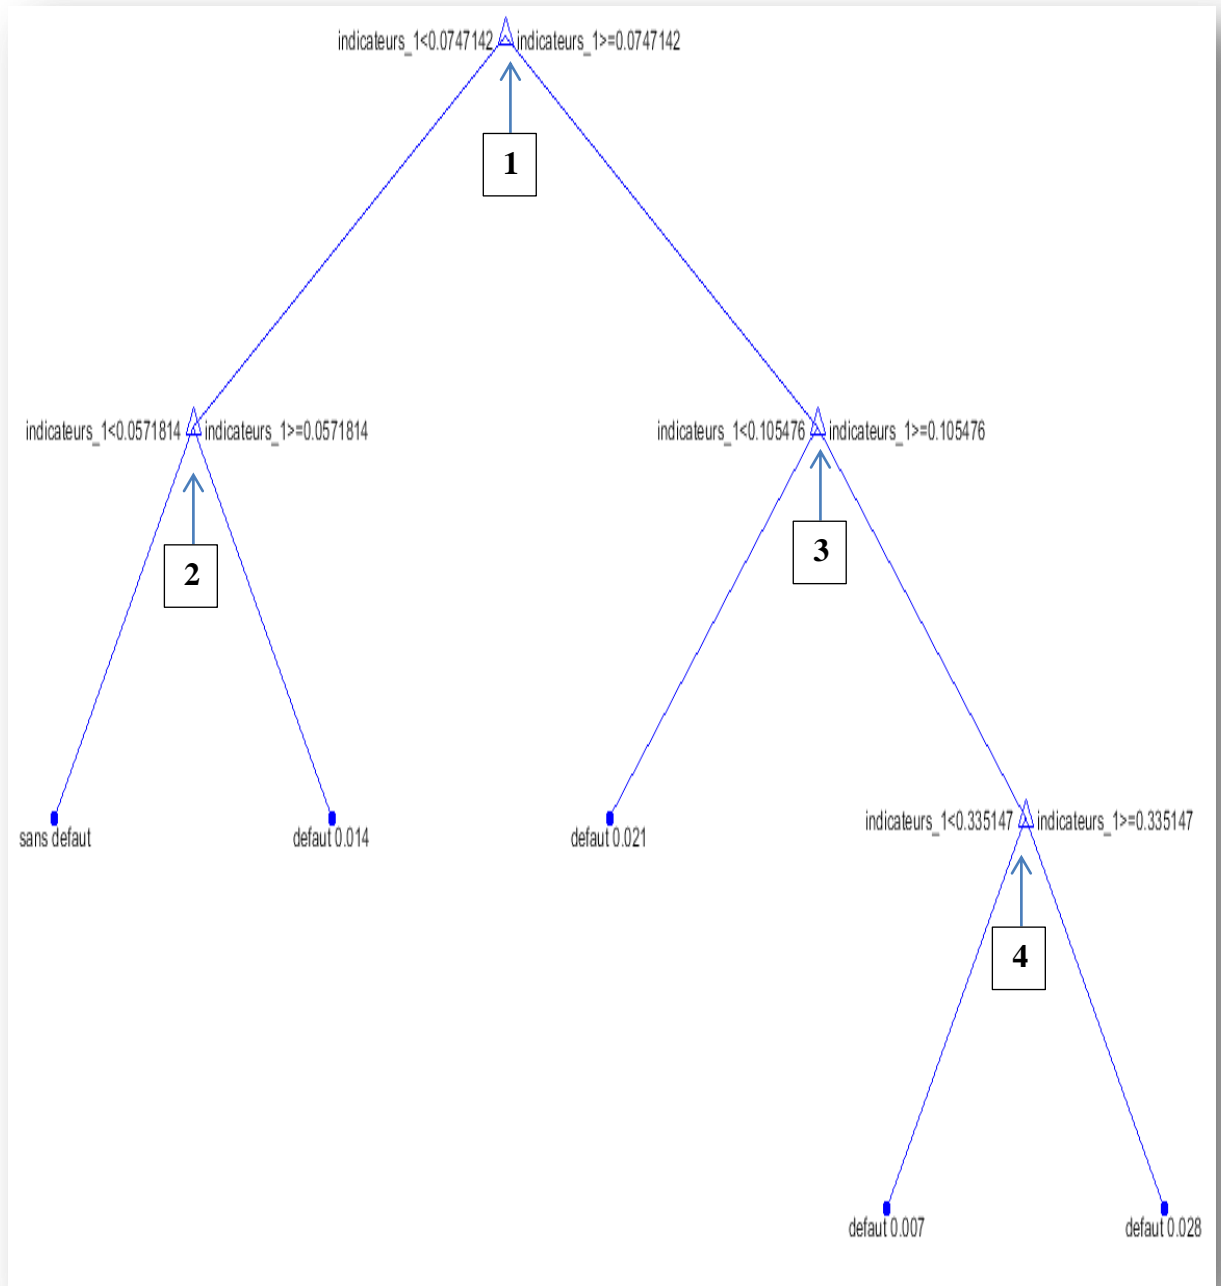


FIGURE III.16 : l'arbre de décision.

La Figure III.16 représente la structure de l'arbre de décision obtenu par les données de l'entraînement (première étape de l'exécution du programme), nous notons que le processus de classification avec l'arbre de décision a été bien fait et avec précision, on remarque que :

- L'arbre est construit avec les valeurs de la valeur efficace STD (indicateur 1), on utilise cette valeur parce que c'est la valeur la plus utilisée pratiquement dans l'étude des défauts.
- L'arbre est construit à partir de nœud 1 (nœud de départ) qui présente la règle « $STD < 0.074$ », s'il est juste on passe au deuxième nœud (nœud 2), sinon on passe au troisième nœud (nœud 3).

III.7 Conclusion

Ce chapitre présente les résultats de l'application de la méthode des arbres de décisions comme un outil de diagnostic des défauts de roulements d'un moteur électrique, par la classification automatique des différents indicateurs temporels et fréquentiels calculés à partir des signaux vibratoires réels des roulements, correspondant aux différents états de fonctionnement du banc d'essai.

On a expliqué comment créer un modèle de classification avec les indicateurs, et l'utiliser dans la prévision et la classification avec des autres nouvelles bases de données.

Conclusion générale

Les machines tournantes pendant leur travail émettent des vibrations qui se changent en fonction de leur état. L'idée du diagnostic intelligent des machines est basée sur l'utilisation des résultats de l'analyse vibratoire dans le processus de l'automatisation du diagnostic et de prise de décision sur l'état de santé des systèmes étudiés.

L'intelligence artificielle est un domaine émergeant basé sur l'exécution automatique de tâches, en général l'apprentissage automatique donne la possibilité de faire des prédictions automatiquement à l'aide de bases des données, donc il est très approprié pour l'utilisation dans le domaine du diagnostic des défauts mécaniques.

Au cours de cette étude, nous avons discuté la classification intelligente des données enregistrées à partir de l'analyse des signaux vibrations issus d'un banc d'essai conçu pour étudier les défauts de roulements. Nous avons également utilisé la machine learning comme un moyen de diagnostic automatique. La prise de décision sur le mode de fonctionnement (ans défaut ou avec défaut) du système étudié est faite automatiquement par la méthode de l'arbre de décision.

Le processus utilisé a prouvé une grande capacité de classification des états de fonctionnement de la machine étudiée et par la suite d'identifier et de reconnaître avec une haute précision l'état de santé ainsi que le type et l'élément défaillant.

L'avenir du diagnostic intelligent des pannes mécaniques est très prometteur, surtout à la lumière du grand développement dans le domaine de l'intelligence artificielle, ce développement permet de maintenir les machines en état de bon fonctionnement pendant une plus longue période.

Bibliographie

- [1]-D Saliou ; « Contribution au diagnostic industriel de défaut de roulement et de balourd par technique neuronales application a la machine asynchrone a cage ». Thèse de doctorat, Université Paris XII Val de Marne Creteil, 2007.
- [2]-D Mourad ; « L'introduction de défauts mécaniques dans l'étude des machines tournantes ». Thèse magistère 2001.
- [3]-K Ilyes ; « Diagnostic des machines tournants par les technique de l'intelligence artificiel, thèse de doctorat », Université Badj Mokhtar Annaba, 2013-2014.
- [4]-H Mohammed ; « Application de l'ODS à l'analyse des problèmes de vibration des machines tournantes ». Mémoire de master, 2012.
- [5]-B Nedjoudja ; « Conception d'un outil d'aide à la détection et diagnostic des défaillances dans un système de production ». Mémoire de master, Université de Batna, 2011-2012.
- [6]-O Djebili ; «Contribution à la maintenance prédictive par analyse vibratoire des composants mécaniques tournants. Application aux butées à billes soumises à la fatigue de contact de roulement». Thèse de doctorat, Université De Reims Champagne Ardenne, 2013.
- [7]-Héng, 2002 & Randall, 2011.
- [8]-Bruel & KJAER ; « Analyse des vibrations maintenance conditionnelle des machines tournantes ». www.bkvibro.com, copyright 2005.
- [9]-C Angeli & A Chatzinikolaou ; «On-line fault detection techniques for technical systems: A survey». International journal of Computer Science & application, Vol. 1, pp.12-30, 2004.
- [10]-A Chloé ; «Introduction au Machine Learning».
- [11]-<https://ch.mathworks.com/fr/discovery/machine-learning.html?fbclid=IwAR2RkxJwKsQZBZrZ1MRSDad-8rkcBUyK-q7lz3iMsi16MzbM9HfcQ8tbCI>.
- [12]-R Kegg ; «One-Line Machine and Process Diagnostics ». CIRP Annals Manufacturing Technology, 33(2), 469-473, 1984.
- [13]-A Mille ; « Les Réseaux Bayésiens A la recherche de la vérité ». Cours Cognition et connaissance, Université Claude Bernard Lyon 1, pp. 1-9, 2007.

- [14]-Q Yang ; « Model-Based and Data Driven Fault Diagnosis Methods With Applications to Process Monitoring». PHD thesis, Electrical Engineering and Computer Sciences, Case Western Reserve University, Ohio, USA, 2004.
- [15]-W Kajiro, I Matsuura, M Abe, M Kubota, and D. M. Himmelblau; «Incipient fault diagnosis of chemical processes via artificial neural networks». Aiche Journal, vol.35, pp.1803-1812, 1989.
- [16]-V Venkat, R Rengaswamy, N.K Surya , and K Yin, «A review of process fault detection and diagnosis: Part iii: Process history based methods». Computers & Chemical Engineering, pp.327–346, 2003.
- [17]-W Arnaud; « Application des algorithmes d'apprentissage automatique pour la détection de défauts de roulements sur les machines tournantes dans le cadre de l'Industrie ». Mémoire présenté à l'Université du Québec à Chicoutimi en vue de l'obtention du grade de Maître ès sciences appliquée en ingénierie, profil recherche.
- [18]-B E Boser & I M Guyon, & V N Vapnik ; « A training algorithm for optimal margin classifiers». Dans Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory, pp. 144-152.
- [19]-L Yinan ; Rapport de Mémoire, master 1 informatique, université du Hawe, 2005/2006.
- [20]-S Fedala ; « Le diagnostic vibratoire automatisé: comparaison des méthodes d'extraction et de sélection du vecteur forme ». Magister thesis, University of Setif, 2005.
- [21]-F Hocine, « Application des réseaux de neurones artificiels au diagnostic des défauts des machines tournantes ». Magister Thesis. University of Setif, 2008.

Résumé

Cette étude discute le diagnostic automatique des défauts mécaniques des machines tournantes par la méthode de la Machine Learning, en se basant sur l'analyse des signaux vibratoires issus d'un banc d'essai conçu pour étudier les défauts de roulements. Nous avons également utilisé la machine learning comme un moyen de classification et de diagnostic automatique.

La prise de décision sur le mode de fonctionnement (sans défaut ou avec défaut) du système étudié est faite automatiquement par la méthode de l'arbre de décision.

Le processus utilisé a prouvé une grande capacité de classification des états de fonctionnement de la machine étudiée et par la suite d'identifier et de reconnaître avec une haute précision l'état de santé ainsi que le type et l'élément défaillant.

Mots-clés: Machines tournantes, apprentissage automatique, analyse vibratoire, arbre de décision.

Abstract

This study discusses the automatic diagnosis of mechanical faults of rotating machines by the Machine Learning method, based on the analysis of vibratory signals from a test rig designed to study bearing faults. We also used machine learning as a tool of classification and automatic diagnosis.

Decision-making on the mode of operation (without or with faults) of the studied system is done automatically by the decision tree method.

The process used has proven a high capacity to classify the operating states of the machine studied and subsequently to identify and recognize with high precision the state of health as well as the type and the faulty element.

Keywords: Rotating machines, machine learning, vibration analysis, decision tree.

ملخص

تناقش هذه الدراسة التشخيص التلقائي للعيوب الميكانيكية للألات الدوارة بواسطة طريقة التعلم الآلي، استناداً إلى تحليل الإشارات الاهتزازية من جهاز اختبار مصمم لدراسة العيوب في المدحرجات، كما استخدمنا طريقة تعلم الآلات كأداة للتصنيف والتشخيص التلقائي.

إن اتخاذ القرار حول أسلوب عمل النظام المدروس (بدون أو مع عيوب) يتم تلقائياً بواسطة أسلوب شجرة القرار.

وقد أثبتت الطريقة المستخدمة قدرة عالية على تصنيف الحالات التشغيلية للألة التي تمت دراستها ومن ثم تحديد الحالة الصحية وكذلك النوع والعنصر الذي فيه عيب والتعرف عليهما بدقة عالية.

الكلمات المفتاحية: الآلات الدوارة، التعليم الآلي، تحليل الاهتزازات، شجرة القرار.