

E.N.S.T

المدرسة الوطنية العليا للتكنولوجيا
Ecole Nationale Supérieure de Technologie



Department of Industrial
Engineering & Maintenance

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Département : Génie Industriel Et Maintenance

Mémoire de fin d'étude en vue de l'obtention du diplôme

D'Ingénieur d'État en Génie Industriel

Spécialité

Management et Ingénierie de la Maintenance Industrielle

- Thème -

Diagnostic de défauts multiples dans les machines tournantes basé sur les réseaux de neurones convolutifs

Réalisé par

Bechichi Mohamed lamine

Les membres de Jury :

REZGUI Wail (MCB)	Président
MEDDOUR Ikhlas (MCA)	Promoteur
HAOUARI Fouad	Examineur

Alger, le 06/07/2022

Année universitaire 2021–2022

Dédicace

“

Je d'édie ce travail

À mes cherh parent

À mes frères et soeurs.

À toute ma famille.

À tout mes amis.

À tous ceux qui me sont chers, à vous tous

Merci.

”

- Mohamed lamine

Remerciements

“

Tout d’abord, je remercie Allah le tout puissant de m’avoir donné le courage et la patience nécessaires à mener ce travail à son terme.

*Je tiens à remercier tout particulièrement mon encadrant monsieur **MEDDOUR Ikhlas**, pour m’avoir donné l’opportunité de travailler sur ce projet, pour son grand soutien scientifique, pour les conseils qu’il m’a apportés pendant l’élaboration de ce mémoire.*

Que les membres de jury trouvent, ici, l’expression de mes sincères remerciements pour l’honneur qu’ils me font en prenant le temps de lire et d’évaluer ce travail.

*Je remercie mes parents et ma soeur **Akila** pour leur présence et leur soutien moral et physique sans faille.*

Pour finir, je souhaite remercier toute personne ayant contribué de près ou de loin à la réalisation de ce travail.

”

Table des matières

Dédicace	I
Remerciements	II
Introduction générale	1
1 Etude bibliographique	3
Introduction.....	4
Généralités sur la maintenance	4
Définition.....	4
Les types de maintenance	4
Surveillance	6
Types de surveillance.....	6
Techniques de surveillance des machines tournantes	8
Choix d'une technique de surveillance	10
Les principaux défauts qui touchent les machines tournantes	11
analyse vibratoire.....	14
Vibration.....	14
Les méthodes de l'analyse vibratoire	16
Méthodes de diagnostic	20
Terminologie relative au diagnostic	20
Etapas du diagnostic.....	21
Classification des méthodes de diagnostic	21
Etat de l'art sur l'application des méthodes d'Intelligence Artificielle utilisées dans le diagnostic automatique des Machines tournantes.....	24
Intelligence Artificielle.....	24
L'Apprentissage Automatique (Machine Learning)	24
L'apprentissage profond (Deep Learning)	27
Conclusion.....	31
2 Banc d'essai	32
Introduction.....	33
Montage Expérimental	33
Banc Expérimental	33
Logiciel de traitement de données.....	37
Plan expérimental	38
Conclusion.....	39

3 Détection et classification des défauts par la méthode CNN	40
Introduction.....	41
2. Les bibliothèques de python utilisées pour le développement du modèle de détection et classification	41
Analyse de l'état	44
Conception de modèle	45
Les étapes	46
Résultat et discussion	49
Colclusion.....	50
Conclusion Générale	51
Résumé	
Abstract	
.	ملخص

Table des figures

Les types de maintenance.....	5
Les fonctions de la surveillance industrielle [4].....	6
Les types de surveillance [4].....	7
La surveillance On-line [4].....	7
La surveillance Off-line [4].	8
Différentes techniques de la surveillance des machines tournantes [17].....	8
Principe de l'analyse vibratoire [4] : a) Mesures des vibrations. b) Représentation du spectre vibratoire	9
Technique de la thermographie infrarouge [4].....	9
Composantes d'un roulement [15].	11
Exemples des défauts de roulement [7].....	12
Défaut répartis d'engrenage [7].	13
Défaut localisé d'engrenage [7].	14
Procédure d'analyse de l'enveloppe [5].	18
Les étapes du diagnostic.	21
Classification générale des méthodes de diagnostic[23].....	22
Relation entre les différentes disciplines de l'IA [22].....	24
Les grandes classes d'apprentissage automatique [14].	25
Architecture standard de CNN [34].	28
La structure du RNN [10].	30
La structure du GAN [10].	30
La structure de l'Auto-Encodeur [37].....	31
Le banc d'essai [35].....	33
a) photos d'engrenage sans défaut. b) photos d'engrenage avec défaut [35].	34
2.3 Schéma cinématique du banc [35].....	35
Accéléromètre [35].....	36
Le conditionneur [35].	37
Fenêtre du logiciel de traitement DynamX 7 [35].	38
Photos des défauts simulés [35].	39
Quelle que bibliothèque utiliser dans notre modèle.	41
Exemple d'un spectre sonore.[16]	42
Exemple d'un audio en domaine temporel.[16]	43
Exemple d'un périodogramme.[16]	43
Exemple d'un spectrogramme.[16]	44
Format final d'un extrait sonore.	44
Architecture de notre modèle.....	45

Table des figures

Exemple de la sortie d'une couche de convolution [31].	46
Exemple de la sortie d'une couche de MaxPooling [31].	46
Exemple de la fonction Flatten [31].	47
Les paramètres de la fonction FIT pour notre modèle.	47
Nombre d'époques et de Lot utilisé dans notre modèle.	48
Accuracy de notre modèle en fonction de nombre d'époques.	49
Loss de notre modèle en fonction de nombre d'époques.	49

Liste des tableaux

Choix de technique de surveillance [4][29][15].....	10
Les principaux indicateurs scalaires [8].	17
Les avantages et les inconvénients des méthodes du domaine fréquentiel [25].	19
Les avantages et les inconvénients des méthodes d'apprentissage profond [30].	31
Fréquences caractéristiques des défauts d'engrenages [35].	36
caractéristiques géométriques utilisés [35].	36
Les sons d'engrenage sans défaut, avec défaut simple et avec défaut multiple.	39

Liste des sigles et acronymes

CNN	<i>Convolutional Neural Network</i>
RNN	<i>Recurrent Neural Network</i>
GAN	<i>Generative Adversarial Network</i>
AE	<i>Auto-Encodeur</i>
DL	<i>Deep Learning</i>
IA	<i>Intelligence Artificielle</i>
SVM	<i>Support Vector Machine</i>
K-NN	<i>k-nearest neighbors</i>
SVR	<i>Support Vector Regression</i>
AQT	<i>Analyse Qualitative des Tendances</i>
ACP	<i>Analyse en Composantes Principales</i>

Introduction générale

Les machines tournantes occupent actuellement une place prépondérante dans les applications industrielles. Ces machines tournantes sont composées de plusieurs éléments comme le stator, le rotor, l'arbre, les éléments de transmission de puissance et guidage en rotation. Les roulements et les engrenages sont considérés comme étant les éléments mécaniques les plus sensibles dans la machine. Lors du fonctionnement des machines tournantes, ils sont subis à plusieurs défauts qui ont un impact important sur les performances, la fiabilité, la disponibilité et l'efficacité des machines tournantes par conséquent ils augmentent le coût de maintenance.

Un diagnostic efficace de défaillances d'un système industriel permet de détecter précocement les défauts pour améliorer la productivité. Le diagnostic peut être approché de deux manières essentielles, avec ou sans connaissances préalables dont le premier est basé sur la modélisation des systèmes, alors que le second se base sur les principes de l'intelligence artificielle. Les méthodes sans connaissance préalable possèdent de nombreux avantages, notamment le fait qu'il n'est pas nécessaire d'utiliser le modèle du système à diagnostiquer. Cette catégorie comprend les méthodes basées sur la reconnaissance des formes, les systèmes experts, les réseaux de neurones.

Selon l'état de l'art, la majorité des travaux de recherche s'intéressent à l'étude des défauts simples, où on se concentre sur un seul défaut sans prendre en considération la possibilité d'existence ou d'apparition d'un autre défaut. Les approches proposées restent donc très limitées puisqu'elles sont dédiées à des cas particuliers de défauts. Nous sommes donc motivés dans ce travail de proposer une approche de détection et de diagnostic non seulement des défauts simples, mais aussi des défauts combinés à différents degrés de dégradation. L'approche proposée se base sur l'exploitation des spectrogrammes des signaux vibratoires par la méthode des réseaux de neurones convolutifs.

Ce manuscrit est subdivisé en trois chapitres et finit se termine par une conclusion générale.

Le premier chapitre divisé en cinq grandes parties, la première aborde des généralités sur la maintenance industrielle et les différents types de maintenance. La deuxième partie concerne la surveillance et leurs techniques les plus utilisées et ses applications dans le domaine des machines tournantes, et les principaux défauts qui touchent les machines tournantes. La troisième partie présente une étude théorique sur la surveillance vibratoire des machines tournantes ainsi que les différentes méthodes de traitement du signal utilisés dans ce domaine. Tandis que la quatrième partie concerne les étapes et les différents méthodes de diagnostic et la dernière partie décrit des outils d'intelligence artificielle souvent utilisés dans le diagnostic automatique des machines tournantes.

Le deuxième chapitre, est dédié à la présentation technique du banc d'essai sur lesquels l'approche proposée sera testée.

Le troisième chapitre présente les étapes de la mise en œuvre d'un modèle intelligent de diagnostic et de classification des défauts par la méthode des Réseaux de Neurones Convolutifs, où trois cas sont abordés, à savoir, système sans défauts, système avec un défaut simple et système avec des défauts combinés.

Dans ce contexte, les vibrations jouent un rôle clé dans le diagnostic des défauts des machines tournantes. En effet, la modification de la signature vibratoire d'une machine tournante est souvent la première marque physique d'une anomalie.

Chapitre 1

Etude bibliographique

Introduction

Aujourd'hui, les machines tournantes sont présentes dans de nombreuses installations industrielles. Vu l'importance de ces machines tournantes dans l'industrie, il est nécessaire de garder les en bon état. Pour ce raison la maintenance est un élément principal pour garder les équipements en bonne état. Dans ce chapitre on va voir des généralités sur la maintenance industrielle, généralités sur la surveillance des machines tournantes, la surveillance par l'analyse vibratoire (surveillance vibratoire) et les méthodes de diagnostic des défauts. On termine ce chapitre par un état de l'art sur l'application des méthodes d'intelligence artificielle dans le diagnostic automatique des machines tournantes.

Généralités sur la maintenance

Définition

Dans les entreprises, la maintenance est considérée comme fonction stratégique, selon la norme européenne NF EN 13306 X 60-319 est une ensemble des 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 ». Elle a essentiellement pour but [6] :

- D'augmenter la durée de vie des matériels.
- De diminuer la probabilité des défaillances en service.
- De diminuer les temps d'arrêt en cas de panne.

Les types de maintenance

On distingue deux principaux types de maintenance :

Maintenance corrective

« Maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).

La maintenance corrective consiste donc à intervenir sur un équipement une fois que celui-ci est défaillant.

Elle est subdivisée en maintenance palliative et curative.

- La maintenance corrective curative couramment appelée réparation, a pour objectif de rétablir un équipement dans un état spécifié pour lui permettre d'accomplir une fonction requise. ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).
- La maintenance corrective palliative couramment appelée dépannage, est destinée à permettre à un équipement d'accomplir provisoirement tout ou partie d'une fonction requise. ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).

Maintenance préventive

« Maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinés à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).

La maintenance préventive consiste donc à intervenir sur un équipement avant la défaillance de ce dernier.

Elle est subdivisée en :

- Maintenance conditionnelle désigne la « Maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement et intégrant les actions qui en découlent ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).
- Maintenance systématique désigne la « Maintenance préventive exécutée à des intervalles de temps préétablis (tous les mois) ou selon un nombre défini d'unités d'usage (nbr d'heure de fonctionnement d'un équipement, nbr d'unités fabriquées par un équipement) mais sans contrôle préalable de l'état du bien ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).
- Maintenance prévisionnelle désigne la « Maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien ». (Extrait de la norme européenne NF EN 13306 X 60-319 de juin 2001).




FIG. 1.1 : Les types de maintenance.

Surveillance

La surveillance est un élément de la maintenance préventive conditionnelle, le rôle principal de la surveillance des machines tournantes est de fournir en permanence des informations sur leurs états sans arrêter la chaîne de production. L'objectif de cette technique est d'améliorer la disponibilité et la sécurité, ainsi que la minimisation des pertes dans la production. Elle consiste principalement à détecter et à classer les défaillances en observant l'évolution du système, puis à la diagnostiquer en localisant les éléments défaillants et en identifiant les causes [4][29].

La surveillance se compose de deux fonctions principales qui sont la détection et le diagnostic.

- **La détection** : Dont le but est de déterminer la présence ou non d'un défaut affectant le procédé. Elle consiste à analyser et déceler ses effets (symptômes) sur le système.
- **Le diagnostic** : Se basant sur les défauts détectés, cette fonction se décompose donc en deux fonctions élémentaires :

Une localisation : Qui sert à déterminer le type de défaut affectant le procédé à base d'informations sur l'élément défectueux.

Une identification : elle permet d'identifier la cause de ces symptômes en identifiant l'origine et la nature du défaut, et de déterminer sa taille et son comportement temporel.




FIG. 1.2 : Les fonctions de la surveillance industrielle [4].

Types de surveillance

Selon leur importance et leur criticité, les machines à besoin d'un système de surveillance en ligne ou hors ligne avec des capacités de diagnostic, comme dans le cas des machines simples telles que les pompes et les ventilateurs. Il existe essentiellement deux types de surveillance [4] [29] :

- Surveillance On-line.
- Surveillance Off-line.




FIG. 1.3 : Les types de surveillance [4].

Surveillance "On-line" ou suivi continu

Ce type de surveillance est utilisé en permanence sur une machine particulière et surveille en permanence son état de fonctionnement par la mesure en continu des paramètres physiques, en particulier ceux à évolution rapide tels que la vitesse, la traction et les vibrations. Par conséquent, il joue un rôle important dans l'efficacité du contrôle des processus. Si l'état de la machine change soudainement, un signal d'alarme sera immédiatement émis vers la salle de contrôle. Cette technique repose généralement sur un diagnostic dit à base des modèles, qui s'appuient sur la modélisation comportementale et structurelle du système à diagnostiquer. Le principe est de comparer le comportement prédit obtenu à partir du modèle de représentation (de bon fonctionnement) avec le comportement réel observé. Cette comparaison vous permet de détecter les incohérences pour déduire les causes des défauts [4] [29].




FIG. 1.4 : La surveillance On-line [4].

Surveillance "off-line" ou suivi périodique

Avec ce type de surveillance, des mesures, des prélèvements et des contrôles sont effectués régulièrement à des moments préétablis. Par exemple, en thermographie infrarouge ou en analyse d'huiles, où l'évolution du paramètre physique est plutôt lente, la surveillance est nécessairement périodique [4].




FIG. 1.5 : La surveillance Off-line [4].

Techniques de surveillance des machines tournantes

Aujourd'hui, plusieurs techniques peuvent être employées pour surveiller l'état des machines tournantes par l'analyse des vibrations, du bruit, thermique, du courant, d'huile, etc... [4][17][19].




FIG. 1.6 : Différentes techniques de la surveillance des machines tournantes [17].

Analyse vibratoire

L'analyse vibratoire occupe une place considérable dans les stratégies de maintenance conditionnelle. Elle permet la détection des défauts rencontrés sur les machines tournantes,

Chapitre 1. Etude bibliographique

Son principe consiste à mesurer un signal vibratoire sur la machine et ensuite traiter ce signal par des outils spécifiques [4] [17][19][8].




FIG. 1.7 : Principe de l'analyse vibratoire [4] :

a) Mesures des vibrations.

b) Représentation du spectre vibratoire

Analyse d'huile

L'huile est toujours en contact avec les pièces mobiles (en mouvement). Il fournit de nombreuses informations sur l'état de la machine. L'analyse d'huile est appliquée à toutes les machines contenant des fluides de lubrification. Dans cette technique, un échantillon d'huile est prélevé et analysé (recherche de particules d'usure) pour en déduire l'état de l'équipement [4] [17][19][8].

Analyse par thermographie

Cette technique permet de mesurer la température de composants sans contact. Il peut être utilisé pour surveiller des machines tournantes, notamment pour détecter des défauts qui se manifestent par un échauffement anormal de la surface de l'équipement. La thermographie permet de réaliser des mesures à distances et d'obtenir instantanément une image thermique de la zone inspectée [4] [17][19][8].



FIG. 1.8 : Technique de la thermographie infrarouge [4].

Choix d'une technique de surveillance

Les méthodes citées précédemment, n'ont pas la capacité de détecter les mêmes types de défauts, c'est pourquoi elles entrent rarement en concurrence. Donc, il n'existe pas une méthode universelle permettant de détecter de manière assez précoce tous les types de défauts susceptibles de se produire sur une machine tournante, chaque méthode a son champ d'application privilégié [4][29].

Parmi les méthodes de surveillance, l'analyse vibratoire est la plus connue et la plus largement employée que l'analyse des huiles et l'analyse thermique, le tableau 1.1 donne un aperçu sur les critères pris en compte pour le choix de l'outil de surveillance [4][29].

TAB. 1.1 : Choix de technique de surveillance [4][29][15].

	Les avantages	Les limitations	Champ d'application privilégié
Analyse vibratoire	Détection de défauts à un stade précoce. Possibilité de réaliser un diagnostic approfondi - Autorise une surveillance continue. Permet de surveiller l'équipement à distance (télémaintenance).	Spectres parfois difficiles à interpréter. Dans le cas de la surveillance continue, installations relativement coûteuses.	Détection des défauts de tous les organes cinématiques de la machine (balourd, défauts d'alignement, jeux, etc.) et de sa structure.
Analyse d'huile	Détection d'une pollution anormale du lubrifiant, avant que celle-ci n'entraîne une usure ou un échauffement. Possibilité de connaître l'origine de l'anomalie par analyse des particules.	Ne permet pas de localiser précisément le défaut. Nécessite de prendre de nombreuses précautions dans le prélèvement de l'échantillon.	Contrôle des propriétés physico-chimiques du lubrifiant, détection d'un manque de lubrification, analyse des éléments d'usure, analyse de contamination par le process (étanchéité), etc.
Analyse par thermographie	Permet de réaliser un contrôle rapide de l'installation. Interprétation souvent immédiate des résultats.	Détection de défauts à un stade moins précoce que l'analyse vibratoire. échauffements de surface. Ne permet pas de réaliser un diagnostic approfondi.	Détection de tous les défauts engendrant un échauffement (manque de lubrification en particulier).

Les principaux défauts qui touchent les machines tournantes

Les défauts d'engrenages et de roulements en fonctionnement représentent un coût significatif pour l'industrie et il est important de les éviter. Les statistiques sur les causes de défaillance et la localisation des défauts permettent de conclure que les éléments les plus sensibles sont les engrenages et les roulements.

Défaut de roulement

Les roulements sont les éléments mécaniques les plus importants des machines tournantes et leur utilisation au sein des machines tournantes devient une nécessité absolue. Généralement, un roulement est constitué de deux bagues (extérieure et intérieure) l'une fixe et l'autre tournante avec le moyeu ou l'arbre, elles sont séparées par un ensemble d'éléments de roulement qui sont des billes, des rouleaux ou des aiguilles. La séparation et le maintien à équidistance des corps roulants est assuré par la cage [15].




FIG. 1.9 : Composantes d'un roulement [15].

Plusieurs défauts et avaries proviennent de 4 familles de causes [7] :

- **Avaries liées à la charge et à la vitesse appliquée** : écaillage, grippage, coloration et détérioration des cages.
- **Avaries liées à la lubrification** : grippage, rupture des bagues par contraintes thermiques, coloration, détérioration des cages et écaillage,
- **Avaries liées au montage** : empreintes des corps roulants par déformation plastique, traces de coups, certaines détériorations des cages, corrosion par contact, certains écaillages provenant des défauts d'alignement,
- **Avaries liées à l'environnement** : usure, empreintes, corrosion, cratères, cannelures créées par le passage d'un courant électrique.

Les défauts et les avaries principales sont l'usure abrasive, le grippage, les empreintes, écaillage et dégradation des matériaux et la fatigue au contact des éléments roulants [7] :

- **Ecaillage** : les contacts entre les corps roulants et les bagues occasionnent de très forte charge des contraintes à la fois de compression en surface et cisaillement en sous couche conduisent à des inclusions en sous-couche puis des fissures qui vont se créer et se développer jusqu'à ce que des morceaux de matière se détachent.
- **Usure abrasive** : destruction d'un élément par enlèvement progressif de la matière en surface et formation de particules. Cette usure est généralement liée à des roulements mal protégés ou mal lubrifiés.
- **Grippage et usure adhésive** : produit lors de fort glissement qui entraîne une soudure localisée, des aspérités de surfaces et un transfert de matière entre les surfaces.
- **Empreintes** : L'effet de la charge produit une déformation plastique lorsqu'une particule est pincée dans le contact, provoquant des défauts de surfaces.
- **Déséquilibre thermique** : lié au dégagement de chaleur des surfaces en contact. Si cette énergie thermique n'est pas dissipée en continu, une élévation de température est possible et engendre une destruction du lubrifiant ainsi qu'une réduction de la dureté des matériaux en contact.

Les avaries précédentes peuvent être réduites et même éliminées par une surveillance des causes de dégradation et un entretien approprié. Par contre, il existe une avarie dites la fatigue qui apparait même dans les conditions idéales de fonctionnement. La charge dans le roulement est transmise d'une bague à l'autre par des éléments roulants. En rotation, il se crée donc un champ de contraintes cyclique qui est responsable de la fatigue du roulement.



FIG. 1.10 : Exemples des défauts de roulement [7].

Défaut d'engrenage

Les principaux défauts survenant sur un couple d'engrenages d'un réducteur simple sont les défauts répartis sur toute la denture et les défauts localisés sur une partie de la denture [7].

- **Usure** : l'enlèvement de matière causé par le glissement des deux surfaces de contact. Le développement de cette usure est en fonction de la charge mécanique à transmission et de la vitesse de glissement, ainsi que de la présence de composants abrasifs dans le lubrifiant. L'usure normale est de façon inverse à la dureté de la surface des dents et évolue difficilement. Elle est presque négligeable pour les dents très dures. L'usure anormale se déclenche lorsque le lubrifiant est contaminé par des particules abrasives ou lorsqu'il est de nature corrosive. Elle entraîne un dysfonctionnement, voire un arrêt.
- **Pitting ou piqûres** : Il s'agit de trous plus ou moins profonds qui touchent toutes les dents, notamment dans la zone du cercle primitif. Ces dommages se produisent essentiellement sur les engrenages fabriqués en acier relativement dur, et donc plus fragiles, sensibles aux effets combinés des sur-contraintes (fissuration). Les piqûres sont moins susceptibles de se produire lorsque la viscosité du lubrifiant est élevée, car dans ce cas, le film d'huile qui sépare les surfaces en contact est plus épais.




FIG. 1.11 : Défaut répartis d'engrenage [7].

- **Écaillage** : il s'agit également de trous mais ceux-ci sont moins nombreux, plus profonds et plus étendus que ceux du pitting. Les dégradations sont produites par fatigue en sous-couche, au point de cisaillement maximal. On rencontre ce type d'avarie dans les engrenages cémentés (couche superficielle durcie), ces engrenages sont actuellement très répandus car ils permettent de passer des couples importants dans des dimensions raisonnables. L'écaillage qui est le défaut principal, évolue très rapidement vers la rupture, sans passer par une phase d'usure.
- **Fissuration** : elle progresse à chaque mise en charge, et elle est située en pied de dent. Elle apparaît sur des aciers fins et durcis, qui sont sujets aux concentrations de contraintes.




FIG. 1.12 : Défaut localisé d'engrenage [7].

analyse vibratoire

L'analyse vibratoire est l'un des moyens utilisés pour surveiller l'état de santé des machines tournantes en fonctionnement. Elle s'inscrit dans une politique de maintenance prédictive de l'outil de production industrielle.

Les objectifs d'une telle démarche sont de :

- Réduire le nombre d'arrêts sur casse.
- Fiabiliser l'outil de production.
- Augmenter son taux de disponibilité.
- Mieux gérer le stock de pièces détachées, etc...

A partir des vibrations collectées régulièrement sur une machine tournante, l'analyse vibratoire permet de détecter d'éventuels dysfonctionnements et de suivre leur évolution afin de planifier une intervention mécanique [9].

Vibration

L'organisation Internationale de Normalisation (ISO) a édité une révision de la norme ISO 2041, définissant la notion de vibration « est une variation avec le temps de l'intensité d'une grandeur caractéristique du mouvement ou de la position d'un système mécanique lorsque l'intensité est alternativement plus grande et plus petite qu'une certaine valeur moyenne ou de référence ». En effet, un objet est dit vibrer lorsqu'il est animé d'un mouvement oscillatoire autour d'une position d'équilibre ou de référence [4][9].

Caractéristiques d'une vibration

Une vibration se caractérise principalement par, son amplitude, sa période et sa fréquence. Pour une vibration harmonique élémentaire (sinusoïdale) [4][15].

- **La période T** : c'est la durée correspondant à l'intervalle de temps entre deux positions successives identiques. L'unité s'exprime en seconde (s).
- **La fréquence F** : c'est le nombre de cycles par seconde, et qui est l'inverse de la période T . l'unité est le Hertz (de symbole Hz et de dimension S^{-1}).

$$F = \frac{1}{T} \quad (1.1)$$

- **L'amplitude A** : maximale ou valeur crête, valeur absolue maximale de la vibration par rapport à sa position d'équilibre.

La vibration instantanée $y(t)$ peut s'écrire :

$$y(t) = Y \sin(\Omega t + \varphi) \quad (1.2)$$

Où : Ω

Y : représente l'amplitude.

t : la variable temporelle (en seconde).

Ω : la pulsation ou la fréquence angulaire ($\Omega = 2\pi f$), exprimée en (rad/s).

φ : l'angle de phase, exprimée en (rad).

Une vibration peut être recueillie en mesurant trois grandeurs cinématiques, l'accélération, la vitesse et le déplacement. C'est trois grandeurs ont la particularité d'être liées entre elles par des relations simples [4][15].

- **Le déplacement x** : caractérise le déplacement de l'objet soumis à la vibration par rapport à la position d'équilibre. La forme d'onde devient :

$$x(t) = X \sin(\Omega t) \quad (1.3)$$

- **La vitesse** : caractérise l'accroissement de position par unité de temps. Elle se décrit par la dérivée du déplacement $v(t) = \frac{dx(t)}{dt}$, ce qui donne la fonction de vitesse suivant :

$$v(t) = X\Omega \cos(\Omega t) \quad (1.4)$$

- **L'accélération γ** : caractérise l'accroissement de vitesse par unité de temps. Elle se décrit par la dérivée du vitesse $\gamma(t) = \frac{dv(t)}{dt}$, ce qui donne la fonction d'accélération suivant :

$$\gamma(t) = -X\Omega^2 \sin(\Omega t) \quad (1.5)$$

Les méthodes de l'analyse vibratoire

Les méthodes utilisées pour la surveillance vibratoire peuvent être classées en deux catégories :

- Des méthodes temporelles comme la valeur efficace de l'accélération ou RMS, facteur de crête et Kurtosis.
- Des méthodes fréquentielles comme l'analyse spectrale, l'analyse cepstrale et l'analyse d'enveloppe.

Les méthodes temporelles

Cette méthode consiste à calculer des indicateurs statistiques à partir du signal vibratoire. Le suivi de l'évolution d'un indicateur peut donner une information plus au moins fiable sur l'état de fonctionnement du système. Certains indicateurs sont plus adaptés pour le dépistage d'un défaut que d'autres. Néanmoins, ils ne donnent qu'une information globale sur l'état de la machine. Par conséquent, ils peuvent déceler la présence d'un défaut mais en aucun cas sa nature. Considérés comme paramètres de détection du premier niveau, les indicateurs scalaires peuvent être intégrés dans le cadre d'une surveillance de l'état de fonctionnement des machines et peuvent représenter une défense de première ligne contre les défaillances. Le tableau 1.2 donne un aperçu sur les plus connus d'entre eux : leurs expressions mathématiques, ainsi que les avantages et les inconvénients de chacun [8].

Où :

N_e : Nombre d'échantillons du signal.

S : Valeur moyenne du signal.

V_c : Valeur crête du signal.

TAB. 1.2 : Les principaux indicateurs scalaires [8].

Indicatur	Expression mathématique	Avantages	Inconvénients
Valeur maximale	$v = \text{MAX}(v(t))$	Technique simple et facile.	Sensible au bruit.
Valeur efficace RMS (Root Mean Square)	$\sqrt{\frac{1}{N_e} \sum_{n=1}^{N_e} [s(t)]^2}$	Facile et rapide. Une variation excessive du niveau RMS signifie en général un changement de l'état de fonctionnement et donc une éventuelle défaillance.	Difficulté de détermination des seuils. Sa valeur isolée ne peut être significative d'un défaut. Sensible à l'énergie du signal et pas à sa forme.
Facteur de crête (Rapport entre la valeur crête du signal et sa valeur efficace RMS)	$F_C = \frac{V_C}{RMS}$	Sensible aux défauts de type choc. efficace sur des signaux filtrés.	Insensible dans le cas de petits défauts. Décroit lorsque la gravité du défaut augmente. Sensible au bruit.
kurtosis (Rapport entre le moment statistique d'ordre 4 et le moment statistique d'ordre 2 au carré)	$\frac{\frac{1}{N_e} \sum_{n=1}^{N_e} [s(t)-s]^4}{\left[\frac{1}{N_e} \sum_{n=1}^{N_e} [s(t)-s]^2 \right]^2}$	L'indicateur le plus sensible aux chocs (roulements, engrenages). Détection précoce d'un défaut de choc.	Décroit lorsque la gravité du défaut augmente. Sensible au bruit.

Méthodes fréquentielles

• Analyse spectrale

Mettre en évidence les différentes fréquences contenues dans un signal est le but de l'analyse spectrale. En effet le signal vibratoire est très complexe, dans la signature vibratoire de la machine immergent toutes les composantes de ses organes. La transformée de Fourier est donc un moyen efficace pour décomposer le signal en une multitude de composants élémentaires. Le résultat est un spectre qui ne requiert qu'un temps de calcul minime avec la version discrète de la transformée de Fourier nommée FFT (Fast Fourier Transform).

Les composantes fréquentielles contenues dans le spectre peuvent avoir plusieurs origines ; la fréquence de rotation de la machine et ses harmoniques, les fréquences de résonance, d'engrènement, ... etc. Le plus important c'est qu'elles peuvent correspondre à un éventuel défaut sur un ou plusieurs organes de la machine. Chaque défaut possède sa propre composante fréquentielle qui le distingue d'un autre et

permet sa détection facilement sur le spectre. Ainsi les signatures fréquentielles des différents défauts qui peuvent se manifester sur une machine tournante ont été définies. Interpréter un pic sur un spectre nécessite donc le maximum d'informations sur la cinématique ainsi que les différents organes constitutifs [7][33][8].

• Analyse de l'enveloppe

L'analyse d'enveloppe est l'une des techniques les plus importantes et les plus efficaces du traitement du signal. Cette technique sépare le signal basse fréquence du bruit de fond. L'analyse d'enveloppe est largement utilisée dans le diagnostic des roulements et des machines à basse vitesse et présente l'avantage de permettre une détection précoce des problèmes de roulement. Le filtrage du signal, l'extraction de l'enveloppe du signal filtré à l'aide de la transformée de Hilbert (HT) et la détermination du spectre de l'enveloppe à l'aide de la FFT sont les trois procédures qui constituent la méthodologie de travail de l'analyse d'enveloppe [25][5].

Transformée de Hilbert $\hat{x}(t)$ du signal $x(t)$ est donnée par :

$$\hat{x}(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (1.6)$$

Le signal analytique $x_+(t)$ du signal $x(t)$ est défini comme :

$$x_+(t) = x(t) + j\hat{x}(t) \quad (1.7)$$

L'enveloppe $v(t)$ du signal est définie comme étant l'amplitude du signal analytique :

$$v(t) = \sqrt{\hat{x}(t)^2 - x(t)^2} \quad (1.8)$$




FIG. 1.13 : Procédure d'analyse de l'enveloppe [5].

• Analyse cepstrale

L'analyse cepstrale est une méthode qui permet la détection de défauts à partir d'un spectre de fréquences. Le cepstre est utilisé pour représenter les phénomènes périodiques qui sont dissimulés par les spectres. La méthode de Fourier considère que les signaux sont stationnaires. Cependant, dans les machines tournantes, les signaux ne sont pas stationnaires, donc pour réaliser la détection et résoudre la limite de la méthode de Fourier, nous utilisons l'analyse cepstrale. Le cepstre $c(\tau)$ se définit comme l'inverse de la transformée de Fourier du logarithme décimal de la transformée de Fourier du spectre d'amplitude du signal $X(f)$, avec $X(f) = TF[X(f)]$ [17].

$$c(\tau) = TF^{-1} [\ln |X(f)|] \quad (1.9)$$

• FFT

La transformation de Fourier rapide (FFT) est une méthode de traitement et d'analyse des signaux couramment utilisée. Elle permet de transformer un signal dans le domaine temporel en un signal dans le domaine fréquentiel, de sorte que certaines caractéristiques qui ne sont pas claires dans le domaine temporel puissent être trouvées facilement [21] :

$$F(w) = \int f(t)e^{-iwt} dt \quad (1.10)$$

Où $F(w)$ est la fonction image de $f(t)$ et $f(t)$ est la fonction primitive de $F(w)$.

TAB. 1.3 : Les avantages et les inconvénients des méthodes du domaine fréquentiel [25].

Les méthodes du domaine fréquentiel	Les avantages	Les inconvénients
Analyse spectrale	Utile pour détecter un signal qui change de manière significative sur une courte période de temps.	Requiert les compétences d'experts en raison de sa complexité.
Analyse de l'enveloppe	Excellente application dans le système de roulement, fonctionne bien même en présence d'une petite fluctuation aléatoire.	Peut conduire à une erreur de diagnostic grossière, ne convient pas pour être appliqué dans le système d'engrenage.
Analyse cepstrale	Facile à mettre en œuvre, utile pour l'analyse des bandes latérales.	Ne peut être appliquée qu'aux harmoniques bien séparées, les fluctuations de la courbe du spectre sont éliminées par le filtrage.
FFT	Technique facile à mettre en œuvre, rapide.	Ne peut pas analyser efficacement les caractéristiques transitoires dans le temps.

Méthodes de diagnostic

Le diagnostic était à l'origine utilisé dans le domaine médical. Ce terme signifie le raisonnement conduisant à l'identification de la cause (origine) d'une défaillance, d'un problème ou d'une maladie sur la base de caractéristiques ou de symptômes constatés par des observations, des contrôles ou des tests (il s'agit donc d'acquérir des connaissances par des signes observables), comme dans son sens médical, Le diagnostic d'un système industriel consiste à détecter et localiser les composants ou les éléments défectueux d'un système dynamique. Il a pour objet de trouver la cause d'un défaut [13].

Selon l'Association Française de Normalisation (AFNOR) et la Commission Electrotechnique Internationale (CEI) "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".

Terminologie relative au diagnostic

Selon la standardisation de Le comité technique SAFEPROCESS de la fédération internationale de contrôle automatique de l'IFAC (International Federation of Automatic Control), Voici les termes et leurs significations utilisés dans le domaine du diagnostic [13] :

Défaut : C'est toute déviation ou tout écart d'au moins une caractéristique observée du système surveillé par rapport à sa caractéristique de référence requise, correspondante à l'état de fonctionnement normal et standard. Un défaut ne provoque pas généralement un arrêt complet du système mais peut entraîner une probable défaillance. Suite à un défaut, le système est incapable d'accomplir la fonction principale pour laquelle a été conçu.

Défaillance : Est l'incapacité d'un système physique à accomplir sa fonction principale ou une de ses fonctions. Une défaillance peut conduire à un défaut. Mais un défaut n'entraîne pas nécessairement une défaillance. Cela signifie, que le système peut toujours accomplir sa fonction principale tant que le défaut n'affecte pas cette tâche.

Panne : Une panne est l'incapacité d'un appareil à effectuer une fonction requise. Lors de l'apparition d'une défaillance, caractérisée par l'arrêt du dispositif pour remplir sa fonction, le dispositif sera déclaré en panne. Par conséquent, une défaillance est toujours le résultat d'un mauvais fonctionnement.

Dégradation : Est un processus de diminution progressive des performances d'une entité fonctionnelle d'un dispositif.

Perturbation : Est toute entrée non contrôlée, issue de l'environnement extérieur, influençant de façon négative sur un système physique.

Anomalie : Caractérise un comportement du système physique, non conforme à une référence.

Symptôme : Représente un signe distinctif permettant de détecter un dysfonctionnement du système surveillé.

Etapes du diagnostic

La procédure du diagnostic de défaillances et de dégradations susceptibles d'affecter les différentes entités d'un processus industriel s'articule autour des étapes suivantes [13] :

Acquisition des données : Cette fonction doit fournir une image du procédé. Les fonctions suivantes doivent être réalisées :

- Conditionnement et prétraitement du signal.
- Validation du signal de mesure.

Détection : La détection est le premier niveau de diagnostic dans lequel une décision binaire est prise, soit le système fonctionne normalement, soit un problème est survenu. Le résultat du processus de détection est une alarme indiquant que le comportement réel du système n'est plus conforme au modèle de comportement normal.

Localisation : C'est le deuxième niveau du diagnostic, déclenché par une procédure de détection, consiste à identifier plus précisément le composant défaillant, tel qu'un capteur, actionneur, processus ou unité de commande.

Identification : L'identification d'un défaut permet d'identifier la cause de ces symptômes en identifiant l'origine et la nature du défaut, et de déterminer sa taille et son comportement temporel

Prise de décision : Une fois le comportement inapproprié du système identifié, il est important d'agir de manière à maintenir les performances souhaitées ou à limiter les dégradations sur le système réel. Cette prise de décision permet de choisir entre plusieurs options comme arrêter le système pour faire de la maintenance ou accepter un fonctionnement dégradé. Il peut encore s'agir, quand cela est possible, de reconfigurer ou de réorganiser le système.



FIG. 1.14 : Les étapes du diagnostic.

Classification des méthodes de diagnostic

Les méthodes de diagnostic se distinguent selon différents critères : la dynamique de procédé (discret, continu ou hybride), sa complexité, l'implémentation de diagnostic en ligne et/ou hors ligne, la nature d'information (qualitative et/ou quantitative) .

Les méthodes de diagnostic peuvent être classées en deux grandes familles [23][26][12] :

- Les méthodes sans modèle mathématique qui ne nécessitent pas de connaissances accrues du système physique, mais utilisent des connaissances superficielles.

- Les méthodes à base de modèles qui nécessitent une connaissance approfondie du système physique.




FIG. 1.15 : Classification générale des méthodes de diagnostic[23].

Méthodes à base de modèle

Le principe des méthodes à base de modèles est de déterminer les écarts entre le système réel et son modèle. Les méthodes basées sur les modèles sont plus efficaces que celles basées sur le traitement des données ou les approches relationnelles. Ces modèles peuvent être classés en deux catégories quantitatives ou qualitatives.

Les méthodes quantitatives à base de modèle reposent sur les relations mathématiques qui existent entre les variables. Les méthodes de diagnostic à base de modèles quantitatifs se décomposent en trois grands groupes :

- Les approches par espace de parité.
- Les approches d'estimation paramétrique.
- Les approches d'estimation d'états.

Les méthodes qualitatives proposées par la communauté d'intelligence artificielle (IA) sont basées sur un raisonnement qualitatif (ou semi-qualitatif), basé sur l'établissement de relations causes à effets. En effet, le diagnostic est généralement un système

causal puisqu'il permet de définir des hypothèses sur les composants défaillants qui sont à l'origine du dysfonctionnement constaté. Le concept de raisonnement qualitatif traduit le lien entre un composant et les formules qui décrivent son comportement. Les méthodes les plus utilisées sont les suivantes :

- Les graphes causaux.
- Les réseaux de Petri...

Méthodes sans modèle

En effet, dans certaines applications industrielles, la conception d'un modèle mathématique est difficile, voire impossible à obtenir, en raison des nombreuses reconfigurations qui interviennent dans le processus de production ou de la complexité des phénomènes en jeu. Dans ce cas, on utilise des méthodes qui ne nécessitent pas une connaissance approfondie du processus. Deux classes d'approches peuvent être utilisées :

Les méthodes quantitatives, ou méthodes dites de connaissance, sont utilisées lorsque la majorité des mesures ne sont pas disponibles et que la construction de modèles est difficile. Elles sont notamment utilisées pour identifier les causes de défaillances dans un processus industriel. Il peut s'agir d'analyses fonctionnelles et structurelles basées sur l'expérience et les connaissances de l'opérateur. Parmi ces approches on peut citer :

- L'AMDEC (Analyse des Modes de Défaillances et de leurs Effets et de leur Criticité).
- Arbre de défaillances.
- Les systèmes experts...

Les méthodes qualitatives ou méthodes basées sur le traitement de données,

elles consistent en l'exploitation d'une base de connaissance symbolique et nécessitent l'existence d'un large éventail de données historiques correspondant aux divers modes de fonctionnement de l'installation. Parmi ces méthodes on peut citer :

- L'Analyse en composantes principales (ACP).
- Analyse qualitative des tendances (AQT).
- Réseaux de neurones.
- Reconnaissance de forme.
- Analyse spectrale...

Etat de l'art sur l'application des méthodes d'Intelligence Artificielle utilisées dans le diagnostic automatique des Machines tournantes.

Intelligence Artificielle

L'intelligence artificielle désigne des systèmes qui agissent et pensent comme les humains. Elle est également capable d'imiter le comportement humain. Elle se concentre sur l'amélioration de la capacité des ordinateurs à s'engager dans des processus cognitifs de type humain tels que l'apprentissage, le raisonnement et l'autocorrection. La puissance de l'ordinateur (mémoire, rapidité) lui permet de les accomplir avec une performance hors de la portée de l'intelligence humaine. L'IA, en tant que discipline nouvelle et multidisciplinaire, vise à utiliser un outil informatique pour simuler certains aspects des processus de pensée et du comportement intelligent de l'homme.

En raison de leur robustesse et de leur adaptabilité, les algorithmes d'IA pour le diagnostic des défauts des machines tournantes se sont répandus. Ils ne nécessitent pas non plus beaucoup de connaissances physiques préalables, qui peuvent être difficiles à acquérir en pratique [22][1][32].




FIG. 1.16 : Relation entre les différentes disciplines de l'IA [22].

L'Apprentissage Automatique (Machine Learning)

Machine Learning ou apprentissage automatique une branche de l'intelligence artificielle qui permet à laisser des algorithmes découvrir des patterns, à savoir des motifs récurrents, dans les ensembles de données. Ces données peuvent être des chiffres, des images, des statistiques...

Tout ce qui peut être stocké numériquement peut servir de données pour l'apprentissage automatique. Les algorithmes d'apprentissage automatique apprennent de manière autonome l'exécution des tâches et les prédictions à partir des données, améliorant ainsi les performances au fil du temps. Une fois entraîné, l'algorithme sera capable de trouver de nouveaux modèles de données [11].

Avec l'évolution du matériel ces dernières années, l'utilisation d'approches du ML en maintenance industrielle est devenue efficace en termes de temps et d'argent, notamment pour la détection des types de pannes et pour la maintenance prédictive [14].

Il existe différents types d'apprentissage automatique, Nous pouvons classer les en plusieurs catégories très distinctes : apprentissage supervisé, apprentissage non supervisé et apprentissage par renforcement.




FIG. 1.17 : Les grandes classes d'apprentissage automatique [14].

L'apprentissage supervisé

L'apprentissage supervisé, le plus courant, qui utilise un ensemble de données connu pour effectuer des prédictions. Le processus se passe en deux phases, Durant une première phase appelée phase d'apprentissage, il s'agit de déterminer un modèle des données étiquetées. Au cours d'une seconde phase, appelée phase de test, on présente au réseau de nouveaux vecteurs qui n'ont pas servi à l'apprentissage et l'on observe ses réponses. L'efficacité du réseau sont alors évaluées par le pourcentage d'erreurs [27][38].

L'apprentissage supervisé, on distingue entre deux types :

Les modèles de classification : sont utilisés pour affecter des éléments à une classe discrète en fonction d'un ensemble spécifique de fonctionnalités. Ceci revient à attribuer une classe pour chaque valeur d'entrée. Chaque modèle a ses propres forces et faiblesses dans un scénario donné. Il est courant que les modèles de classification prédisent des valeurs continues comme les probabilités d'appartenance à chaque classe de sortie. Une probabilité prédite peut être convertie en une valeur de classe en sélectionnant l'étiquette de la classe qui présente la probabilité la plus élevée [14] [18].

Parmi les méthodes d'apprentissage supervisé (type de classification) on distingue les méthodes suivantes :

- Machine à vecteurs de support « SVM ».
- Naive Bayes.
- K-Nearest Neighbor « K-NN ».
- Discriminant analysis...

Les méthodes de régression : s'appliquent lorsque le résultat que l'on cherche à estimer est une valeur continue, Comme le cas de la prédiction du prix d'une voiture. En ML, la régression est un outil important de l'apprentissage supervisé pour la modélisation et l'analyse des données. Elle est notamment utilisée en statistique et en économie. Certains algorithmes peuvent être utilisés à la fois pour la classification et la régression avec de petites modifications, telles que les arbres de décision et les réseaux de neurones artificiels [3][18].

Parmi les méthodes d'apprentissage supervisé (type de régression) on distingue les méthodes suivantes :

- Neural network.
- SVR.
- L'arbre de décision.
- Linear regression...

L'apprentissage non supervisé

Pour l'apprentissage non supervisé la base de données d'apprentissage ne contient pas de variable cible (comme on l'a vu en apprentissage supervisé). Il y a seulement un ensemble de données collectées en entrée. L'algorithme doit donc découvrir la structure par lui-même à travers les données. Il ingère de grandes quantités de données et utilise des algorithmes pour extraire les caractéristiques nécessaires à l'étiquetage, au tri et à la classification des données en temps réel, sans avoir besoin d'intervention humaine [24][11]. Les tâches non supervisées les plus courantes sont le clustering, utilisé pour construire des classes automatiquement en fonction des exemples disponibles. Les techniques de clustering consistent à décomposer un ensemble d'individus en différents sous-ensembles les plus homogènes possibles, les règles d'association permettent d'analyser les relations entre les variables ou de détecter des associations et la réduction de dimension[3][38][24]. Parmi les méthodes d'apprentissage non supervisé on distingue les méthodes suivantes :

- Hierarchical.
- K-Means.

- Fuzzy C-Means.
- Hidden Markov...

L'apprentissage par renforcement

L'apprentissage par renforcement permet à un algorithme d'apprendre de ses erreurs pour atteindre un objectif. [24]. Il consiste à apprendre, à partir d'expériences successives, ce qu'il convient de faire de façon à trouver la meilleure solution. En fonction de ses compétences, il sera récompensé ou pénalisé pour l'encourager à poursuivre dans une direction ou à changer d'approche [18].

L'apprentissage profond (Deep Learning)

L'apprentissage profond (Deep Learning, DL) est un type d'apprentissage automatique et révèle le développement profond de l'IA, et il est très en vogue ces derniers temps. Il est basé sur l'idée des réseaux de neurones artificiels et il est taillé pour gérer de larges quantités de données en ajoutant des couches au réseau. DL est synonyme d'apprentissage de caractéristiques ou d'apprentissage de représentations, et se caractérise par des représentations de données variées et de haut niveau. Plus précisément, les caractéristiques de bas niveau des modules simples et non linéaires ont été composées pour générer des représentations de haut niveau plus abstraites en termes de catégories ou de caractéristiques. Par rapport à l'apprentissage automatique traditionnel, le principal avantage de l'apprentissage automatique est que des couches de caractéristiques sont automatiquement apprises à partir de données brutes à l'aide d'une technique d'apprentissage générale, plutôt que de s'appuyer sur des compétences techniques et une expérience du domaine [32][18].

Domaines d'application de L'apprentissage profond

L'apprentissage en profond investit progressivement notre quotidien [18] :

- L'étiquetage automatique d'image.
- La reconnaissance vocale.
- La synthèse vocale avancée.
- La conception de nouvelles molécules pharmaceutiques...

Intérêts de L'apprentissage profond

Les algorithmes de l'apprentissage automatique classiques fonctionnent très bien dans certains cas. Cependant, ils semblent être inefficaces pour les problèmes majeurs du l'apprentissage profond telles que la reconnaissance vocale et la reconnaissance d'objets. La principale différence entre les algorithmes de l'apprentissage automatique traditionnel et

l'apprentissage profond est l'étape de l'extraction de caractéristiques. Pour l'apprentissage automatique traditionnel les caractéristiques à identifier dépendent de l'expertise humaine. Cette pratique est très difficile et requiert un spécialiste en la matière, parfois les caractéristiques distinctives ne sont même pas identifiables par l'homme. L'apprentissage profond permet de pallier à ce problème en utilisant plusieurs couches de réseau de neurones. Un autre avantage du L'apprentissage profond c'est qu'il s'adapte bien, plus la quantité de données fournie est grande plus les performances sont meilleures [18].

Les méthodes de l'apprentissage profond

Il existe plusieurs méthodes de l'apprentissage profond utilisées dans le diagnostic des défauts, parmi ces méthodes, on peut citer : Convolutional neural network (CNN), Recurrent neural network (RNN), Generative adversarial network (GAN) et l'Auto-encoder (AE) ...ect.

A. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) ou Reseaux de Neurones Convolutif, l'un des modèles les plus classiques de l'apprentissage profond. Le CNN a obtenu un succès remarquable dans de nombreuses recherches et dans l'industrie, et il a d'excellentes performances dans le domaine de la reconnaissance d'images, du traitement du langage naturel et de la détection de cibles. Comme le montre la figure 1.18, le CNN est composé des couches de convolution, des couches de pooling, couche de fully-connected, couche d'entrée et couche de sortie. Il possède trois caractéristiques structurelles : la connexion locale, weight sharing et time or space sampling. Ces caractéristiques rendent le réseau neuronal convolutif avantageux pour l'extraction features [32][21][34].




FIG. 1.18 : Architecture standard de CNN [34].

La couche de convolution : La fonction principale de la couche convolutive est d'obtenir les cartes de fonctionnalité par une série d'opérations de filtrage convolutif sur l'entrée. La couche de convolution est généralement composée d'un ensemble de noyaux apprenables et de biais, dont les résultats sont introduits dans une fonction d'activation. L'opération de convolution peut être exprimée comme suit [21][36] :

$$x'_j = f\left(\sum_{i \in M_j} x'_{i-1} \cdot w'_{ij} + b'_j\right) \quad (1.11)$$

Où x_j^l est le j^{eme} élément dans la l^{eme} couche, M_j est la j^{eme} région de convolution dans la $(l-1)^{eme}$ couche, x_i^{l-1} est l'élément, w_{ij}^l est la matrice de poids, b_j^l est le biais et f est généralement une fonction d'activation non linéaire ReLU, et elle peut être écrite comme suit [21] :

$$f(x) = MAX(0, lg(1 + e^x)) \quad (1.12)$$

La couche pooling : est souvent connectée après la couche de convolution. En général, la tâche principale de la couche pooling est de réduire les dimensions de la sortie de la couche précédente, donc le principe de la couche pooling est de compresser le volume de données, réduisant ainsi les ressources et le temps de calcul nécessaires. En dehors de cela, un autre avantage de l'opération de pooling dans la couche pooling est qu'elle peut permettre aux features convolutionnelles gagnées d'être invariantes par décalage. La couche pooling a des méthodes communes, Max Pooling, Mean Pooling et Stochastic Pooling [21][36].

La couche fully-connected : Après que l'image d'entrée est propagée alternativement par plusieurs couches de convolution et couches pooling, les features extraites sont classées et utilisées comme entrée de couche fully-connected. L'entrée est obtenue par sommation pondérée des vecteurs de features unidimensionnelles développés par tous les graphiques de features. La fonction principale de la couche fully-connected est d'extraire davantage les fonctionnalités et de connecter l'étape de sortie avec le classificateur softmax, et son expression mathématique peut s'écrire comme [21][36] :

$$y^i = (w^i x^{i-1} + b^i) \quad (1.13)$$

Où i est le numéro de séquence de la couche du réseau, y^i est la sortie de la couche entièrement connectée, x^{i-1} est un vecteur caractéristique unidimensionnel, w^i est le coefficient de poids et b^i est le biais, la fonction d'activation f de la couche finale dans la couche fully-connected est la fonction Softmax pour les tâches de classification. De plus, une opération d'abandon, connue sous le nom de technique de régularisation, peut être ajoutée après chaque couche convolution ou couche fully-connected pour améliorer la capacité de généralisation du modèle CNN conçu et éviter le débordement pendant l'apprentissage du modèle [34].

B. Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) est un type de réseau de neurones artificiels (ANN) qui utilise des connexions d'unités pour former un graphe dirigé avec une entrée de séquence. Cela permet d'afficher un comportement temporel dynamique. Comme toutes les entrées du RNN sont connectées, la valeur de l'état caché précédent est donnée comme entrée à l'état actuel. Le RNN ajoute des neurones auto-connectés dans la couche cachée pour former une mémoire interne et utilise la back-propagation pour réaliser la mémoire des informations historiques et le retour d'information sur l'état du réseau. La structure spéciale du réseau RNN permet de conserver les informations d'état de la couche cachée et présente un avantage considérable dans le domaine de la modélisation des systèmes dynamiques complexes. Par conséquent, le RNN est capable de gérer des données séquentielles de longueur variable, ce qui le rend très utile pour l'apprentissage profond. Il est généralement utilisé dans des domaines tels que la traduction automatique et le traitement du langage [28][10].




FIG. 1.19 : La structure du RNN [10].

C. Generative adversarial network (GAN)

Generative adversarial network (GAN) est un algorithme d'apprentissage de features basé sur des scénarios de jeu. L'apprentissage des features est effectué par l'apprentissage adversatif, qui peut être utilisé pour résoudre le problème du déséquilibre des données. Le GAN est composé de deux parties, le générateur et le discriminateur, qui sont en concurrence l'un avec l'autre, pour obtenir une capacité accrue d'imitation des échantillons de données originaux, puis de discriminer itérativement [10][2].




FIG. 1.20 : La structure du GAN [10].

D. Auto-Encodeur (AE)

L'Auto-Encodeur (AE) est un algorithme d'apprentissage non supervisé qui utilise la back-propagation (BP) pour extraire une feature des données d'entrée. Il s'agit d'un réseau de neurones avec une couche d'entrée, une couche cachée et une couche de sortie. La couche d'entrée et la couche cachée forment un réseau de codage, et la couche cachée et la couche de sortie forment un réseau de décodage [28][10]. Le concept fondamental de l'entité d'application est de transformer les données d'entrée de haute-dimension en un vecteur de codage de faible-dimension grâce à une cartographie non linéaire à travers le réseau de codage, puis de reconstruire le vecteur de code à travers le réseau de décodage, puis d'apprendre de nouvelles représentations de données [10].




FIG. 1.21 : La structure de l'Auto-Encodeur [37].

TAB. 1.4 : Les avantages et les inconvénients des méthodes d'apprentissage profond [30].

Les méthodes	Les avantages	Les inconvénients
CNN	Robuste et évolutive. Parmi les meilleurs méthodes de classification. Spécialisé dans les traitement d'image.	Entraînement plus lent en raison du nombre élevé de poids. Analyse des données par morceaux, sans modélisation des dépendances à long terme.
RNN	Présente la corrélation temporelle pour une série chronologique données.	La formation est difficile à conserver des dépendances à long terme Besoin de plus de ressources.
GAN	Cet algorithme a rapidement gagné en popularité grâce à ses performances en matière de génération d'images.	Le générateur et le discriminateur doivent converger ensemble.
AE	Faible complexité. la surveillance en ligne de l'état de fonctionnement.	L'illustration éparses et la procréation d'erreurs couche par couche ne sont pas assurées.

Conclusion

Dans ce chapitre on a donné des notations sur la maintenance industrielle et leurs types, ainsi qu'un aperçu sur les techniques les plus utilisés dans la surveillance des machines tournantes, une présentation des éléments mécaniques les plus importants dans les machines tournantes qui sont les roulements et les engrenages et leurs défauts qu'ils subissent souvent. Puis les méthodes utilisées dans la surveillance vibratoire (les méthodes temporelles et les méthodes fréquentielles) et les méthodes de diagnostic des défauts. On termine ce chapitre par un état de l'art sur l'application des méthodes d'intelligence artificielle dans le diagnostic automatique des machines tournantes.

Chapitre 2

Banc d'essai

Introduction

Ce chapitre présente un aperçu du banc d'essai et de ses composants, ainsi que les caractéristiques de chaque composant. Des expériences ont été menées sur ce banc d'essai dans le but d'étudier les défauts simples et combinés des engrenages en effectuant des tests sur ce banc d'essai. Ce chapitre est divisé en deux parties, la première partie décrit le montage expérimental et la deuxième partie décrit le plan expérimental.

Montage Expérimental

Banc Expérimental

Afin d'être plus proche d'un défaut d'engrenage réel, un dispositif expérimental a été conçu au laboratoire de vibrations acoustiques de l'INSA de Lyon en France. Le banc d'essai contient deux transmissions à engrenages normalement lubrifiés. La première transmission est constituée d'un pignon de 42 dents, montés à l'arbre d'entrée et une roue de 50 dents montée sur l'arbre intermédiaire. La seconde transmission est constituée d'une roue de 65 dents montée elle aussi sur l'arbre intermédiaire et une roue de 45 dents, montée sur l'arbre de sortie. Le banc d'essai comporte également un frein pour simuler une charge variable voir figure 2.1. Les expériences sont réalisées pour deux fréquences de rotations 15 et 20 Hz [35].




FIG. 2.1 : Le banc d'essai [35].

On présente sur la figure 2.2 deux photos d'engrenage, la première à l'état neuf (sans défaut) et la deuxième avec défaut.



FIG. 2.2 : a) photos d'engrenage sans défaut.
b) photos d'engrenage avec défaut [35].

On présente dans ce qui suit les différentes composantes du banc d'essai.

Moteur asynchrone

Moteur asynchrone de vitesse nominal 2810 tr/min (46Hz), d'une puissance de 2.2KW avec un nombre de pôle $n = 3$.

Variateur de vitesse

Les variateurs de vitesse sont constitués principalement d'un convertisseur statique et d'un circuit de commande qui réalise la régulation et l'asservissement de la machine à travers le convertisseur statique de sorte que l'utilisateur puisse commander directement une vitesse. Puisque la vitesse du rotor est liée à la fréquence du courant au stator, il est donc possible d'utiliser cette dernière pour la commande en vitesse.

Une cuve

Afin d'éviter l'usure des engrenages, et de diminuer le bruit engendré par ces derniers, on a décidé de rajouter un lubrifiant (huile). Ainsi, la cuve utilisée est construite en acier et en plexiglas, afin de permettre le suivi du niveau d'huile.

Deux transmissions par engrenages

Le banc d'essais comporte une transmission par engrenages à dentures droites à deux étages, le premier est monté sur l'arbre d'entrée qui est lié directement au rotor, le deuxième est ainsi entraîné en rotation (voir schéma cinématique). Les roues utilisées sont de module $m = 2mm$, et de nombre de dents respectivement, de : $Z1 = 42$, $Z2 = 50$, $Z3 = 65$ et $Z4 = 45$. Pour chaque étage, on calcule le rapport de transmission, qui se définit comme étant le rapport entre le nombre de dents de l'entrée (menant) sur le nombre de dents de la sortie (mené) : voir le schéma de la figure 2.3.

$$R_1 = \frac{Z1}{Z2} = \frac{42}{50} = 0.84 < 1 \rightarrow \text{Redecteur} \quad (2.1)$$

$$R_2 = \frac{Z3}{Z24} = \frac{65}{45} = 1.44 > 1 \rightarrow \text{Multiplicateur} \quad (2.2)$$




FIG. 2.3 : Schéma cinématique du banc [35].

Fréquences caractéristiques expérimentales des défauts pour les engrenages

Nous représentons dans le Tab 2.3, les fréquences caractéristiques des défauts d'engrenages tels que la fréquence de rotation pour chaque vitesse de l'arbre d'entrée et de sortie et les fréquences d'engrènement.

TAB. 2.1 : Fréquences caractéristiques des défauts d'engrenages [35].

Type d'engrenage	Droite					
caractéristiques d'engrenage	Rapport de transmission			U1 = 42/50 = 0.84		
				U2 = 65/45 = 1.444		
	Fréquences de rotation [Hz]					
	15 Hz			20 Hz		
	Arbre 1	Arbre 2	Arbre 3	Arbre 1	Arbre 2	Arbre 3
14.38	12.07	17.38	19.15	16.08	23.15	
Fe [Hz]	603.5		782.5	804.3		1045.5

Roulements à billes

Les roulements utilisés sont en acier, étanche à la poussière, aux projections d'eau et à l'humidité de type KOYO- RS 6002, dont les caractéristiques sont :

TAB. 2.2 : caractéristiques géométriques utilisés [35].

Type du roulement	caractéristiques géométriques				
roulement rigide à bille	n (bille)	D_i (mm)	D_e (mm)	D_m (mm)	α (degré)
BC modèle RS 6002	10	15	32	24	0

n nombre des billes, D_i Diamètre de la cage interieur (mm), D_e Diamètre de la cage extérieur (mm), α L'angle de contact (degré).

Les accéléromètres

Les capteurs de vibrations utilisés sont de type accéléromètre piézoélectrique (IEPE : Integral Electronic Piezo Electric), leur sensibilité est de 100mV/g .



FIG. 2.4 : Accéléromètre [35].

Frein

Pour que la transmission travail sous chargement, nous avons conçu un frein permettant d'appliquer un couple sur l'arbre de sortie, afin d'accélérer l'apparition du défaut sur la denture des engrenages.

Un conditionneur

Les données issues des capteurs vont être recueillies par un conditionneur. Généralement ce type d'instrument propose soit une simple conversion charge/tension ou tension/tension. De plus, des gains d'amplification et d'atténuation sont souvent disponibles. Des intégrations simples et doubles permettent également d'obtenir en sortie les signaux de vitesse ou de déplacement. Enfin, des fonctions de pré-filtrage du signal permettent souvent d'optimiser le signal avant enregistrement et/ou analyse.



FIG. 2.5 : Le conditionneur [35].

Logiciel de traitement de données

DynamX est un logiciel permettant la programmation des essais, l'acquisition des signaux, leur traitement, leur archivage et la rédaction du rapport de présentation. L'organisation de la base a été conçue pour faciliter au maximum le classement et l'accès aux données. DynamX garantit ainsi l'enrichissement continu et la pérennité des données et analyses.




FIG. 2.6 : Fenêtre du logiciel de traitement DynamX 7 [35].

Plan expérimental

Dans le but d'étudier les défauts simples et combinés d'engrangs, on a réalisé des expériences sur le même banc d'essai utilisé pour le cas du défaut réel en changeant les anciens pignons par d'autres sans défaut. Dans cette deuxième partie, nous avons voulu étudier la capacité des auditeurs d'identifier les différents types de défaut, allant d'un petit défaut simple jusqu'à la combinaison de plusieurs défauts. Pour cela, nous avons simulé plusieurs défauts avec différents degrés de dégradation :

- S1: Engrenage Sain.
- S2: Petit Défaut sur le pignon1.
- S3: Moyen Défaut sur le pignon 1.
- S4: Grand Défaut sur le pignon 1.
- S5 : Grand Défaut sur le pignon 1 & Petit Défaut sur le pignon 2.
- S6 : Grand Défaut sur le pignon 1 & Moyen Défaut sur le pignon 2.
- S7 : Grand Défaut sur le pignon 1 & Grand Défaut sur le pignon 2.

Chapitre 2. Banc d'essai

Ces tableaux présentent les résultats des expériences du banc d'essai, en va utiliser ces derniers comme des données dans le prochaine chapitre.

TAB. 2.3 : Les sons d'engrenage sans défaut, avec défaut simple et avec défaut multiple.

Sans défaut				
Son 1	Son 2	Son 3	Son 4	Son 5

Défaut simple										
Son 6	Son 7	Son 8	Son 9	Son 10	Son 11	Son 12	Son 13	Son 14	Son 15	Son 16

Défaut multiple							
Son 17	Son 18	Son 19	Son 20	Son 21	Son 22	Son 23	Son 24

On présente sur la figure 2.7 trois photos correspondant au petit, moyen et grand défaut respectivement.




FIG. 2.7 : Photos des défauts simulés [35].

Conclusion

Dans ce chapitre nous avons fait une présentation d'un banc d'essai pour déterminer le comportement des engrenages et des roulements en fonctionnement et collecté les données des expériences expérimentales après plusieurs conditions de fonctionnement ont été expérimentées pour utiliser dans le chapitre suivant pour la réalisation d'un modèle de diagnostic des défauts par la méthode de CNN.

Chapitre 3

Détection et classification des défauts par la méthode CNN

Introduction

D'après les recherches bibliographiques que nous avons effectuées, nous sommes convaincu qu'il est plus efficace de concevoir un modèle d'apprentissage (Deep Learning) afin de pouvoir détecter et identifier les défauts des machines tournantes, et de les classer en fonction de leurs types. Ce chapitre présente donc les étapes suivies pour mettre en place un modèle de détection et de classification des défauts de d'engrenage par la méthode CNN.

Cela a été réalisé en utilisant l'environnement de travail Phyton. Ce dernier est un langage de programmation open source, avec une grande communauté de développeurs orienter à DATA SCIENCE. La bibliothèque TensorFlow contient les outils nécessaires pour construire un modèle basé sur l'apprentissage profond, comme le réseau de neurones convolutif (CNN) et leurs types (Conv 1D, Conv 2D et Conv 3D) qui sont très puissants dans le traitement des données spatiales à plusieurs dimensions. Ils permettent d'extraire les caractéristiques spatiales du DATA, pour ensuite les en utiliser dans la détection et la classification des défauts.

2. Les bibliothèques de python utilisées pour le développement du modèle de détection et classification

```
import librosa
import os
from sklearn.model_selection import train_test_split
import numpy as np
from tqdm import tqdm
import tensorflow as tf
from keras.utils import to_categorical
```

FIG. 3.1 : Quelles bibliothèques utiliser dans notre modèle.

Librosa

Librosa est un paquetage Python pour l'analyse musicale et audio. Librosa est essentiellement utilisé lorsque l'on travaille avec des données audio comme dans la génération de musique et la reconnaissance automatique de la parole. Il fournit les blocs de construction nécessaires à la création de systèmes de recherche d'information musicale. Librosa permet de visualiser les signaux audio et d'en extraire les caractéristiques à l'aide de différentes techniques de traitement du signal¹.

¹ <https://librosa.org/doc/latest/index.html>

sklearn

Scikit-learn est une bibliothèque gratuite d'apprentissage automatique pour Python. Qui a été créée pour faciliter et rendre plus robuste l'apprentissage automatique en Python².

Tensorflow

TensorFlow est une bibliothèque open source conviviale pour Python destinée au calcul numérique, qui permet d'accélérer et de faciliter l'apprentissage automatique et le développement de réseaux neuronaux³.

MFCC

Mel Frequency Cepstral Co-efficients (MFCC) qui est les coefficients qui composent collectivement un MFC. MFC est une représentation du spectre de puissance à court terme d'un son, basée sur une transformation en cosinus linéaire d'un spectre de puissance logarithmique sur une échelle de fréquence mel non linéaire[16].

Spectre sonore : Un spectre sonore est une représentation d'un son - généralement un court échantillon d'un son - en termes de quantité de vibration à chaque fréquence individuelle. Il est généralement présenté sous la forme d'un graphique de la puissance en fonction de la fréquence.




FIG. 3.2 : Exemple d'un spectre sonore.[16]

² <https://scikit-learn.org/stable/>

³ <https://www.tensorflow.org/>

Les étapes de la conversion audio en MFCC :

- Obtenez votre audio dans un format de domaine temporel.




FIG. 3.3 : Exemple d'un audio en domaine temporel.[16]

- Convertissez votre audio en périodogramme à l'aide de la transformation rapide de Fourier.

Un périodogramme : est similaire à la transformée de Fourier, mais il est optimisé pour les données échantillonnées de manière irrégulière et pour les différentes formes de signaux périodiques.




FIG. 3.4 : Exemple d'un périodogramme.[16]

- Après cela, nous convertissons notre périodogramme en spectrogramme.

Un spectrogramme : est un diagramme représentant le spectre d'un phénomène périodique, associant à chaque fréquence une intensité ou une puissance.




FIG. 3.5 : Exemple d'un spectrogramme.[16]

Analyse de Data

Nous avons utilisé dans ce travail 24 extraits sonores (des fichiers WAV) mesurés sur un banc d'essai qui contient deux transmissions à engrenages normalement lubrifiés. La durée de chaque extrait sonore est de 10 secondes. La première étape consiste à convertir ces fichiers wav en spectrogramme en utilisant la fonction MFCC pour extraire les vingt fréquences les plus apparues.




FIG. 3.6 : Format final d'un extrait sonore.

Pour la codification des classes de l'état d'engrenage, l'outil Keras-categorical est utilisé. Comme expliqué dans le chapitre précédent.

Sans défaut $\rightarrow$ 001.

Défaut simple $\rightarrow$ 010.

Défaut combiné $\rightarrow$ 100.

Reshape

L'origine de l'audio est stereo, reshape permis nous de réduire les dimensions.

Conception de modèle

Pour notre étude le choix d'un CNN classifieur a été fait pour la classification et la détection des défauts avec une architecture montré dans la figure 3.7 :




FIG. 3.7 : Architecture de notre modèle.

Les étapes

- La première couche est une couche de convolution avec 32 filtres du taille 3x3, ces sorties sont actives par la fonction de redressement linéaire, chaque filtre est implémenté afin d'extraire une caractéristique spatiale obtenant 32 matrices de taille (20,10) pour ensuite pouvoir les implémenter à la prochaine couche du modèle.




FIG. 3.8 : Exemple de la sortie d'une couche de convolution [31].

- Après dans la deuxième couche du MaxPooling en utilisant une fenêtre de dimensions (2,2) pré-spécifié pour réduire la dimension des matrices d'entrées et extraire les caractéristiques le plus significative arrivant à des matrices de dimensions (10,5,32) afin de les passer à la couche suivante.




FIG. 3.9 : Exemple de la sortie d'une couche de MaxPooling [31].

- Ensuit dans la troisième couche (la deuxième couche de Convolution), on utilise 32 filtres du taille 2x2, et la fonction d'activation relu obtenant 32 matrices de taille (10,5) puis on les faire passer par une fonction Flatten afin de transformer notre data en un vecteur de taille (10*5*32=1600).




FIG. 3.10 : Exemple de la fonction Flatten [31].

- Finalement on utilise deux couches fully-connected, dans la première couche nous implémentons 128 neurones et dans la deuxième couche nous implémentons 3 neurones ce qui correspond aux nombres de classe (sans défaut, défaut simple, défaut combiné) avec une fonction d'activation SoftMax pour les deux couches fully-connected.

SoftMax : La fonction Softmax permet elle de transformer un vecteur réel en vecteur de probabilité. On l'utilise souvent dans la couche finale d'un modèle de classification, notamment pour les problèmes multiclasse.

Cross entropy loss

Cross entropy loss est une fonction d'optimisation utilisée lors de la formation d'un modèle de classification qui classe les données en prédisant la probabilité que les données appartiennent à une classe ou à une autre[20].

Adam

Adam est un algorithme d'optimisation qui peut être utilisé à la place de la procédure classique de descente de gradient stochastique pour mettre à jour les poids de réseau itératifs en fonction des données d'apprentissage[20].

```
model.compile(loss="categorical_crossentropy",|
              optimizer="adam",
              metrics=['accuracy'])
```

FIG. 3.11 : Les paramètres de la fonction FIT pour notre modèle.

Binary crossentropy

Binary crossentropy est une fonction de loss (perte) utilisée dans les tâches de classification binaire. Il s'agit de tâches qui répondent à une question avec seulement deux choix (oui ou non, 0 ou 1). Il est possible de répondre à plusieurs questions indépendantes de ce type en même temps, comme dans la classification multi-labels ou dans la segmentation binaire d'images.

Formellement, cette perte est égale à la moyenne de la perte de l'entropie croisée catégorielle sur de nombreuses tâches à deux catégories.

La fonction binary crossentropy loss calcule la perte d'un exemple en calculant la moyenne suivante :

$$Loss = \frac{1}{outputsize} \sum_{i=1}^{outputsize} y_i * \log(\hat{y}_i) + (1 - y_i) * \log(1 - \hat{y}_i) \quad (3.1)$$

où $\hat{y}_i$ est la i^{eme} valeur scalaire dans la sortie du modèle, y_i est la valeur cible correspondante, et output size est le nombre de valeurs scalaires dans la sortie du modèle.

Batch (Lot)

La taille du lot est un hyperparamètre de la descente de gradient qui contrôle le nombre d'échantillons d'entraînement à traiter avant la mise à jour des paramètres internes du modèle. Pour le modèle développé la taille du lot est 5.

Epochs (époques)

Le nombre d'époques est un hyperparamètre de la descente de gradient qui contrôle le nombre de passages complets dans l'ensemble de données d'entraînement. Le nombre d'époques choisi est 500.

```
model.fit(X_train, y_train_hot, epochs=500, validation_data=(X_test, y_test_hot), batch_size=5)
```

FIG. 3.12 : Nombre d'époques et de Lot utilisé dans notre modèle.

Les données sont divisées, en utilisant l'une des fonctions SKLearn, en deux parties :

- 80 % pour l'entraînement de notre modèle (training).
- 20 % pour la validation de notre modèle (testing).

Résultat et discussion

La Figure 3.13 montre l'évolution de la précision du modèle en fonction du nombre des époques. On peut constater que la précision du modèle est de 65 % pour l'ensemble d'entraînement et 80 % pour l'ensemble de validation.




FIG. 3.13 : Accuracy de notre modèle en fonction de nombre d'époques.

La figure 3.14 montre l'évolution de l'erreur du modèle en fonction du nombre des époques. On peut constater que les courbes des erreurs pour l'ensemble d'entraînement et celui de validation prennent une allure décroissante jusqu'à atteindre une valeur minimale de 0,6.




FIG. 3.14 : Loss de notre modèle en fonction de nombre d'époques.

Colclusion

Nous pourrions affirmer que notre objectif a été atteint puisque le modèle CNN conçu est capable de détecter et de classifier les différents types de défauts (simples ou multiples) avec une exactitude très satisfaisante (80 %). Au fur et à mesure que les données vont croître, la précision du modèle augmentera de même.

Conclusion générale

Dans le milieu industriel actuel, la surveillance et le diagnostic des machines tournantes ont connu un grand développement ces dernières années. Ces derniers considérés comme essentiels pour leur impact sur le flux de production. Ils permettent de répondre à des impératifs tels que la réduction des coûts de maintenance, la maîtrise totale de la disponibilité de l'outil de production et de la sécurité des équipements.

Un banc d'essai a été mis en place pour déterminer le comportement des engrenages et des roulements en fonctionnement. Plusieurs conditions de fonctionnement ont été expérimentées. Les données résultant de cette expérience expérimentale nous a permis de développer une méthode de diagnostic de défauts des machines tournantes par des approches neuronales, plus performant que les techniques traditionnelles de détection des défauts basées sur le traitement du signal. Un modèle d'intelligence artificielle (apprentissage profond) par réseaux de neurones convolutifs (CNN) a été développé afin d'avoir une meilleure classification, notamment dans le cas de défauts combinés, et ce modèle conçu est efficace et précis pour la détection et la classification des différents types de défauts (simples ou combinés) avec une exactitude très satisfaisante (80 %).

Enfin, nous espérons que l'idée de diagnostic automatique par des modèles intelligents sera diffusée, car elle contribue au profit du temps, ainsi que d'être une méthode très efficace pour détecter et identifier les défauts. Nous espérons également qu'un modèle intelligent intégré aux machines tournantes sera réalisé à l'avenir, afin qu'il devienne facile à utiliser et qu'il soit très avantageux pour la maintenance et l'industrie dans son ensemble, parce qu'il réduira l'incertitude et le taux d'erreur par rapport aux modèles intelligents normaux.

Bibliographie

- [1] Yasir Hassan ALI, Roslan ABD RAHMAN et Raja Ishak Raja HAMZAH. “Acoustic emission signal analysis and artificial intelligence techniques in machine condition monitoring and fault diagnosis : a review”. In : *Jurnal Teknologi* 69.2 (2014).
- [2] Adnan ALTHUBAITI, Faris ELASHA et Joao Amaral TEIXEIRA. “Fault diagnosis and health management of bearings in rotating equipment based on vibration analysis—a review”. In : *Journal of Vibroengineering* 24.1 (2022), p. 46-74.
- [3] Medoued AMMAR. “Surveillance et diagnostic des défauts des machines électriques : applications aux moteurs asynchrones”. Thèse de doct. thèse de doctorat, Université du 20 Août 1955-Skikda, 2012.
- [4] Adel BOUDIAF. “Contribution au Diagnostic des Défauts dans les Machines Tour-nantes par Analyse Multirésolution”. Thèse de doct. 2016.
- [5] Adel BOUDIAF et al. “A comparative study of various methods of bearing faults diagnosis using the case Western Reserve University data”. In : *Journal of Failure Analysis and Prevention* 16.2 (2016), p. 271-284.
- [6] Belaid BOUZOUANE. “Diagnostic des défauts de machines tournantes”. Thèse de doct. 2013.
- [7] Claire BRENEUR. “Eléments de maintenance préventive de machines tournantes dans le cas de défauts combinés d’engrenages et de roulements”. Thèse de doct. Lyon, INSA, 2002.
- [8] Lilia CHAABI. “Conception d’un système expert pour le diagnostic des roulements dans les machines tournantes fonctionnant en régime variable”. Thèse de doct. 2021.
- [9] Rachid CHAIB. “Contribution à l’optimisation de la maintenance conditionnelle par l’analyse vibratoire”. In : (2006).
- [10] Wei CUI et al. “Application of Rotating Machinery Fault Diagnosis Based on Deep Learning”. In : *Shock and Vibration* 2021 (2021).
- [11] DATASCIENTEST. *Machine Learning : Définition, fonctionnement, utilisations*.
- [12] Haithem DERBEL. “Diagnostic à base de modèles des systèmes temporisés et d’une sous-classe de systèmes dynamiques hybrides”. Thèse de doct. Université Joseph-Fourier-Grenoble I, 2009.
- [13] Aicha Amani DJALAB et al. “Robust method for diagnosis and detection of faults in photovoltaic systems using artificial neural networks”. In : *Periodica Polytechnica Electrical Engineering and Computer Science* 64.3 (2020), p. 291-302.

- [14] Yalcoué FATOUMATA, Amor ADNANE et Ziane ATAOUA. “Machine Learning Pour La Maintenance Prédictive.” In : (2021).
- [15] Semchedine FEDALA. “Diagnostic des défauts des machines tournantes par reconnaissance des formes”. Thèse de doct. 2021.
- [16] Md Afzal HOSSAN, Sheeraz MEMON et Mark A GREGORY. “A novel approach for MFCC feature extraction”. In : *2010 4th International Conference on Signal Processing and Communication Systems*. IEEE. 2010, p. 1-5.
- [17] Hassane HOTAÏT. “Contribution au processus de surveillance intelligente des machines tournantes : cas des roulements à billes.” Thèse de doct. Reims, 2020.
- [18] Andriamiandrasoa IANJAFITIA. “Systeme de detection d’objet base sur le deep learning dans un magasin intelligent.” In : (2019).
- [19] Bilal IKHLEF, Abdelmoumin CHENTOUF et Hocine Encadreur FENINECHE. “Etude de diagnostic intelligent des défauts mécaniques dans les machines tournantes.” Thèse de doct. Université de Jijel, 2021.
- [20] John D KELLEHER. *Deep learning*. MIT press, 2019.
- [21] Pengfei LIANG et al. “Intelligent fault diagnosis of rolling element bearing based on convolutional neural network and frequency spectrograms”. In : *2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*. IEEE. 2019, p. 1-5.
- [22] Ruonan LIU et al. “Artificial intelligence for fault diagnosis of rotating machinery : A review”. In : *Mechanical Systems and Signal Processing* 108 (2018), p. 33-47.
- [23] Salowa METHNANI. “Diagnostic, reconstruction et identification des défauts capteurs et actionneurs : application aux station d’épurations des eaux usées”. Thèse de doct. Université de Toulon ; École nationale d’ingénieurs de Sfax (Tunisie), 2012.
- [24] Rachid MIFDAL. “Application des techniques d’apprentissage automatique pour la prédiction de la tendance des titres financiers”. Thèse de doct. École de technologie supérieure, 2019.
- [25] Mohamad Hazwan MOHD GHAZALI et Wan RAHIMAN. “Vibration analysis for machine monitoring and diagnosis : a systematic review”. In : *Shock and Vibration* 2021 (2021).
- [26] Hocine OUBABAS. “Contribution au diagnostic et à la commande tolérante aux fautes par l’approche ensembliste”. Thèse de doct. 2019.
- [27] Saidoun OUERDIA. “Commande floue et neuro-floue du niveau de liquide d’un réservoir”. Thèse de doct. Université Mouloud Mammeri, 2008.
- [28] Asiye K OZCANLI, Fatma YAPRAKDAL et Mustafa BAYSAL. “Deep learning methods and applications for electrical power systems : A comprehensive review”. In : *International Journal of Energy Research* 44.9 (2020), p. 7136-7157.
- [29] Belhour SAMIRA. “Contribution à l’optimisation de la maintenance predictive par l’utilisation du logiciel OMNITREND (Système on line) cas : Cimenterie HAMMA BOUZIANE”. In : *Mémoire de magister université de Mentouri de Constantine, Algérie* (2008).

Bibliographie

- [30] Oscar SERRADILLA et al. “Deep learning models for predictive maintenance : a survey, comparison, challenges and prospects”. In : *Applied Intelligence* (2022), p. 1-31.
- [31] SLIDEPLAYER. *convolutional neural networkS*.
- [32] Shengnan TANG, Shouqi YUAN et Yong ZHU. “Deep learning-based intelligent fault diagnosis methods toward rotating machinery”. In : *Ieee Access* 8 (2019), p. 9335-9346.
- [33] Baptiste TRAJIN. “Analyse et traitement de grandeurs électriques pour la détection et le diagnostic de défauts mécaniques dans les entraînements asynchrones. Application à la surveillance des roulements à billes”. Thèse de doct. Institut National Polytechnique de Toulouse-INPT, 2009.
- [34] Hui WANG et al. “A new intelligent bearing fault diagnosis method using SDP representation and SE-CNN”. In : *IEEE Transactions on Instrumentation and Measurement* 69.5 (2019), p. 2377-2389.
- [35] Ramdane YOUNES et al. “Experimental study of real gear transmission defects using sound perception”. In : *The International Journal of Advanced Manufacturing Technology* 76.5 (2015), p. 927-940.
- [36] Bo ZHAO et al. “Intelligent fault diagnosis of rolling bearings based on normalized CNN considering data imbalance and variable working conditions”. In : *Knowledge-Based Systems* 199 (2020), p. 105971.
- [37] Funa ZHOU et al. “A multimodal feature fusion-based deep learning method for online fault diagnosis of rotating machinery”. In : *Sensors* 18.10 (2018), p. 3521.
- [38] Wend-Benedo Arnaud Bienvenue ZOUNGRANA. “Application des algorithmes d’apprentissage automatique pour la détection de défauts de roulements sur les machines tournantes dans le cadre de l’Industrie 4.0”. Thèse de doct. Université du Québec à Chicoutimi, 2020.

Résumé

Résumé

Différentes méthodes sont mises en œuvre pour la détection d'un défaut sur une machine tournant, en utilisant des mesures vibratoires, elles diffèrent entre elles par leur précision, leur simplicité de mise en œuvre et leur sensibilité aux erreurs de mesure. Comme la détection d'une combinaison de plusieurs défauts est toujours difficile à mettre en œuvre par les méthodes classiques du traitement du signal. Nous proposons dans le présent travail l'application de la méthode des Réseaux de Neurones Convolutif (CNN), où les spectrogrammes des mesures acoustiques ont été utilisés pour l'apprentissage du modèle. Les résultats obtenus montrent que l'approche proposée permet la détection et la classification des défauts simples et combinés, avec efficacité et précision.

Mots clés : Machines tournantes, Défauts combinés, Diagnostic, Intelligence Artificielle, Apprentissage automatique, Apprentissage profond, CNN.

Abstract

Different methods are implemented for the detection of a defect on a rotating machine, using vibration measurements, they differ between them by their accuracy, their simplicity of implementation and their sensitivity to measurement errors. As the detection of a combination of several defects is always difficult to implement by conventional methods of signal processing. We propose in the present work the application of the Convolutional Neural Networks (CNN) method, where the spectrograms of the acoustics measurements were used for the training of the model. The results obtained show that the proposed approach allows the detection and classification of simple and combined defects, with efficiency and accuracy.

Keywords : Rotating machines , Multi-faults, Diagnosis, Artificial intelligence, Machine learning, Deep learning, CNN.

ملخص

يتم تنفيذ طرق مختلفة للكشف عن عيب في آلة دوارة، باستخدام قياسات اهتزازية، وهي تختلف في دقتها وبساطتها

تنفيذها وحساسيتها لأخطاء القياس. نظرًا لصعوبة اكتشاف مزيج من العديد من العيوب دائمًا عن طريق الطرق التقليدية لمعالجة الإشارات. في هذا العمل، نقترح تطبيق طريقة الشبكات العصبية التلافيفية، حيث تم استخدام مطياف القياس الصوتي لتعلم النماذج. تظهر النتائج التي تم الحصول عليها أن النهج المقترح يسمح باكتشاف وتصنيف العيوب البسيطة والمجمعة، بكفاءة ودقة.

كلمات مفتاحية :

الآلات الدوارة، الأعطال المتعددة، التشخيص، الذكاء الاصطناعي، التعلم الآلي، التعلم العميق، الشبكات العصبية التلافيفية