

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE :
OPTION :
N° :



FILIERE :
DEPARTEMENT :

Mémoire présenté pour l'obtention du diplôme de Master Académique
dans le cadre du décret ministériel 1275

Par: Laidi Mira & Alili Asma
Saidi Rokaia & Hraiz Safia

Diagnostic de la défaillance d'un moteur
par méthode du deep learning

Soutenu le / /2024 devant le jury composé de :

.....	Université de M'Sila	Président
Dr . Mostafa tabbakh	Université de M'Sila	Rapporteur
.....	Université de M'Sila	Examineur

Année universitaire : 2023/2024

Remerciement

Avant tout ; je dois remercier Allah le tout puissant qui m'a donnée la force, le courage de mener à terme ce travail.

Je tiens à remercier tout particulièrement mon encadreur de thèse, Dr. Mostafa tabbakh, qui a proposé le sujet et supervisé le travail et qui a toujours été ouverte aux suggestions en raison de sa modestie. Il est très utile qu'elle puisse trouver que c'est l'expression de ma sincère gratitude pour ces suggestions, sa gentillesse et sa patience avec moi pendant que je terminais ce travail, et son soutien. Sans elle, cet essai n'aurait jamais été achevé.

Je remercie aussi les membres de jury pour avoir fait l'honneur de juger et d'évaluer ce travail.

Enfin, je tiens à exprimer ma gratitude à tous mes estimés professeurs de département de en général et aux professeurs de Génie Civil des matériaux en particulier.

Merci à tous qui, de près ou de loin

Dédicaces

من قال انا لها نالها و انا لها وان ابنت رغمها عنها اتيت بها

الحمد لله حبا وشكرا و امتنانا على البدء والختام

يقول الله ﷻ ﴿واخر دعواهم ان الحمد لله رب العالمين﴾

الى من كلل العرق جبينه وعلمني ان النجاح لا يأتي الا بالصبر والإصرار , الى النور الذي اثار دربي والنور الذي لا ينطفئ , بقلبي ابدا من بدل الغالي واستمديت منه قوتي واعتزالي بداتي (والدي العزيز)

لي من جعل الله الجنة تحت اقدامها و سهل لي الشدائد بدعائها الى الانسانية العظيمة التي طالما تمنيت ان تفقد عيناها برويتي في يوم كهذا (والدتي الحبيبة)

لي من كان الأول دوما في مساندتي وتشجيعي الى رفيق وصديق الأيام جميعا بجلوها ومرها الى من زرع في نفسي حب العلم والعمل فصار عنوان لنجاحي وتعلمت منه الصبر والكفاح زوجي وامني وسكني مهما اهديتك كلمات شكر لا يستوفيك حقها

الى خلعي الثابتة وامان ايامي , الى من شددت عضدي بهم فكانو لي ينابيع ارتوي منها القوي والهمة اخوتي ابدا بتوامي بشري واختي المغتربة عنا اية واخي الياس وبسمة ولجين

اهدي تخرجي الى اوفى أصدقائي الى من ساندوني ولا زالو يساندونني اميمة حبيبتي وبثينة الغالية

وأخيرا رفعت القبة مودعا سنيذا مضت ...

لعيدي ميرة

Dedicaces

من قال انا لها "نالها".

لم تكن الرحلة قصيرة و لا ينبغي لها ان تكون ،

لم يكن الحلم قريبا و لا الطريق كان محوها بالتسميلات ،

لكنني فعلتها و نلتها .

الحمد لله حبا و شكرا و امتنانا ، الذي بفضلها انا اليوم أنظر

الى حلما طال انتظاره و قد أصبح واقعا أفتخر به .

إلى من علمتني أن الدنيا كفاح و سلاحها العلم و المعرفة " أمي " ،

أهديك هذا الانجاز الذي لولا تضحياتك لما كان له وجود ، ممتنة لأن

الله قد إصطفاك لي من البشر أما يا خير سند و عوض .

إلى من دعمني بلا حدود و أعطاني بلا مقابل ، إلى من سعى لأجل راحتي

و نجاحي ، إلى أعظم و أعز رجل في الكون " أبي الغالي " دعمت لي طول العمر .

إلى ملائكة الطاهر ، و قوتي بعد الله ، داعمتي الأولى و الأبدية " خالتي وريدة " .

إلى ذات القلب الحنون ، إلى أمي الثانية " خالتي سعيدة " .

إلى من آمنت بقدراتي و علمتني أن لا أمتدح بالفشل " أختي أمال " .

إلى من تذكرني بقوتي و ساعدتني في النهوض كلما وقعت " أختي دنيا " .

إلى من قيل فيهم :

{ سَنَشُدُّ عَضُدَكَ بِأَخِيكَ }

إلى من مدوا أيديهم بلا ملل و قنص ضعفي " إخوتي خالد و إبراهيم " .

أدامكم الله ضلعا ثابتا لي

" الطالبة عليلي أسماء "

Dedicaces

بسم الله الرحمن الرحيم

«... بِرِزْقِ اللَّهِ الَّذِينَ آمَنُوا وَآلَهُمْ الصَّالِحِينَ...» الحمد لله الذي بنعمته تتم الصالحات

الحمد لله حبا وشكرنا وامتنانا الذي بفضلہ ، ہا أنا اليوم أنظر إلى حلما طال انتظاره وقد أصبح واقعا أفتخر به إلى الاميرة "أمي" وقد ورثت في جوفها كيف أكون إنسانا قبل أن أصرخ صرختي الأولى في هذا العالم إلى ملاكي الطاهر ، وقوتي بعد الله ، داعمتي الأولى والأبدية العالم أهديك هذا الإنجاز الذي لولا تضحياتك لما

كان له الوجود

إلى الحبيب النائم تحت التراب طاب حاله وجعلك الله بنعيم حتى يبعثون "أبي"

إلى من دعمني بلا حدود وقتي ضعفي وأعطاني بلا مقابل "أخي وسندي سعد"

إلى من مد يده دون كلل ولا ملل "حسين ، نورالدين"

ألى من آمنتم بقدراتي وأمان أيامي وتقف خلفي كظلي "أخواتي"

أدامكم الله خلعا ثابتا لي

أهديكم هذا العمل المتواضع وثمره جدي ، والله ولي التوفيق .

سعيدتي رقية

من قال انا لها.. نالها،وأنا لها وإن ابت رغما عنها اتيت بها

الحمد لله حباً وشكراً وامتنان على البدء والختام

يقول الله ﷻ:

{وأخر دعواهم ان الحمد لله رب العالمين }

الى النور الذي اثار دربي والنور الذي لاينطفئ بقلبي ابداً، من بذل الغالي واستمديت منه قوتي واحتزازي بذاتي
الى من جعل الله الجنة تحفة اقدامها وسملت لي الشدائد بدعائها الى الانسانه العظيمه التي طالما تمنيت ان تُقر عيناها
برؤيتي في يوم كهذا إلى من كانت لي أم وأب في آن واحد

(والدتي الحبيبه)

الى خلعي الثابت وامان أيامي، الى من شددت عضدي بهم فكانو لي ينبوع ارتوي منها القوى والمهمه، الى قرة عيني
وصفوتما

(اخواني واخواتي)

. ولكل من كان عوناً وسنداً في هذا الطريق وللأصدقاء الأوفياء ورفقاء السنين واصحاب الشدائد والازمات

اهديكم هذا الانجاز وثمره نجاحي الذي لطالما تمنيته، ها انا اليوم اتممت اول ثمراته بفضل من الله عز وجل، فالحمد لله
على ما وهبني، وان يعينني ويجعلني مباركاً اينما كنت

"حرايز صفية"

Dedicaces

Résumé

La machine asynchrone est largement utilisée dans l'industrie en raison de sa résistance, de son coût et de sa maintenance réduits. Cependant, elle peut être sujette à de nombreuses pannes électriques ou mécaniques pendant son fonctionnement, nécessitant une détection précoce. Cela a conduit à l'utilisation de plusieurs méthodes de diagnostic permettant d'identifier et de classifier les pannes, y compris l'utilisation de techniques d'intelligence artificielle et de réseaux de neurones artificiels. L'objectif de ce travail est de diagnostiquer les pannes de la machine asynchrone à cage d'écureuil (rupture des barres du rotor) en utilisant des techniques de réseaux de neurones artificiels. Nous avons développé un modèle de réseau neuronal pour détecter et classifier les pannes, puis avons réalisé des tests pour vérifier la validité de ce modèle de réseau neuronal.

Mots- clés : machine asynchrone, diagnostic des pannes, pannes de rupture des barres du rotor, réseaux de neurones artificiels.

Abstract :

The asynchronous machine is widely used in the industry due to its resistance, low cost, and maintenance. However, it can experience various electrical or mechanical faults during operation, requiring early detection. This has led to the use of multiple diagnostic methods to identify and classify machine faults, including the use of artificial intelligence and neural networks. The aim of this study is to diagnose faults in the squirrel-cage asynchronous machine (specifically rotor bar breakage) using artificial neural network techniques. We developed a neural network model for fault detection and classification, followed by testing to validate the accuracy of this neural network model. Keywords: asynchronous machine; fault diagnosis; rotor bar breakage faults; artificial neural networks

المخلص:

الآلة غير المتزامنة هي أكثر استخداما في الصناعة بسبب مقاومتها وانخفاض تكلفتها وصيانتها، ولكن يمكن أن تتعرض للعديد من الأعطال الكهربائية أو الميكانيكية أثناء تشغيلها والتي تتطلب الكشف المبكر. أدى ذلك الى استخدام طرق تشخيص عديدة تسمح لنا بتحديد وتصنيف الأعطال التي تحدث على الآلة من بينها استخدام تقنيات الذكاء والشبكات العصبية الاصطناعية.

الهدف من هذا العمل تشخيص اعطال الآلة الغير متزامنة ذات قفص السنجاب (عطل كسر قضبان الدوار) باستخدام تقنيات الشبكات العصبية الاصطناعية. قمنا بتطوير نموذج شبكة عصبية اكتشاف وتصنيف الأعطال ثم أجرينا اختبارات للتحقق من صحة نموذج هذه الشبكة العصبية

كلمات مفتاحية: الآلة الغير متزامنة؛ تشخيص الأعطال؛ اعطال كسر قضبان الدوار؛ الشبكات العصبية الاصطناعية.

Sommaire

INTRODUCTION GENERALE :	1
Chapitre1 : État de l'art	
I.INTRODUCTION	5
I.1.Constitution de la machine asynchrone à cage :	6
I.2.1. Le Stator :	6
I.2.3. Organes mécaniques	8
I. 3.Les défaillances dans la machine asynchrone	9
I.4.1. Défaillances d'ordre mécanique	11
I.4.1.1. Défaillances des roulements	11
I.4.1.2. Défaillances du flasque	11
I.4.1.3. Défaillances de l'arbre	12
I.4.2. Défaillances d'ordre électrique	12
CONCLUSION	15
Chapitre 2 :	
Diagnostic des défauts dans les machines asynchrones par intelligence artificiel	
II.1.INTRODUCTION	17
II2. Définition du diagnostic :	18
II.3.Les différentes méthodes de diagnostic :	18
II.3.1. Diagnostic par l'analyse spectrale et le suivi des grandeurs mesurables :	18
II.3.2. Analyse des courants statoriques :	18
II.3.3. Analyse vibratoire des machines tournantes :	18
II.3.4. Analyse des flux :	19
II.3.5. Analyse du couple électromagnétique :	19
II.4.Techniques de traitement du signal utilisées dans le diagnostic :	19
II.4.1.Traitement de signal :	20
II.4.1.1. Analyse temporelle	20
II.4.1.2. Analyse fréquentielle :	21
II.5. Diagnostique par réseaux de neurones	23
II.5.1. les réseaux de neurones :	23
II.5.2 Les Réseaux de Neurones Artificiels (RNA) :	24
II.5.3. Principe de Fonctionnement :	24
II.5.4. Domaines d'Application	24
II.6 Réseaux neurones convolutionnels (CNN) :	25
II.6.1 Architecture des Réseaux de Neurones Convolutifs (CNN) :	2527

II.6.1.3 Couche de correction RELU :	27
II.6.1.4. La couche entièrement connectée (Fully connected):	27
III.6.2. Avantages de CNN	29
II.7 Entraînement des CNN	29
II.7.1 Méthodes d'entraînement des CNN, notamment l'utilisation de jeux de données d'entraînement et de validation.	29
II.7.2 Techniques d'optimisation des hyperparamètres, telles que l'ajustement du taux d'apprentissage et l'utilisation de techniques de régularisation.	30
CONCLUSION	33
Chapitre 3 :	33
III.1. INTRODUCTION	34
III.2. DEFAUTS DE ROULEMENTS A ELEMENTS ROULANTS	35
III.3. PRINCIPALES CARACTERISTIQUES DES SIGNAUX VIBRATOIRES DE ROULEMENTS A BILLES	35
III.4. METHODOLOGIE DE TRAVAIL	36
III.5. DONNEES UTILISEES	37
III.6. ETUDE DU SIGNAL EMANANT D'UN ROULEMENT A BILLE	39
III.6.1. Etude dans le domaine temporel	40
III.7. Transformée en ondelette continue (CWT)	45
III.8. L'apprentissage par transfert :	48
III.8.1. Le Modèle pré-entraîné	48
III.8.2. Résultat de l'apprentissage pour la classification des défauts de roulements	49
III.8.3. Analyse de la Matrice de Confusion et des Résultats de Classification	51
III.9. CONCLUSION	54
CONCLUSION GENERALE	55
CONCLUSION GENERALE	56

List de figure

Figure I.1 : Constitution de la machine asynchrone à cage [4]	03
Figure I.2: Le Stator[6].	04
Figure I.3: Rotor à cage d'écureuil[9].	05
Figure I.4: Rotor bobinée[11].	05
Figure I.5 : Proportion des défauts[13]	07
Figure I.6 : Répartition des pannes sur les machines de fortes puissances [16].	08
FigureII.7 : Technique de traitement de signal [26]	18
FigureII.8 : les réseaux de neurones[35]	22
FigureII.9 . Architecture simple de CNN	25
FigureII.10.Couche de pooling	26
FigureII.11. la courbe de la fonction RELU	26
FigureII.12.La couche entièrement connectée (Fully connected)	27
FigureII.13. Évolution de la courbe d'erreur durant la phase d'apprentissage [48].	30
Figure III.14. Vue d'ensemble d'un roulement à bille	36
Figure III.15.a Représentation temporel d'un signal acquit à partir d'un roulement à bille à l'état normal	41
Figure III.16.b Représentation fréquentiel d'un signal acquit à partir d'un roulement à bille à l'état normal	42
Figure III.17.c Représentation de l'énergie spectral d'un signal acquit à partir d'un roulement à bille à l'état normal	42
Figure III.18.a Représentation temporel d'un signal acquit à partir d'un roulement à bille avec un défaut interne	43
Figure III.19.b Représentation fréquentiel d'un signal acquit à partir d'un roulement à bille avec un défaut interne	43
Figure III.20.c Représentation de l'énergie spectral d'un signal acquit à partir d'un roulement à bille avec un défaut interne	44
Figure III.21.a Représentation temporel d'un signal acquit à partir d'un roulement à bille avec un défaut externe	45
Figure III.22.b Représentation fréquentiel d'un signal acquit à partir d'un roulement à bille avec un défaut externe	45
Figure III.23.c Représentation de l'énergie spectral d'un signal acquit à partir d'un roulement à bille avec un défaut externe	46
Figure III.24.a Représentation temporel et spectrogramme d'un signal acquit à partir d'un roulement à bille avec défaut interne	47
Figure III.25.b Représentation temporel et spectrogramme d'un signal acquit à partir d'un roulement à bille avec défaut externe	48
Figure III.26.c Représentation temporel et spectrogramme d'un signal acquit à partir d'un roulement à bille sans défaut	48

Abréviations et acronymes

SVM : les machines à vecteurs de support

MCS : Le spectre du courant statorique

MCSA : MotorCurrent Signature Analysis

TFR : La transformée de Fourier rapide

TO : Transformée en ondelettes

RNA : réseau de neurones artificiels

SNN : réseaux neuronaux simulés

CNN : Convolutional Neural Network

ReLu : Rectified Linear Unit

CPU : Central Processing Unit

STFT : transformation de Fourier à court terme

BPFO : fréquence de passage des billes sur la bague extérieure

BPFI : fréquence de passage des billes sur la bague intérieure

FTF : fréquence fondamentale de la cage

BSF : fréquence de rotation des billes

CWT : la transformation en ondelettes continues

$\bar{x}$: La valeur moyenne

Var : La variance

σ : L'écart type

Skew : *Le Skewness*

SKurt : Le Kurtosis



INTRODUCTION GENERALE



INTRODUCTION GENERALE

La machine électrique occupe une place très importante dans le milieu industriel, et devient un élément principal dans les différents domaines d'applications. Comme toute autre machine, la machine asynchrone n'est pas à l'abri d'un dysfonctionnement. Elle peut être affectée par des défauts électriques ou mécaniques au niveau du stator, ou du rotor, ou les deux en même temps. Les pannes peuvent être d'origine diverses, les roulements à bille étant la partie mécanique la plus sujette aux défauts dus au vieillissement et à l'usure, les défauts roulement sont les plus fréquents. Les premières approches de détection de défauts consistaient à l'analyse des signaux vibratoires issus de la machine.

L'analyse vibratoire est une technique privilégiée pour détecter ces anomalies. Bien que l'analyse de Fourier permette d'étudier les signaux stationnaires, les défauts de roulements engendrent souvent des vibrations transitoires non stationnaires nécessitant des méthodes plus avancées comme la transformée en ondelettes. L'analyse vibratoire occupe une place prépondérante dans le dépistage et le diagnostic de défauts des machines tournantes, et ce, de façon croissante en raison des performances toujours plus accrues en matière de traitement du signal. Les techniques classiques comme l'analyse de Fourier permettent aussi de mettre en relation les amplitudes et les fréquences des phénomènes vibratoires stationnaires, cependant, certains défauts mécaniques sont représentés par des signaux transitoires de caractère non stationnaires, caractérisés par des vibrations complexes, ces défauts ne peuvent être détectés dans les premières stades de leur apparition par l'utilisation de la transformée de Fourier et la méthode de filtrage classique, mais ils peuvent être détectés par l'application des méthodes de traitement de signal avancées, comme la Transformée en ondelette[1]. Les techniques de diagnostic des défauts de roulement peuvent être classées en trois approches: l'analyse temporelle basée sur des paramètres statistiques, l'analyse fréquentielle et l'analyse temps-fréquence tels que la transformée en ondelettes (TO).

Dans une procédure de diagnostic, après extraction des caractéristiques, un système de classification intelligent s'impose. Plusieurs systèmes de classification intelligents ont été développés et utilisés pour la surveillance et le diagnostic, tels que les classificateurs flous, les algorithmes génétiques, les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (RNA).

Les réseaux de neurones à convolution sont très utilisés dans le domaine de reconnaissance des images mais nous voulons dans le cadre de ce mémoire les appliquer à un contexte un peu différent qui

est la classification automatique des textes et comme application classification des textes par type de contenu textuel (Contenu artistique, contenu sportif, contenu politique ou contenu scientifique).

Ce projet vise à développer une approche innovante combinant l'analyse temps-fréquence par transformée en ondelettes et les techniques de deep learning pour le diagnostic des défauts de roulements dans les machines asynchrones. L'objectif est d'exploiter la transformée en ondelettes pour obtenir des représentations 2D riches en informations des signaux vibratoires acquis. Ces représentations seront ensuite traitées par un réseau de neurones convolutifs (CNN) utilisant le modèle pré-entraîné SqueezeNet.

Cette méthode tire parti des avantages des représentations temps-fréquence détaillées et de la puissance des réseaux de neurones profonds pour une classification précise des différents types de défauts de roulements. Les résultats préliminaires obtenus à ce stade du projet sont prometteurs.

L'objectif principal est de développer une méthodologie fiable permettant la détection précoce et l'identification des défauts de roulements (côté rotor) dans les machines asynchrones. Cette étude porte sur des modèles simulés et des données expérimentales pour une validation complète. Les résultats contribueront à l'amélioration de la maintenance prédictive et à l'augmentation de la fiabilité des systèmes industriels utilisant ces machines.

L'essentiel du travail est divisé en trois parties principales :

Le premier chapitre est consacré à l'étude du moteur asynchrone et des différents types de défauts pouvant l'affecter. Une attention particulière est portée sur les défauts de roulements, leur nature et leurs causes. Cette partie pose les bases théoriques nécessaires à la compréhension du problème abordé.

Le deuxième chapitre donne un aperçu des procédures de classification classiques, incluant l'extraction des caractéristiques pertinentes à partir des signaux vibratoires. Ensuite, les réseaux de neurones artificiels (RNA) sont présentés en tant que technique de classification puissante. Enfin, une introduction aux réseaux de neurones convolutifs (CNN) est fournie, en mettant l'accent sur leur capacité à traiter des données de type image, ce qui sera exploité dans le cadre de ce projet.

Dans ce chapitre central, la méthodologie proposée pour le diagnostic des défauts de roulements est mise en évidence. Il décrit l'utilisation de la transformée en ondelettes pour obtenir des représentations temps-fréquence 2D des signaux vibratoires acquis. Ces représentations sont ensuite traitées par un

INTRODUCTION GENERALE :------

réseau de neurones convolutifs utilisant le modèle pré-entraîné SqueezeNet. Les résultats obtenus pour la classification des défauts de roulements (bague intérieure,



Chapitre1 :

État de l'art



I.INTRODUCTION

Les moteurs électriques produisent de l'énergie mécanique à partir de l'énergie électrique. Les moteurs à induction sont largement utilisés dans des applications utilisant les pompes, les ventilateurs, les ascenseurs, les véhicules électriques, l'acier et les cimenteries, car ils sont un élément essentiel de l'industrie moderne. De nombreux types de défauts affectent les moteurs à induction et les systèmes d'entraînement. Pour garantir un fonctionnement fiable des moteurs à induction, les fabricants et les utilisateurs s'appuyaient initialement sur des techniques de protection simples contre les surintensités et les surtensions [1]. Cependant, en raison de l'utilisation généralisée de l'automatisation et de la réduction conséquente de l'interaction directe entre l'homme et la machine pour superviser le fonctionnement du système, le besoin de surveillance de l'état des moteurs à induction s'est accru récemment. de formation du moteur. Ils peuvent réduire les pertes financières et prévenir les répercussions désastreuses. La classification de l'état du moteur et l'estimation de la gravité des défauts des signaux n'ont jamais été des tâches faciles et sont souvent influencées par de nombreux facteurs. Ces dernières années, les chercheurs se sont concentrés sur la surveillance et le diagnostic des défauts des moteurs à induction [2]. Ce chapitre présente d'abord la structure d'un moteur à induction.

Les symptômes des défauts mécaniques et électriques du moteur à induction sont ensuite rappelés. Enfin, nous rappelons les techniques de diagnostic des moteurs à induction utilisées dans les recherches antérieures.

I.1.Constitution de la machine asynchrone à cage :

Le moteur d'induction triphasé (souvent appelé moteur asynchrone triphasé) comprend deux parties principales :

- Un inducteur fixe nommé stator : le stator, partie fixe de la machine ou est connectée l'alimentation électrique.
- Un induit mobile nommé rotor: le rotor, partie tournante qui permet de mettre en rotation la charge mécanique. Plus la partie qui fait l'assemblage des deux nommée les paliers: partie mécanique qui permet la mise en rotation de l'arbre moteur.

Les organes mécaniques la rotation du rotor et le maintien des différents sous-ensembles [3].




Figure I.1 : Constitution de la machine asynchrone à cage [4]

I.2.1. Le Stator :

Le stator est composé d'un enroulement bobiné qui est réparti dans les encoches du circuit magnétique. Ce circuit magnétique est composé d'un empilement de tôles sur lesquelles sont découpées des encoches parallèlement à l'axe de la machine. Les conducteurs d'encoches et les têtes de bobines sont les deux parties du bobinage statorique. Le champ magnétique à l'origine de la conversion électromagnétique est créé dans l'entrefer par des conducteurs d'encoches. Les têtes de bobines, quant à elles, permettent la fermeture des courants en organisant une circulation judicieuse des courants d'un conducteur d'encoche à l'autre afin d'obtenir une distribution de courant la plus

sinusoïdale possible à la surface de l'entrefer, ce qui limite les ondulations du couple électromagnétique [5] .




Figure I.2: Le Stator[6].

I.2.2. Rotor:

Le rotor, qui est fixé sur l'arbre moteur, est un cylindre en tôles empilées. À la périphérie extérieure, des encoches sont percées pour accueillir les conducteurs. Cela est le stator est séparé par un entrefer très court de seulement 0,4 à 2 mm. Le rotor est divisé en deux catégories [7] :

Le rotor en forme de cage d'écureuil : Des courants d'un conducteur d'encoche à l'autre. Le circuit du rotor est formé par la répartition régulière de ces barres conductrices (figure I.3). La cage est placée dans un circuit magnétique composé de disques en tôles disposés sur l'arbre de la machine, similaire à celui d'un moteur à rotor bobiné triphasé. Une carcasse en fonte entoure cette couronne [8].



Figure I.3: Rotor à cage d'écureuil[9].

Rotor bobiné:

Le rotor bobiné est constitué de tôles munies d'encoches où sont placés des conducteurs formant des bobinages. Ces bobinages peuvent être accédés à l'aide de trois bagues et trois balais. Ce système peut modifier les caractéristiques électromécaniques du moteur [10].



Figure I.4: Rotor bobinée[11].

I.2.3. Organes mécaniques

La carcasse sert d'enveloppe et protège contre l'environnement extérieur. L'arbre fonctionne comme un organe de transmission. Il inclut une partie centrale qui supporte le corps du rotor et un bout d'arbre sur lequel est fixé un demi-accouplement. Il est généralement fabriqué à partir d'acier moulé ou forgé. Il est dimensionné en fonction des efforts de flexion (force centrifuge, attraction magnétique radiale, etc.), des efforts radiaux et tangentiels causés par les forces centrifuges, et de la

torsion (couple électromagnétique transmis en régime permanent ou transitoire). Il est soutenu par une ou plusieurs étapes. Les paliers soutiennent le rotor et lui permettent de tourner librement. Le deuxième palier est chargé de garantir les dilatations thermiques de l'arbre.

I. 3. Les défaillances dans la machine asynchrone

Si la machine asynchrone à cage d'écureuil est considérée comme robuste, elle peut parfois être affectée par divers défauts. Il est possible que ces défauts soient d'origine électrique ou mécanique. Le défaut peut être causé par un petit problème lors de la fabrication, tout comme une utilisation non conforme de la machine. Parfois, nous pouvons également attribuer la responsabilité au milieu dans lequel la machine est employée (environnements corrosifs et/ou chimiques néfastes).[12]

En 1988, une entreprise d'assurance allemande spécialisée dans les systèmes industriels [8] a mené une étude statistique sur les pannes des machines asynchrones de moyenne puissance (de 50 kW à 200 kW). Les résultats ont révélé que 60 % des pannes se produisent au stator, 22 % au rotor et le reste (18 %) dans les autres parties de la machine telles que les roulements, les borniers, etc. Les résultats obtenus sont les suivants :

- Stator : 60 % des pannes
- Rotor : 22 % des pannes
- Autres parties (roulements, borniers, etc.) : 18 % des pannes

Ces chiffres montrent l'importance de surveiller toutes les parties de la machine pour une maintenance efficace.




Figure I.5 : Proportion des défauts[13] .

Selon les mêmes recherches, les pannes au stator ont diminué de 78 % à 60 % entre 1973 et 1988, tandis que les pannes au rotor ont augmenté de 12 % à 22 %. Les changements observés sont causés

par l'amélioration des isolants pendant cette période. La distribution des pannes dans les diverses parties du moteur est illustrée dans la figure 1.6 suivante :

Stator :

- 1973 : 78 % des pannes
- 1988 : 60 % des pannes

Rotor :

- 1973 : 12 % des pannes
- 1988 : 22 % des pannes

Autres parties :

- La proportion de pannes dans les autres parties de la machine (comme les roulements et les borniers) reste inchangée à 18 %.

Les améliorations des matériaux isolants ont conduit à une réduction significative des pannes au stator, tandis que les pannes au rotor ont augmenté, peut-être en raison de l'augmentation de la charge et des exigences opérationnelles sur les moteurs au fil du temps. Ces données sont représentées graphiquement dans la figure 1.6 pour une meilleure visualisation.

Selon une autre étude statistique [14] menée sur des machines de grande puissance (allant de 100 kW à 1 MW), les pannes les plus courantes se produisent sur les roulements dans cette gamme de puissance. Selon la Figure 1.8, le stator et le rotor sont responsables de 12 % et 8 % des pannes respectivement. Les machines de ce type présentent des contraintes mécaniques plus importantes, ce qui explique le nombre élevé de pannes causées par les roulements. Elles nécessitent une maintenance mécanique plus importante. [15]




Figure I.6 : Répartition des pannes sur les machines de fortes puissances [16].

La machine asynchrone peut présenter différentes sources de dysfonctionnement, qu'elles soient électriques, mécaniques ou magnétiques. Leurs origines sont variées et peuvent être regroupées en trois catégories .

I.4.1. Défaillances d'ordre mécanique

Les problèmes mécaniques sont généralement les plus fréquents parmi tous les défauts que la machine asynchrone peut présenter. Il est possible que ces imperfections se manifestent au niveau des roulements à billes, des flasques ou même de l'arbre moteur. Dans la suite du document, nous mentionnons certains de ces défauts sans en fournir les détails. Il existe dans la littérature des livres extrêmement exhaustifs qui abordent ces différents problèmes.[17]

I.4.1.1. Défaillances des roulements

Le rôle des roulements à billes est crucial pour assurer le bon fonctionnement de toutes sortes de machines électriques. Les problèmes de roulements peuvent résulter d'une mauvaise sélection de matériau lors de la production. Un roulement abîmé, écaillé ou fissuré peut causer des problèmes de rotation dans la culasse du roulement, ce qui peut perturber la machine. Les vitesses élevées peuvent également entraîner la dégradation des roulements.

Dans certaines applications, la graisse, qui favorise la lubrification et la bonne rotation des roulements, peut se rigidifier et entraîner une résistance à la rotation. La détection de ce genre de défaillances peut être réalisée en utilisant l'analyse vibratoire de la machine ou l'analyse harmonique des courants statoriques.[17]

I.4.1.2. Défaillances du flasque

Le plus souvent, les défauts causés par les flasques de la machine asynchrone se produisent lors de la fabrication. Effectivement, une mauvaise position des flasques entraîne une déformation

des roulements à billes, ce qui entraîne une excentricité au niveau de l'arbre de la machine. Ce genre de défaillance peut être repéré grâce à une analyse vibratoire ou à une analyse harmonique des courants de la machine absorbés. [17]

I.4.1.3. Défaillances de l'arbre

L'arbre de la machine peut présenter une fissure en raison de l'utilisation d'un matériau inapproprié lors de sa fabrication. Au fil du temps, cette fissure peut entraîner une fracture définitive de l'arbre, ce qui entraîne un arrêt irrémédiable de la machine asynchrone. Les environnements corrosifs peuvent également diminuer la résistance de l'arbre de la machine. Prenons l'exemple de l'humidité, qui peut entraîner des microfissures et entraîner la destruction totale de la machine. Une excentricité, qu'elle soit statique, dynamique ou mixte, peut entraîner des efforts importants sur l'arbre moteur, ce qui entraîne une fatigue accrue. Ce genre de défaillance peut être détecté grâce à une analyse vibratoire, une analyse par ultrason, une analyse fréquentielle des courants absorbés ou simplement une analyse visuelle de l'arbre de la machine.[18]

I.4.2. Défaillances d'ordre électrique

Les défaillances d'origine électrique peuvent, dans certains cas, entraîner l'arrêt de la machine. Ces défauts se divisent en deux catégories distinctes : les défauts qui surviennent au niveau des circuits électriques du stator et ceux qui surviennent au niveau des circuits électriques du rotor.[19]

I.4.2.1. Défaillances au stator

Les défauts qui se manifestent au niveau du stator sont principalement causés par des problèmes thermiques (surcharge), électriques (diélectriques, etc.), mécaniques (bobinage, etc.) et environnementaux (agressions, etc.). Parmi eux, on peut citer [20]:

- Défauts d'isolants
- Court-circuit entre spires
- Court-circuit entre phases
- Déséquilibre d'alimentation
- Défaut de circuit magnétique

I.4.2.2. Défaillances au rotor

Les défauts au stator représentent environ 40 à 60 % des défauts des machines asynchrones. Les défauts les plus courants, situés au niveau du rotor, peuvent être définis comme suit :

I.4.2.2.1. Rupture de barres

La rupture de barres est l'un des défauts les plus fréquents au niveau du rotor. Elle peut se produire soit au niveau de l'encoche, soit à l'extrémité qui relie la barre à l'anneau rotorique. La détérioration des barres réduit la valeur moyenne du couple électromagnétique et augmente l'amplitude des oscillations, ce qui entraîne des oscillations de la vitesse de rotation, des vibrations mécaniques et un fonctionnement anormal de la machine. La grande amplitude de ces oscillations accélère la détérioration de la machine. Ainsi, le couple diminue sensiblement avec le nombre de barres cassées, induisant un effet cumulatif de la défaillance. L'effet d'une cassure de barre croît rapidement avec le nombre de barres cassées. Suite à une rupture de barre, les circuits rotoriques créent un champ magnétique inverse de pulsation, induisant des composantes de courant à ces fréquences dans les circuits statoriques.[21]

Défauts d'enroulement du rotor :

Les enroulements du rotor peuvent subir des défauts tels que des courts-circuits entre spires, des ruptures partielles ou totales des enroulements, ou des défauts d'isolation électrique. Ces défauts peuvent être causés par des contraintes mécaniques, thermiques ou électriques excessives.

Défauts de connexion :

Les connexions électriques du rotor, telles que les connexions entre les barres du rotor et les anneaux, peuvent se desserrer ou se corroder avec le temps, entraînant une résistance électrique accrue et une détérioration des performances du moteur.

Déséquilibre de masse :

Un déséquilibre de masse dans le rotor peut entraîner des vibrations excessives, ce qui peut endommager les paliers et d'autres composants mécaniques de la machine.

Défaillance des roulements du rotor :

Les roulements de support du rotor peuvent également subir des défauts tels que des défaillances de lubrification, des dommages mécaniques ou des défauts d'alignement, ce qui peut entraîner une usure prématurée du rotor et des vibrations excessives.

Ces défauts de défaillance du rotor peuvent avoir un impact significatif sur la performance, la fiabilité et la durée de vie de la machine asynchrone. Il est donc important de surveiller régulièrement

l'état du rotor et d'effectuer une maintenance préventive pour détecter et corriger ces défauts avant qu'ils ne provoquent des pannes majeures [22].

CONCLUSION

En conclusion, ce chapitre met en lumière les différentes défaillances rencontrées dans les machines asynchrones, en se concentrant principalement sur les défaillances d'ordre mécanique et électrique. Les machines asynchrones sont sujettes à une variété de défauts qui peuvent compromettre leur performance, leur fiabilité et leur durabilité.

Du côté des défaillances mécaniques, nous avons examiné les problèmes potentiels tels que les défauts des roulements, des flasques et de l'arbre. Ces défauts peuvent être causés par des contraintes mécaniques, thermiques, électriques ou environnementales, et nécessitent une surveillance régulière et une maintenance préventive pour prévenir les pannes et les arrêts de production coûteux.

Par ailleurs, les défaillances d'ordre électrique ont également été abordées, mettant en évidence les problèmes courants tels que les défauts au stator et au rotor. Les défauts électriques peuvent être causés par des surcharges, des problèmes d'isolation, des déséquilibres d'alimentation, des courts-circuits, entre autres. Ils peuvent entraîner des pannes soudaines et des dommages importants à la machine.



Chapitre 2 :

**Diagnostic des défauts dans les machines
asynchrones par intelligence artificiel**



II.1.INTRODUCTION

Le traitement du signal est une discipline indispensable de nos jours. Il a pour objet l'élaboration ou l'interprétation des signaux porteurs d'informations. Son but est de réussir à extraire un maximum d'information. La transformée de Fourier est un outil de traitement de signal qui permet la compréhension et la mise en œuvre de nombreuses techniques numériques de traitement des signaux. Cet outil trouve de nombreuses applications dans des domaines tels que la transmission numérique, le diagnostic ou encore l'astronomie.

Un réseau de neurones artificiels ou réseau neuronal artificiel est un système dont la conception est à l'origine schématiquement inspirée du fonctionnement des neurones biologiques, et qui par la suite s'est rapproché des méthodes statistiques. [36]

On s'intéresse à décrire dans ce chapitre les principales techniques de traitement de signal et les réseaux de neurones pour le diagnostic des défauts dans la machine asynchrone.

II.2. Définition du diagnostic :

Le mot diagnostic peut avoir plusieurs interprétations selon le contexte et le domaine d'application. Et le diagnostic dans les procédés industriels est détermination du type, de la taille, de la localisation et de l'instant d'occurrence d'un défaut. Fonction qui suit la détection et inclut les fonctions de localisation et d'identification. [23]

Le diagnostic des défaillances, s'il est réalisé avec efficacité et s'il permet de détecter de façon précoce une dégradation, représente un des moyens pour contribuer à l'amélioration de productivité.

II.3. Les différentes méthodes de diagnostic :

II.3.1. Diagnostic par l'analyse spectrale et le suivi des grandeurs mesurables :

L'analyse spectrale est une méthode utilisée pour diagnostiquer les défauts en mesurant des grandeurs telles que les fréquences, les amplitudes et les phases des signaux. Elle permet d'identifier des signatures caractéristiques associées à différents défauts, tels que des vibrations anormales ou des irrégularités dans les spectres de fréquences. Cette méthode est largement utilisée dans la maintenance prédictive des machines industrielles et le diagnostic médical.

II.3.2. Analyse des courants statoriques :

L'étude des courants statoriques dans le domaine fréquentiel demeure la méthode la plus répandue, car le spectre obtenu fournit des informations sur la plupart des défauts électriques et magnétiques qui peuvent survenir dans une MAS.

Cette technique est dénommée dans la littérature « MotorCurrent Signature Analysis »

(MCSA) . Le spectre du courant statorique est influencé par les défauts de la MAS, ce qui se manifeste par,

Les fréquences des raies spectrales qui se manifestent sont directement liées à la vitesse de rotation de la machine, aux vitesses des champs tournants et aux paramètres de la machine. Ou encore, les amplitudes des raies spectrales sont modifiées dans le spectre du courant. [24]

II.3.3. Analyse vibratoire des machines tournantes :

Les vibrations mécaniques sont la méthode la plus couramment employée pour diagnostiquer les défauts dans les forces radiales, qui sont générées par le champ d'entrefer et qui entraînent des vibrations dans la machine asynchrone. Ces forces sont liées au carré de la force d'induction magnétique. [25]

Il est possible de détecter les vibrations de la machine en utilisant des accéléromètres installés sur les paliers dans les directions axiale, verticale et radiale. On compare les spectres des signaux de vibrations provenant du moteur défectueux avec ceux des références enregistrées lors de l'état de la machine. La méthode offre la possibilité de détecter à la fois des défauts électriques et mécaniques, car la force magnétomotrice peut absorber les effets des asymétries du stator ou du rotor, tandis que la perméance varie en fonction de la variation de l'intensité. Toutefois, le prix élevé des capteurs de vibration, ainsi que les problèmes rencontrés lors de la connexion de ces capteurs (problème d'accessibilité), constituent les limites et les désavantages de cette méthode. [25]

II.3.4. Analyse des flux :

Dans une machine parfaite, il y a un équilibre entre les courants et les tensions statoriques, ce qui bloque le flux de fuite axial. En cas de défaut, il y a un déséquilibre électrique et magnétique au niveau du stator, ce qui entraîne des flux de fuite axiale de différentes valeurs en fonction de la gravité du défaut. L'installation d'une bobine autour de l'arbre de la machine entraînera l'induction d'une force électromotrice. On peut utiliser le contenu spectral de la tension générée dans cette bobine afin de repérer les divers défauts. [25]

II.3.5. Analyse du couple électromagnétique :

L'analyse du couple électromagnétique permet de repérer certains défauts mécaniques en cherchant des harmoniques dans le spectre du couple mesuré. Ces harmoniques sont le résultat d'une interaction entre le flux et le courant. Cette méthode permet de détecter les défauts de charge et les défauts de torsion de l'arbre, qui provoquent des fluctuations du flux et du courant dans la machine.


II.4. Techniques de traitement du signal utilisées dans le diagnostic :

Différentes techniques de traitement du signal sont utilisées pour diagnostiquer les défauts des machines asynchrones, notamment l'évaluation de la densité spectrale de puissance et la démodulation. Ces techniques permettent d'obtenir des données fiables sur les diverses formes de défauts. Des recherches ont été menées pour développer des méthodes de classification permettant d'effectuer des diagnostics précis en fonction des différentes approches de modélisation utilisées.

En résumé, une combinaison de ces méthodes de diagnostic peut être utilisée pour surveiller et diagnostiquer efficacement les machines asynchrones, permettant ainsi de réduire les temps d'arrêt, d'améliorer la fiabilité et d'optimiser la maintenance préventive.

II.4.1.Traitement de signal :

Le traitement du signal englobe un ensemble de méthodes visant à générer, analyser et modifier les signaux d'entrée afin d'extraire des paramètres révélateurs de défauts éventuels. Ces techniques peuvent être regroupées en trois catégories principales : l'analyse temporelle, l'analyse fréquentielle et l'analyse temps-fréquence.



FigureII.7 : Technique de traitement de signal [26]

II.4.1.1. Analyse temporelle

Cette méthode consiste à étudier les signaux dans le domaine temporel, c'est-à-dire en fonction du temps. Elle permet d'observer l'évolution d'un signal au cours du temps et de détecter des variations, des impulsions ou des comportements transitoires qui pourraient indiquer la présence de défauts. [27]

La valeur moyenne :

La valeur moyenne notée $\bar{x}$ d'un signal sur une fenêtre d'échantillons de données est un paramètre significatif pour presque chaque type de capteur. Elle est définie par [28] :

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N X_i$$

Où x_i est i donnée et N est le nombre de points total choisi pour représenter le signal.

La variance :

Notée par Var est une mesure servant à caractériser la dispersion d'une distribution ou d'un échantillon. Elle est définie par :

$$\text{Var} = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}$$

L'écart type :

Noté par σ ou la moyenne quadratique, c'est la racine carrée du moment d'ordre deux (variance) du signal :

$$\sigma = \sqrt{\text{Var}} = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}}$$

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

Le Skewness :

Noté *Skew* représente le moment statique d'ordre 3 centré sur le cube de l'écart-type. Il mesure la symétrie de la distribution, ou plus précisément le manque du signal. Il est défini comme suit :

$$\text{Skew} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{(\sigma)^3}$$

Les paramètres décrits ci-dessus ont tous le même inconvénient, ils indiquent la dégradation du système mais n'arrivent pas à identifier le défaut responsable de cette dégradation

Le 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 il est défini comme étant le rapport entre le moment d'ordre quatre centré et le carré de la variance [29].

$$\text{Skurt} = \frac{\frac{1}{N} \sum_{i=1}^N [(x_i - \bar{x})^4]}{(\sigma^2)^2}$$

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

II.4.1.2. Analyse fréquentielle :

L'analyse fréquentielle se concentre sur l'étude des signaux dans le domaine fréquentiel, c'est-à-dire en termes de fréquences. Elle permet d'identifier les composantes fréquentielles présentes dans un

signal et de mettre en évidence des signatures caractéristiques associées à des défauts spécifiques. Cette méthode est particulièrement utile pour détecter des vibrations anormales, des harmoniques ou des modulations de fréquence.

II.4.1.2.1 Transformée de Fourier Rapide (TFR) :

La transformée de Fourier rapide (TFR) est une méthode couramment utilisée pour détecter les défauts dans les machines asynchrones. Elle offre de bons résultats pour les opérations à puissance élevée ou à couple constant. Cependant, elle peut rencontrer des difficultés lors des opérations à couple de charge, à vitesse de rotation et à tensions d'alimentation variables. Ainsi, il devient nécessaire d'explorer d'autres techniques de traitement du signal pour les signaux non stationnaires [30].

II.4.1.2.2 Transforme de fourier discrète :

L'utilisation d'un calculateur numérique pour déterminer la transformée de Fourier d'un signal permet d'obtenir uniquement un nombre limité de valeurs de fréquence f , en raison des contraintes de puissance de calcul. Par conséquent, il est nécessaire de discrétiser la variable continue f . Le calcul de la transformée de Fourier discrète pour un signal discret $x(k)$ de longueur N est donné par [31] :

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N}$$

II.4.1.3 Analyse temps-fréquence :

Cette approche combine les deux méthodes précédentes en étudiant à la fois le domaine temporel et le domaine fréquentiel d'un signal. Elle permet de visualiser comment les caractéristiques fréquentielles d'un signal évoluent dans le temps, ce qui peut fournir des informations supplémentaires sur la nature et l'évolution des défauts. Cette méthode est souvent utilisée pour analyser des signaux non stationnaires ou des événements transitoires [32] [33].

II.4.1.3.1 Transformée en ondelettes (TO) :

Les ondelettes font partie de l'analyse temps-fréquence. Contrairement à la transformée de Fourier, qui fournit une représentation en fréquence fixe pour tout le signal, les ondelettes permettent une représentation temps-fréquence variable, ce qui les rend particulièrement adaptées à l'analyse des signaux non stationnaires. Elles fournissent une résolution temporelle élevée pour les hautes fréquences

et une résolution fréquentielle élevée pour les basses fréquences, ce qui en fait un outil puissant pour l'analyse de signaux complexes tels que ceux générés par les machines asynchrones.


La transformée en ondelettes est une méthode de traitement de signal relativement récente. Elle repose sur la décomposition d'un signal dans une base de fonctions particulières. Contrairement à l'analyse de Fourier, les ondelettes sont des fonctions oscillantes qui décroissent rapidement. De plus, elles possèdent la capacité d'être bien localisées dans le temps ou en fréquence, ce qui les distingue de l'analyse temps-fréquence classique. La transformée en ondelettes a été utilisée dans plusieurs travaux pour diagnostiquer les défauts dans les machines asynchrones triphasées à cage [34]

En utilisant ces différentes techniques de traitement du signal, il est possible de détecter, de localiser et de caractériser divers types de défauts dans les machines asynchrones, contribuant ainsi à améliorer la maintenance prédictive et à réduire les temps d'arrêt non planifiés.

II.5. Diagnostic par réseaux de neurones

II.5.1. les réseaux de neurones :

Un réseau de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau .



FigureII 8 : les réseaux de neurones[35]

II.5.2 Les Réseaux de Neurones Artificiels (RNA) :

Un réseau de neurones artificiels ou réseau neuronal artificiel est un système dont la conception est à l'origine schématiquement inspirée du fonctionnement des neurones biologiques, et qui par la suite s'est rapproché des méthodes statistiques. Les réseaux de neurones artificiels (RNA), également connus sous le nom de réseaux neuronaux simulés (SNN) ou perceptrons multicouches, sont un modèle d'apprentissage automatique inspiré du fonctionnement du cerveau humain. Ils sont constitués de neurones artificiels, interconnectés en couches, qui traitent et transmettent des informations. Chaque neurone artificiel reçoit des entrées, les combine à l'aide d'une fonction d'activation, puis produit une sortie. Les connexions entre les neurones sont pondérées, ce qui permet de moduler l'influence de chaque entrée sur la sortie [36].

II.5.3. Principe de Fonctionnement :

Une fois qu'une couche d'entrée est déterminée, des poids sont attribués. Ces poids permettent de déterminer l'importance d'une variable donnée, les poids les plus importants contribuant de façon plus significative à la sortie par rapport aux autres entrées. Toutes les entrées sont ensuite multipliées par leurs poids respectifs, puis additionnées. Par la suite, la sortie est transmise via une fonction d'activation qui détermine la sortie. Si cette sortie dépasse un seuil donné, elle « déclenche » (ou active) le nœud, et transmet les données à la couche suivante du réseau. La sortie d'un nœud devient alors l'entrée du nœud suivant. Ce processus de transmission des données d'une couche à la couche suivante définit ce réseau de neurones comme un réseau à propagation avant [37].

II.5.4. Domaines d'Application

Aujourd'hui, les réseaux de neurones ont de nombreuses applications dans des domaines très variés [38][39]:

- Traitement d'image : compression d'images, reconnaissance de caractères et de signatures, reconnaissance de formes et de motifs, classification, etc.
- Traitement du signal : traitement de la parole, identification de source, filtrage, classification.
- Traitement automatique des langues : segmentation en mots, représentation sémantique des mots (plongements lexicaux), étiquetage morphosyntaxique, traduction automatique, etc.
- Contrôle : diagnostic de pannes, commande de processus, contrôle qualité, robotique, etc.
- Optimisation : allocation de ressources, planification, régulation de trafic, gestion, finance, etc.
- Simulation : simulation boîte noire, prévisions météorologiques.

- Classification d'espèces animales étant donnée une analyse ADN.
- Modélisation de l'apprentissage et perfectionnement des méthodes de l'enseignement.
- Approximation d'une fonction inconnue ou modélisation d'une fonction connue mais complexe à calculer avec précision.


Les réseaux de neurones artificiels, inspirés du comportement du cerveau humain, permettent de créer de l'intelligence artificielle. Notamment appliqués en datamining principalement à travers l'apprentissage non supervisé, ils servent à prédire, à identifier et à classer les données. L'apprentissage, moteur essentiel du système, leur permet d'assimiler un traitement d'information à travers une fonction et de le reproduire pour les données qui leur sont fournies [36].

II.6 Réseaux neurones convolutionnels (CNN) :

Les réseaux neuronaux convolutifs (Convolutional Neural Network, CNN ou ConvNet) sont utilisés avec succès dans un grand nombre d'applications. La tâche de reconnaissance de l'écriture manuscrite a été l'une des premières applications de l'analyse d'image par réseaux de neurones convolutifs. En plus de fournir des bons résultats sur des tâches de détection d'objet et de classification d'images, ils réussissent également bien lorsqu'ils sont appliqués à la reconnaissance faciale, à l'analyse vidéo, ou encore à la reconnaissance de texte [40 ; 41]

II.6.1 Architecture des Réseaux de Neurones Convolutifs (CNN) :

Les CNN sont composés de trois types de couches : des couches convolutives, des couches de regroupement et des couches entièrement connectées. Lorsque ces couches sont empilées, une architecture CNN a été formée. Une architecture CNN simplifiée pour la classification MNIST est illustrée à la figure 3_1 [42]




FigureII.9 . Architecture simple de CNN

II.6.1.1 Couche convolutive

Elle consiste à appliquer un filtre de convolution à l'image pour détecter des caractéristiques de l'image. Une image passe à travers une succession de filtres, ou noyaux de convolution, créant de nouvelles images appelées cartes de convolution. Certains filtres intermédiaires réduisent la résolution de l'image par une opération de maximum local. Au final, les cartes de convolution sont mises à plat et concaténées en un vecteur de caractéristiques.

II.6.1.2. Couche de pooling


Chaque couche de pooling est placée entre la couche de ReLU et convolution. Elle reçoit en entrée plusieurs plans de descripteurs et applique l'opération pooling qui correspond au calcul du maximum de cellules régulière. On utilise souvent des cellules carrées de petite taille pour ne pas perdre trop d'informations. Les choix les plus communs sont des cellules adjacentes de taille 2×2 qui ne se chevauchent pas. Le but de la couche de pooling est de réduire le nombre de paramètres et de calculs dans le réseau. On améliore ainsi l'efficacité du réseau et on évite le sur-apprentissage [43].



FigureII.10.Couche de pooling

II.6.1.3 Couche de correction RELU :

Cette couche est utilisée éventuellement pour corriger des erreurs et ainsi améliorer l'efficacité du traitement entre les couches de convolutions et pooling. Cette couche va opérer comme une fonction d'activation sur les sorties .Lors de ce processus, les cartes de convolution sont soumises à une couche d'activation non linéaire, souvent appelée Rectified Linear Unit (ReLU). Cette opération consiste à remplacer les valeurs négatives des images filtrées par des zéros [41, 44].




FigureII.11. la courbe de la fonction RELU

II.6.1.4.La couche entièrement connectée (Fully connected):

Également connue sous le nom de couche dense, est une composante essentielle des réseaux neuronaux. Dans cette couche, chaque neurone est connecté à chaque neurone de la couche précédente, formant ainsi une connexion complète ou dense. Cette architecture permet au réseau de capturer des relations complexes entre les caractéristiques extraites par les couches précédentes.

Elle reçoit un vecteur en entrée contenant les pixels aplatis de tous les images filtrées, corrigées et réduites par le pooling [42].



FigureII.12.La couche entièrement connectée (Fully connected)

Dans le cas de la classification d'images, le traitement des images implique généralement plusieurs étapes à travers les couches d'un réseau de neurones convolutionnel (CNN). Voici comment cela se déroule :

Extraction des caractéristiques : Les couches de convolution agissent comme des filtres pour extraire des caractéristiques significatives de l'image, telles que les bords, les textures et les motifs. Chaque couche de convolution utilise plusieurs filtres pour capturer différentes caractéristiques à différentes échelles et orientations.

Réduction de la dimensionnalité : Les couches de pooling (mise en commun) réduisent progressivement la dimension de l'image en regroupant les pixels voisins. Cela permet de réduire la quantité de calcul nécessaire et d'obtenir des représentations plus abstraites des caractéristiques extraites.

Classification : Une fois que les caractéristiques ont été extraites et réduites en dimensionnalité, la séquence d'entrée des images est généralement aplatie pour être introduite dans des couches entièrement connectées (fully connected). Ces couches prennent l'ensemble des caractéristiques extraites et tentent de les associer à des classes spécifiques.

Application de la fonction softmax : La dernière couche fully connected est souvent suivie d'une fonction d'activation softmax. Cette fonction transforme les scores de sortie en probabilités, fournissant ainsi une distribution de probabilité sur les différentes classes d'objets possibles dans l'image.

En résumé, le CNN traite automatiquement l'image en extrayant des caractéristiques à travers les couches de convolution et de pooling, puis en les utilisant pour effectuer une classification à l'aide des couches fully connected, suivie de l'application de la fonction softmax pour obtenir les probabilités de chaque classe.

III.6.2. Avantages de CNN

Un avantage majeur des réseaux convolutifs est l'utilisation d'un poids unique associé aux signaux entrant dans tous les neurones d'un même noyau de convolution. Cette méthode réduit l'empreinte mémoire, améliore les performances et permet une invariance du traitement par translation. C'est le principal avantage du réseau de neurones convolutifs par rapport au perceptron multicouches, qui, lui, considère chaque neurone indépendant et affecte donc un poids différent à chaque signal entrant. [45]

II.7 Entraînement des CNN

Il est ardu et coûteux de concevoir un réseau de neurones convolutifs, car cela demande une expérience solide, du matériel et la quantité de données requises. Dans un premier temps, il est nécessaire de définir l'architecture du réseau, à savoir le nombre de couches, la taille et les opérations matricielles qui les relient. Ensuite, la formation vise à optimiser les paramètres du réseau afin de minimiser l'erreur de classification en sortie. Les meilleurs réseaux CNN peuvent nécessiter plusieurs jours pour être exécutés, car les unités de traitement graphique (GPU) sont chargées de traiter des centaines de milliers d'images [46].

II.7.1 Méthodes d'entraînement des CNN, notamment l'utilisation de jeux de données d'entraînement et de validation.


Pour mettre en place un réseau, il est essentiel de diviser les données en trois échantillons : l'échantillon d'entraînement, de validation et de test.

Lors de la phase d'entraînement de notre réseau, nous utilisons l'échantillon d'entraînement et l'échantillon de validation. On utilise l'échantillon d'entraînement afin de modifier les poids du modèle afin de réduire la fonction de perte et d'obtenir les résultats désirés en sortie. L'ensemble de validation

du modèle est également différent de l'échantillon d'entraînement et sert à vérifier notre modèle. Celui-ci est utilisé pour évaluer la capacité de généraliser le modèle.

Afin d'obtenir une capacité de généralisation adéquate, un modèle doit fournir des résultats satisfaisants tant sur l'ensemble d'entraînement que sur l'ensemble de vérification. L'utilisateur doit donc mettre fin à l'apprentissage lorsque le modèle atteint cet objectif (figureII.7).

De son côté, l'échantillon de test permet d'évaluer les performances du modèle sur de nouvelles données, c'est-à-dire des données que le modèle n'a pas encore examinées [47].



FigureII.13. Évolution de la courbe d'erreur durant la phase d'apprentissage [47].

II.7.2 Techniques d'optimisation des hyperparamètres, telles que l'ajustement du taux d'apprentissage et l'utilisation de techniques de régularisation.

II.7.2.1 Hyper paramètre utilisé

L'ensemble d'hyper-paramètres pris en compte et ajustés étape par étape dans ce projet sont :

- Relatif aux images :
- La taille de l'image,
- Paramètres de prétraitement,
- Taille de la base de données.
- Relatif à l'apprentissage :

- La taille de l'image,
- Nombre d'époques (epochs)
- Taille du lot (batch size),
- Taux d'apprentissage (learning rate),
- Critère de mise à jour des poids,
- Expression de la perte d'apprentissage (training loss),
- Critère d'initialisation des poids
- Relatif à l'architecture :
 - Nombre de couches,
 - Type de couches,
 - Nombre de filtres

II.7.2.2 Aperçu général

Cette section présente les grandes lignes de la solution proposée

. Le système repose sur six (06) étapes :

1. Préparation des données : Les images d'entraînement doivent être préparées sous forme de tenseurs pour être utilisées par le modèle. Cela peut impliquer le redimensionnement des images, la normalisation des valeurs de pixel, etc.
2. Construction du modèle : Le modèle CNN est construit à l'aide de la fonction build model, qui crée une architecture avec des couches de convolution, des couches d'activation et une couche de sortie.
3. Compilation du modèle : Avant de pouvoir entraîner le modèle, il doit être compilé en spécifiant une fonction de perte (loss function), un optimiseur et des métriques pour évaluer les performances du modèle.
4. Entraînement du modèle : Le modèle est entraîné en utilisant un ensemble de données d'entraînement. Pendant l'entraînement, les poids du modèle sont

ajustés pour minimiser la fonction de perte et améliorer les performances du modèle sur les données d'entraînement.

5. Évaluation du modèle : Une fois l'entraînement terminé, le modèle est évalué sur un ensemble de données de validation ou de test pour évaluer ses performances sur des données qu'il n'a pas vues pendant l'entraînement.

Cela permet de vérifier si le modèle généralise bien et peut effectuer des prédictions précises sur de nouvelles images.


6. Prédiction des classes : Une fois le modèle entraîné et évalué, il peut être utilisé pour effectuer des prédictions sur de nouvelles images. Les images de test ou d'autres images d'entrée sont fournies au modèle, qui produit des scores de classe pour chaque image. La classe prédite est généralement déterminée en prenant la classe avec le score le plus élevé.

CONCLUSION

Au cours de ce chapitre, nous avons examiné les méthodes traditionnelles de traitement de signal, que ce soit dans le temps (moyenne, écart type, kurtosis...) ou dans la fréquence (série de Fourier, transformation de Fourier). Grâce à la transformation de Fourier, nous avons pu étudier la transformation de Fourier. L'identification et la localisation du défaut de roulement sont l'une des méthodes classiques les plus couramment employées dans l'analyse vibratoire. Dans le prochain chapitre, nous allons examiner les résultats de la transformation en ondelettes.



Chapitre 3 :



III.1. INTRODUCTION

Dans ce chapitre, nous expliquons comment effectuer des diagnostics de pannes à l'aide d'une approche d'apprentissage en profondeur. Nous démontrerons la classification des défauts de roulements en convertissant les signaux de vibration 1D en images 2D de mesures, puis en appliquant l'apprentissage par transfert à l'aide d'un réseau pré-entraîné. L'apprentissage par transfert réduit considérablement le temps passé à extraire et à sélectionner les caractéristiques dans les méthodes traditionnelles de diagnostic des roulements, tout en offrant une bonne précision pour le petit ensemble de données MFPT utilisé.

III.2. DEFAUTS DE ROULEMENTS A ELEMENTS ROULANTS

Les défauts localisés dans un roulement à éléments roulants peuvent se produire sur la bague extérieure, la bague intérieure, la cage ou les éléments roulants eux-mêmes. Lorsqu'un élément roulant frappe un défaut local sur la bague extérieure ou intérieure, ou qu'un défaut sur un élément roulant frappe la bague extérieure ou intérieure, cela excite des résonances à hautes fréquences entre le roulement et le capteur de réponse [1].

La figure suivante montre un élément roulant frappant un défaut local sur la bague intérieure. Un problème courant est la détection et l'identification de ces défauts.




Figure III.14. Vue d'ensemble d'un roulement à bille

III.3. PRINCIPALES CARACTERISTIQUES DES SIGNAUX VIBRATOIRES DE ROULEMENTS A BILLES

Un signal représente une mesure physique qui évolue en fonction du temps, comme les vibrations d'un roulement à billes. Ces signaux vibratoires contiennent des informations sur l'état de fonctionnement du roulement. Lorsque le roulement présente un défaut, celui-ci se traduit par des modifications caractéristiques dans le signal vibratoire. L'analyse de ces signaux permet donc de détecter et de diagnostiquer les défauts des roulements. Quelques propriétés importantes des signaux vibratoires de roulements :

Amplitude du signal :

- L'amplitude du signal vibratoire est liée à la sévérité du défaut du roulement. Plus le défaut est important, plus l'amplitude des vibrations sera élevée.
- L'amplitude permet donc d'évaluer la gravité du défaut et de suivre son évolution dans le temps.

Fréquence du signal :

- Les défauts de roulement induisent des vibrations à des fréquences caractéristiques, dépendantes de la géométrie du roulement.
- Par exemple, les fréquences de passage des éléments roulants (billes, piste intérieure, piste extérieure) sont révélatrices des différents types de défauts.
- L'analyse fréquentielle du signal vibratoire permet donc d'identifier le type de défaut présent.

Forme d'onde du signal :

- La forme d'onde temporelle du signal vibratoire présente aussi des caractéristiques distinctes selon le type de défaut.
- Certains défauts induisent par exemple des chocs périodiques qui se traduisent par des impulsions dans le signal.
- L'analyse de la forme d'onde apporte donc des informations complémentaires pour le diagnostic. L'étude conjointe de ces différentes caractéristiques du signal vibratoire (amplitude, fréquence, forme d'onde) permet ainsi de détecter, d'identifier et de suivre l'évolution des défauts

III.4. METHODOLOGIE DE TRAVAIL

Dans le contexte de la détection des défauts de roulements à billes, les signaux de vibration unidimensionnels (1D) captés par des capteurs sont d'abord collectés. Ces signaux contiennent des informations cruciales sur l'état du roulement, mais leur interprétation directe peut être complexe et peu intuitive. Pour faciliter l'analyse et améliorer la précision du diagnostic, ces signaux 1D sont transformés en spectrogrammes, qui sont des représentations temps-fréquence bidimensionnelles (2D).

Un spectrogramme est une visualisation graphique qui montre comment les fréquences d'un signal changent au fil du temps. Il est obtenu en appliquant une transformation de Fourier à court terme (STFT) aux segments du signal de vibration, ce qui permet de décomposer le signal en ses composantes fréquentielles à différents instants temporels. Cette méthode de transformation fournit une image 2D où l'axe horizontal représente le temps, l'axe vertical représente les fréquences, et les couleurs ou intensités représentent l'amplitude des composantes fréquentielles à chaque instant.

Cette conversion des signaux de vibration 1D en spectrogrammes 2D offre plusieurs avantages :

Amélioration de la visibilité : Les caractéristiques des défauts, souvent difficiles à discerner dans les données brutes, deviennent plus apparentes dans le spectrogramme.

Facilitation de l'analyse : Les motifs et les anomalies dans les données sont plus faciles à identifier lorsqu'ils sont visualisés en termes de temps et de fréquence.

Compatibilité avec les modèles de deep learning : Les spectrogrammes peuvent être traités comme des images, ce qui permet d'utiliser des réseaux de neurones convolutifs (CNN) pré-entraînés pour la classification et la détection des défauts.

En résumé, la conversion des signaux de vibration 1D en spectrogrammes 2D est une étape clé du prétraitement qui améliore la lisibilité des données et la précision des diagnostics dans l'analyse des défauts de roulements à billes.

III.5. DONNEES UTILISEES

Un ensemble de données sur les défauts de roulements a été fourni pour faciliter la recherche sur l'analyse des roulements. L'ensemble de données comprend des données provenant d'un banc d'essai de roulements (données de roulement nominal, un défaut de bague extérieure à différentes charges, et un défaut de bague intérieure à différentes charges), ainsi que trois défauts réel.

Le banc d'essai était équipé d'un roulement NICE avec les paramètres suivants :

- Diamètre des rouleaux : $rd = 0,235$
- Diamètre primitif : $pd = 1,245$
- Nombre d'éléments : $ne = 8$
- Angle de contact : $ca = 0$

L'ensemble de données 1,2 comprend les éléments suivants, et peut être téléchargé sous forme d'un package [<https://github.com/mathworks/RollingElementBearingFaultDiagnosis-Data>]

- 3 conditions de base : 270 lbs de charge, vitesse de l'arbre d'entrée de 25 Hz, fréquence d'échantillonnage de 97 656 échantillons/s, pendant 6 secondes
- 3 conditions de défaut de bague extérieure : 270 lbs de charge, vitesse de l'arbre d'entrée de 25 Hz, fréquence d'échantillonnage de 97 656 échantillons/s, pendant 6 secondes
- 7 conditions de défaut de bague extérieure : 25, 50, 100, 150, 200, 250 et 300 lbs de charge, vitesse de l'arbre d'entrée de 25 Hz, fréquence d'échantillonnage de 48 828 échantillons/s, pendant 3 secondes (la résonance du roulement a été trouvée inférieure à 20 kHz)
- 7 conditions de défaut de bague intérieure : 0, 50, 100, 150, 200, 250 et 300 lbs de charge, vitesse de l'arbre d'entrée de 25 Hz, fréquence d'échantillonnage de 48 828 échantillons/s, pendant 3 secondes
- 5 fichiers d'analyse de données (.m) liés au document d'introduction d'Eric Bechhoefer mentionné ci-dessous
- Trois2 exemples de fichiers du monde réel sont également inclus : un roulement d'arbre intermédiaire d'une éolienne (la structure de données contient les vitesses de roulement et la vitesse de l'arbre), un roulement d'arbre de pompe à huile d'une éolienne, et un défaut de roulement planétaire du monde réel).

Chaque ensemble de données contient un signal d'accélération gs , une fréquence d'échantillonnage sr , une vitesse d'arbre $rate$, un poids de charge $load$, et quatre fréquences critiques représentant différents emplacements de défauts : fréquence de passage des billes sur la bague extérieure (BPFO), fréquence de passage des billes sur la bague intérieure (BPFI), fréquence fondamentale de la cage (FTF), et fréquence de rotation des billes (BSF). Les formules pour BPFO et BPFI sont les suivantes [1] :

Où :

N : Nombre d'éléments roulants (billes)

f_r : Fréquence de rotation de l'arbre (trs/min)

β : Angle de contact (degrés)

D : Diamètre primitif (pouces)

d : Diamètre des éléments roulants (pouces)

Ces fréquences caractéristiques permettent d'identifier les défauts spécifiques dans les signaux vibratoires en analysant les pics correspondants dans le domaine fréquentiel. Elles seront particulièrement utiles pour l'étape d'extraction de caractéristiques et le diagnostic final des défauts de roulements.

- BPFO :

$$BPFO = \frac{nf}{2} \left(1 - \frac{d}{D} \cos \varphi \right)$$

- BPFI :

$$BPFI = \frac{nf}{2} \left(1 + \frac{d}{D} \cos \varphi \right)$$

III.6. ETUDE DU SIGNAL EMANANT D'UN ROULEMENT A BILLE

L'analyse des défauts de roulement à billes peut être effectuée en deux étapes principales : dans le domaine temporel et dans le domaine tempo-fréquentiel.

Dans un premier temps, l'étude dans le domaine temporel permet d'observer les caractéristiques du signal vibratoire, telles que les impulsions périodiques et le bruit à large bande. Ces caractéristiques sont typiques des signatures vibratoires de défauts sur les différents éléments du roulement (bague extérieure, bague intérieure, éléments roulants, cage). L'analyse temporelle est essentielle pour détecter la présence de défauts en observant les variations anormales dans le signal.

Ensuite, pour une identification plus précise du type de défaut, l'analyse passe au domaine tempo-fréquentiel. En utilisant la transformation en ondelettes continues (CWT), on peut obtenir un scalogramme, qui est une représentation fréquentielle du signal. Cette méthode permet de repérer les fréquences caractéristiques associées aux défauts spécifiques. Le scalogramme fournit une vue détaillée de la distribution des énergies du signal sur différentes échelles de temps et de fréquences, facilitant ainsi le diagnostic précis des défauts.

L'analyse conjointe du signal temporel et du scalogramme est une approche courante pour le diagnostic et la surveillance de l'état de fonctionnement des roulements à billes, dans le cadre de la maintenance prédictive des machines. En combinant ces deux domaines d'analyse, on peut non

seulement détecter la présence de défauts, mais aussi identifier leur nature et leur localisation avec une grande précision.

III.6.1. Etude dans le domaine temporel

Lorsque des défauts locaux sont rencontrés par les éléments roulants au niveau des pistes intérieures ou extérieures, ou lorsque des défauts des éléments roulants affectent les pistes intérieures ou extérieures, cela modifie les fréquences critiques correspondantes. Ainsi, le signal d'enveloppe généré par la démodulation d'amplitude fournit des informations diagnostiques supplémentaires qui ne sont pas accessibles par l'analyse spectrale du signal brut.

Cas d'un roulement normal sans défaut




Figure III.15.a Représentation temporel d'un signal acquis à partir d'un roulement à bille à l'état normal




Figure III.16.b Représentation fréquentiel d'un signal acquis à partir d'un roulement à bille à l'état normal




Figure III.17.c Représentation de l'énergie spectral d'un signal acquis à partir d'un roulement à bille à l'état normal

En observant les données dans le domaine temporel pour un roulement en bon état, l'amplitude du signal reste constante sans modulation notable, ce qui indique l'absence de défauts significatifs.

Le spectre fréquentiel d'un roulement en bon état montre principalement les fréquences de fonctionnement nominales sans pics anormaux.

Cas d'un défaut dans la partie intérieure




Figure III.18.a Représentation temporel d'un signal acquis à partir d'un roulement à bille avec un défaut interne




Figure III.19.b Représentation fréquentiel d'un signal acquis à partir d'un roulement à bille avec un défaut interne




Figure III.20.c Représentation de l'énergie spectral d'un signal acquis à partir d'un roulement à bille avec un défaut interne

En analysant les données dans le domaine temporel, nous avons remarqué que l'amplitude du signal brut est modulée à une certaine fréquence. La fréquence principale de cette modulation est d'environ 111 Hz (1/0,009 Hz). Il est connu que la fréquence à laquelle un élément roulant frappe un défaut local sur la bague intérieure, c'est-à-dire la BPFI, est de 118,875 Hz. Cette observation suggère une possible correspondance avec la fréquence de passage de la bille sur la bague intérieure (BPFI). Cette concordance indique que le roulement pourrait avoir un défaut localisé sur la bague intérieure.

Cas d'un défaut dans la partie extérieure




Figure III.21.a Représentation temporel d’un signal acquis à partir d’un roulement à bille avec un défaut externe




Figure III.22.b Représentation fréquentiel d’un signal acquis à partir d’un roulement à bille avec un défaut externe




Figure III.23.c Représentation de l'énergie spectral d'un signal acquis à partir d'un roulement à bille avec un défaut externe

En observant les données dans le domaine temporel, nous avons identifié une modulation de l'amplitude du signal brut à une certaine fréquence. La fréquence principale de cette modulation est de 83,9 Hz. Il est connu que la fréquence à laquelle un élément roulant frappe un défaut local sur la bague extérieure, c'est-à-dire la BPFO, est de 83,9 Hz. Cette observation correspond à la fréquence de passage de la bille sur la bague extérieure (BPFO). Cette concordance indique que le roulement pourrait avoir un défaut localisé sur la bague extérieure.

III.7. Transformée en ondelette continue (CWT)

Pour poursuivre l'analyse, il serait intéressant de visualiser les scalogrammes correspondant à un défaut sur la piste extérieure du roulement. Cela permettrait de comparer les signatures vibratoires des différents types de défauts et d'identifier plus précisément la nature du problème rencontré. L'analyse conjointe du signal temporel et du scalogramme est en effet une approche efficace pour diagnostiquer le type de défaut présent dans un roulement à billes, dans le cadre de la maintenance prédictive des machines.

Le prétraitement implique de convertir les signaux de vibration 1D en représentations temps-fréquence 2D (spectrogrammes). Ces signaux contiennent des informations cruciales sur l'état du roulement, mais leur interprétation directe peut être complexe et peu intuitive. Pour faciliter l'analyse

et améliorer la précision du diagnostic, ces signaux 1D sont transformés en spectrogrammes, qui sont des représentations temps-fréquence bidimensionnelles (2D).

Voici les étapes détaillées du processus de conversion :

- **Signal de vibration 1D** : On part d'un signal 1D, comme un signal de vibration enregistré par un capteur.
- **Transformée en ondelettes continue (CWT)** : On calcule la transformée en ondelettes continue (CWT) de ce signal. Cela consiste à décomposer le signal à l'aide d'ondes mères sur différentes échelles (fréquences) et positions (temps).
- **Représentation 2D** : Cette transformation produit une représentation 2D du signal dans le plan temps-fréquence, sous la forme des coefficients de la CWT.
- **Scalogramme** : À partir de ces coefficients, on peut tracer le scalogramme, qui est une représentation graphique de la puissance (ou énergie) des coefficients CWT dans le plan temps-fréquence.




Figure III.24.a Représentation temporelle et spectrogramme d'un signal acquis à partir d'un roulement à bille avec défaut interne




Figure III.25.b Représentation temporel et spectrogramme d'un signal acquis à partir d'un roulement à bille avec défaut externe




Figure III.26.c Représentation temporel et spectrogramme d'un signal acquis à partir d'un roulement à bille sans défaut

Dans le cadre de notre étude sur le diagnostic des défauts de roulements à billes, nous avons transformé les signaux de vibration 1D en représentations temps-fréquence 2D à l'aide de la transformée en ondelettes continue (CWT), produisant des scalogrammes. Voici un résumé des résultats obtenus et des observations basées sur les commentaires précédents :

Analyse des Signaux de Vibration :

- **Défaut de la Bague Intérieure :** Pour un signal de vibration avec une BPFI de 118,875 Hz, le scalogramme montre 12 pics distincts en 0,1 seconde. Ces pics correspondent aux impulsions dans le signal de vibration brut.
- **Défaut de la Bague Extérieure :** Le scalogramme montre 8 pics distincts en 0,1 seconde, alignés avec les fréquences de passage des billes. Cependant, les impulsions sont moins dominantes, ce qui réduit le contraste des pics par rapport au fond.
- **Condition Normale :** Le scalogramme ne montre pas de pics distincts dominants, indiquant une absence de défauts.

Différentiation des Défauts :

Le nombre de pics distincts dans le scalogramme est une caractéristique clé pour distinguer les défauts de la bague intérieure, les défauts de la bague extérieure, et les conditions normales.

La transformation des signaux de vibration en scalogrammes permet une visualisation claire et une identification précise des défauts des roulements. Les pics distincts dans le scalogramme sont des indicateurs fiables des différentes conditions de fonctionnement des roulements. Cette méthode offre une puissante capacité de diagnostic et de classification des défauts, essentielle pour la maintenance prédictive et la fiabilité des machines.

III.8. L'apprentissage par transfert :

III.8.1. Le Modèle pré-entraîné

Le modèle Squeeze Net a été entraîné sur plus d'un million d'images, lui conférant des représentations de caractéristiques riches. Le transfert d'apprentissage est couramment utilisé dans les applications d'apprentissage profond. Nous pouvons prendre un réseau neuronal multicouche pré-entraîné et l'utiliser comme point de départ pour une nouvelle tâche.


L'ajustement fin d'un réseau en utilisant le transfert d'apprentissage est généralement beaucoup plus rapide et plus facile que d'entraîner un réseau à partir de zéro avec des poids aléatoires initiaux. Nous pouvons transférer rapidement les caractéristiques apprises en utilisant un plus petit nombre d'images d'entraînement.

Voici les étapes clés pour ajuster le SqueezeNet pré-entraîné pour la classification sur notre ensemble de données de scalogrammes :

1. Charger le modèle SqueezeNet pré-entraîné
2. Geler les paramètres du réseau pré-entraîné pour empêcher leur mise à jour pendant l'ajustement fin
3. Modifier la couche finale pour correspondre au nombre de classes de notre problème de classification
4. Entraîner le modèle ajusté fin sur notre ensemble de données de scalogrammes
5. Sauvegarder le modèle ajusté fin

Cette approche nous permettra de tirer parti des représentations apprises précédemment et d'obtenir de meilleures performances avec un nombre réduit de données d'entraînement par rapport à un entraînement à partir de zéro.

III.8.2. Résultat de l'apprentissage pour la classification des défauts de roulements



Chapitre 3 :-----


Ce graphique représente la progression d'un modèle de deep learning au cours de 4 époques d'entraînement. Chaque époque comporte plusieurs itérations (164 au maximum).

On peut voir l'évolution de l'accuracy (précision) du modèle sur les données d'entraînement (en bleu) et de validation (en orange) au fil des époques. L'accuracy finale atteint 98% sur les données de validation.

Les informations en dessous du graphique indiquent que le modèle a été entraîné pendant 8 min 36 sec, avec 164 itérations au total, réparties sur 4 époques. La fréquence de validation est de 30 itérations.

Enfin, on peut voir que le modèle a été entraîné sur une seule ressource matérielle (CPU) avec un taux d'apprentissage constant de 0.0001.

Dans l'ensemble, ce graphique montre que le modèle a été entraîné avec succès et a atteint une précision de 100% sur les données de validation.



La matrice présente les résultats d'une classification prédictive, avec 3 classes possibles : "Inner Race Fault", "Normal" et "Outer Race Fault".

Les colonnes indiquent les classes prédites, tandis que les lignes représentent les classes réelles.

III.8.3. Analyse de la Matrice de Confusion et des Résultats de Classification

La matrice de confusion et les diagrammes de performance associés fournissent une évaluation détaillée de la performance du modèle de classification pour les défauts de roulements. Voici une analyse des informations visibles sur les figures fournies :

Inner Race Fault (Défaut de la Bague Intérieure) :

- Correctement Classés (True Positives) : 116 instances
- Classés comme Normaux (False Negatives) : 0 instance
- Classés comme Outer Race Fault (False Positives) : 27 instances

Normal Condition (Condition Normale) :

- Correctement Classés (True Positives) : 115 instances
- Classés comme Inner Race Fault (False Positives) : 0 instance
- Classés comme Outer Race Fault (False Positives) : 2 instances

Outer Race Fault (Défaut de la Bague Extérieure) :

- Correctement Classés (True Positives) : 206 instances
- Classés comme Inner Race Fault (False Positives) : 27 instances
- Classés comme Normaux (False Positives) : 0 instance

Diagrammes de Performance :

Accuracy par Classe :

- **Inner Race Fault :**
 - Précision : 81.1%
 - Erreur : 18.9%

➤ **Normal Condition :**

- Précision : 100.0%
- Erreur : 0.0%

➤ **Outer Race Fault :**

- Précision : 99.0%
- Erreur : 1.0%

Pourcentages de Prédiction par Classe :

➤ **Inner Race Fault :**

- Prédiction correcte : 100.0%

➤ **Normal Condition :**

- Prédiction correcte : 98.3%
- Classé comme Outer Race Fault : 1.7%

➤ **Outer Race Fault :**

- Prédiction correcte : 88.4%
- Classé comme Inner Race Fault : 11.6%

Précision Globale :

La matrice montre une précision élevée pour les trois classes, en particulier pour les défauts de la bague intérieure et les conditions normales.

Le modèle affiche une excellente précision pour la condition normale, sans aucune instance mal classée comme défaut de la bague intérieure ou extérieure.

Défauts de la Bague Intérieure vs. Défauts de la Bague Extérieure :

Les erreurs de classification les plus notables se produisent lorsque des défauts de la bague extérieure sont classés comme des défauts de la bague intérieure. Cela indique une certaine confusion entre ces deux types de défauts, qui pourrait être améliorée avec des données supplémentaires ou des méthodes de prétraitement avancées.

Conditions Normales :

Les conditions normales sont très bien différenciées des défauts, avec une précision de 100% pour la condition normale et une erreur minimale lorsqu'elles sont classées incorrectement.

III.9. CONCLUSION

Notre étude sur le diagnostic des défauts des roulements à billes en utilisant des méthodes de deep learning et des représentations temps-fréquence a montré des résultats prometteurs. En convertissant les signaux de vibration 1D en représentations 2D par le biais de la transformation en ondelettes continues (CWT), nous avons pu obtenir des scalogrammes riches en informations diagnostiques.

Les résultats de la classification, illustrés par la matrice de confusion, révèlent une haute précision globale, particulièrement remarquable pour les conditions normales et les défauts de la bague intérieure. Cependant, certaines confusions persistent entre les défauts de la bague intérieure et extérieure, suggérant des pistes d'amélioration.

Nos observations confirment que les scalogrammes peuvent être utilisés efficacement pour différencier les conditions de fonctionnement des roulements. La distinction claire entre les conditions normales et les défauts, ainsi que la précision élevée atteinte pour les différents types de défauts, démontrent le potentiel des techniques de deep learning pour la maintenance prédictive.



CONCLUSION GENERALE



CONCLUSION GENERALE

Cette étude met en lumière l'efficacité des techniques de deep learning associées aux représentations temps-fréquence pour le diagnostic des défauts des roulements à billes. En transformant les signaux de vibration 1D en scalogrammes via la transformation en ondelettes continues (CWT), nous avons pu exploiter des caractéristiques essentielles du signal pour la classification des états de fonctionnement des roulements.

Les résultats obtenus démontrent une capacité remarquable à distinguer entre les états normaux et les différents types de défauts (bague intérieure, bague extérieure) des roulements. Les scalogrammes ont montré des pics distincts correspondant aux fréquences de passage des défauts, fournissant ainsi une base solide pour la différenciation des conditions de fonctionnement. La matrice de confusion révèle une précision élevée, particulièrement pour les conditions normales et les défauts de la bague intérieure, bien que des améliorations soient nécessaires pour réduire les confusions entre les défauts de la bague intérieure et extérieure.

Les performances prometteuses de cette approche suggèrent une application potentielle pour la maintenance prédictive dans divers environnements industriels. En réduisant le risque de pannes imprévues et en optimisant les intervalles de maintenance, cette méthode peut contribuer à une augmentation significative de la fiabilité et de la rentabilité des opérations industrielles.

Les résultats de cette matrice de confusion et des diagrammes de performance fournissent des preuves solides pour l'utilisation de modèles de deep learning dans la classification des défauts de roulements. Les observations clés peuvent être intégrées dans notre étude pour améliorer la précision et la robustesse du modèle :

Amélioration de la Différenciation :

Étant donné la confusion entre les défauts de la bague intérieure et extérieure, il pourrait être bénéfique d'explorer des techniques supplémentaires de prétraitement ou d'utiliser des modèles plus sophistiqués pour améliorer la différenciation.

Validation des Méthodologies :

Les résultats confirment l'efficacité de la transformation en scalogrammes et de l'utilisation de réseaux de neurones pour le diagnostic des défauts.

Conclusion générale : -----

Applications Pratiques :

Les taux de précision élevés rendent cette approche viable pour des applications pratiques en maintenance prédictive, permettant une détection précoce et précise des défauts pour éviter des défaillances coûteuses.

En conclusion, l'intégration des techniques de deep learning avec les représentations temps-fréquence offre une solution robuste et efficace pour le diagnostic des défauts des roulements. Les prochaines étapes consisteront à améliorer la précision de la classification en explorant des modèles plus avancés et en adaptant l'approche à une gamme plus large de conditions de fonctionnement. Ces efforts permettront de renforcer encore davantage la fiabilité et l'applicabilité industrielle de cette méthode de diagnostic.

Cette approche ouvre la voie à des applications pratiques en maintenance prédictive dans divers environnements industriels. En permettant une détection précoce des défauts et en optimisant les intervalles de maintenance, cette méthode peut contribuer à accroître significativement la fiabilité et la rentabilité des opérations.

Bien que prometteurs, ces résultats soulignent la nécessité d'améliorer encore la précision de classification, notamment pour les défauts similaires. Les prochaines étapes consisteront à explorer des modèles de deep learning plus avancés et à adapter l'approche à une gamme élargie de conditions de fonctionnement. Ces efforts permettront de renforcer la robustesse et l'applicabilité industrielle de cette méthode de diagnostic des défauts de roulements à billes.

REFIRANCES
BIBLIOGRAPHIES

Chapitre : 1

- [1]. Faiz, J., G. Joksimović, and V. Ghorbanian, Fault diagnosis of induction motors. 2017: Institution of Engineering & Technology
- [2]. Albrecht, P., et al., Assessment of the reliability of motors in utility applications-Updated.IEEE Transactions on Energy conversion, 1986(1): p. 39-46
- [3]. Jang, J.-S., ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on
- [4]. AYAD .Haroune.(2020). *DIAGNOSTIC DES DEFAILLANCES DE LA MACHINE ASYNCHRONE* .(thèse de master, UNIVERSITÉ BADJI MOKHTAR -ANNABA).
- [5]. Sahraoui, M., et al., Detection of inter-turn short-circuit in induction motors using Park–Hilbert method. International Journal of System Assurance Engineering and Management, 2014. 5(3): p. 337-351.
- [6].ZERROUK Ahmed.(2013).*Diagnostic des défauts de cassure de barres rotoriques dans la machine asynchrone triphasée (thèse master,Université Mohamed Khider Biskra) .*
- [7].B.Bayala" ,Formation continue - techniciens supérieurs – ingénieurs électrotechniciens la machine asynchrone", Edition Revue 2010.
- [8]. B. ABDELAZIZ, Diagnostic des machines asynchrones. 2018.
- [9].Hakima CHERIF.(2021). *Détection des défauts dans la machine à induction par des techniques avancées(thèse de la Doctorat en sciences,Université Mohamed Khider – Biskra).*
- [10] . S. Bazine, J. Trigeassou, «Les défauts des machines électriques et leur diagnostic » cours, ECL, Lyon, 2003.
- [11].SAHOUI Mohamed & BENACHOUR Ouassim .(2018).*Modélisation et diagnostic de la cassure des barres rotoriques d'une machine asynchrone(thèse de mastre,Université SAAD DAHLAB de BLIDA).*
- [12] (G. DIDIER, Modélisation et diagnostic de la machine asynchrone en presence de defaillances. 2004.)
- [13].AL-MUSHIAA Mohammed Mansoor et AOUKLI Zakaria.(2022).Technique de diagnostic des défauts dans les systèmes électriques par les réseaux de neurones (machine asynchrone).(Thèse de master,Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj).
- [14]** Saoudi A., Decha M., 2018. " *La transformée en ondelettes et l'analyse en enveloppe pour le diagnostic des défauts dans les roulements à bille*". *Thèse de Master, Université Larbi Tebessi, Tebessa.*
- [15]** Rabhi M., Zouaoui N., 2013. " *Diagnostics de défauts de roulements par analyse vibratoire au sein de la briqueterie de REMILA*". *Thèse de Master, Université Abderahmane MIRA, Bejaia.*
- [16].Khelfaoui Nabil.(2019).DIAGNOSTIC DES DEFAUTS DE MACHINES PAR L'ANALYSE DES SIGNAUX .(Thèse de master,UNIVERSITÉ BADJI MOKHTAR- ANNABA).

- [17] (G. DIDIER, Modélisation et diagnostic de la machine asynchrone en presence de defaillances. 2004.)
- [18] (B.Mimi "etude des machines electriques par cao "thèse de doctorat ,université mentouri constantine 2009.)
- [19] .B. Vaseghi, "contribution a l'etude des machines electriques en presence de défaut entrespires," these de doctorat, green - groupe de recherche en electrotechnique et electronique de nancy, nancy universite - institut national polytechnique de lorraine, 2009.
- [20] YAHIA, K., Contribution au Diagnostic de la Machine Asynchrone Triphasée par une Approche Signal. 2012, Thèse de doctorat, Université Mohamed Khider-Biskra
- [21] (MEZROUA Mohammed Ali, "Présentation Des Différentes Défaillances Du Moteur Asynchrone a Cage", Publié le 26/08/2009 à 00:07 par mezrouamed ali).
- [22] Mabrouk ,A ,contribution au diagnostic de la machine asynchrone en presence de variation de charge 2017 thèse de doctorat ,université mohamed khider –biskra.

Chapitre : 2

- [23] S. BENZAHIOUL, Surveillance et Diagnostic de Défauts Dans les Systèmes Electriques, SKIKDA: Thèse de Doctorat, Université 20 AOUT 1955 SKIKDA, 2018, p. 43.
- [24] (G. Didier « Modélisation et diagnostic de la machine asynchrone en présence de défaillances ».Thèse de doctorat, Université Henri Poincaré, Nancy 1,2004.)
- [25] (B. ABDELAZIZ, Diagnostic des machines asynchrones. 2018)
- [26] .babou sonia et keciri fatima.(2018).diagnostic des moteurs a induction par utilisation des capteurs de vibration (thèse de mastre,université abderrahmane mira bejaia).
- [27] Shaiokai Wang, William Prentney Ana-Maria Popesai, TanzeenChaudhury, and MattaiPhilipose, common sense based joint traininghumanactivityrecognizers » : In Proceedings of the 20 Intenational Joint Conference on Artificial Intelligence.pp.2237.2242.2007.
- [28] .Ziani, R. (2018). Contribution à l'analyse et à la classification automatique des défauts mécaniques (Doctoral dissertation).
- [29]. Ilyes, K. (2014). Diagnostic des machines tournantes par les techniques de l'intelligence artificielle. (Doctoral dissertation, Thèse de doctorat, Université de Badji Mokhtar, Annaba, Algérie)
- [30] . Y. Khaled, "Contribution au Diagnostic de la Machine Asynchrone Triphasée par une Approche signal ", Thèse de doctorat, Université Mohamed Khider – Biskra 201
- [31] .www.tektronix.com/scopes/analyse-spectrale-:analyse-du-spectre-d'un-signal.

- [32].B. Boashash. The Relationship Between Instantaneous Frequency and Time- Frequency Representations. IEEE Transactions on signal processing, pages1458-1462, 1993.
- [33].B. Ristic. Kernel design for Time-Frequency signals analysis using the radon transform.IEEE Transactions on signal processing, pages 1996-2008, May 1993
- [34]]. Subrata, K., et al., Induction Motor Fault Diagnosis-Approach through Current Signature Analysis. 2016, Singapore: Springer.
- [35].abbad, aicha khedim , laid (2023).intitulé du sujet intelligence artificielle dans les archives.(thèse de master,université abdelhamid ibn badis mostaganem).
- [36]. « réseau de neurones artificiels ([http s://vitrinelinguistique.oqlf.gouv.qc.c a/redirection/ficheuid/8386038](http://vitrinelinguistique.oqlf.gouv.qc.ca/redirection/ficheuid/8386038)) [arc hive] », Grand Dictionnaire terminologique, Office québécois de la langue française (consulté le 28 janvier 2020)
- [37] F. MEDJILI, Modélisation par Réseaux de Neurones Artificiels (RNA) et commande Prédictive non linéaire d'une station de production d'eau froide, ANNABA: Mémoire de magister, UNIVERSITE BADJI MOKHTAR, 2010.
- [38] C. TOUZET, les reseaux de neurones artificiels, introduction au connexionnisme : cours, exercices et travaux pratiques, hal, 1992.
- [39] Andrei Doncescu, "Les réseaux de neurones artificiels", support de cours.
- [40] y. lecun, l. bottou, y. bengio & p. haffner. gradient-based learning applied to document recognition. in proceedings of the ieee, pages 2278–2324, 1998.
- [41] r. girshick, j. donahue, t. darrell & j. malik. rich feature hierarchies for accurate object detection and semantic segmentation. proceedings of the ieee computer society conference on c
- [42] https://penseeartificielle.fr/focus-reseau-neuronesconvolutifs/#4_Le_flattening_ou_mise_a_plat
- [43] Krizhevsky, Sutskever, I. & Hinton, G., 2012. ImageNet Classification with Deep Convolutional Neural networks. s.l.:In Proceedings of NIPS 2012.
- [44] Le Cun, Y., 1989. Generaliation and Network Design Strategies , s.l.: s.n.omputer Vision and Pattern Recognition, 11 2013.
- [45] Houacine Noura, Khelifa Nadia, Classification des textures par les réseaux de neurones convolutif, thèse MASTER ACADEMIQUE, Domaine : Sciences et Technologies, Filière : Génie électrique, Spécialité : Commande des systèmes, faculte du genie electrique et d'informatique departement d'automatique, universite mouloud mammeri de tizi-ouzou, 27/09/2018.

[46] Phil Kim; Matleb Deep learning with machine learning, Neural networks and

[47] P. Paquet, «L'utilisation des réseaux de neurones artificiels en finance».

Chapitre : 3

[48] Rai, A., & Mohanty, A. R. (2007). Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform. *Mechanical Systems and Signal Processing*, 21(6), 2607-2615.