

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي

UNIVERSITÉ BADJI MOKHTAR - ANNABA
BADJI MOKHTAR – ANNABA UNIVERSITY



جامعة باجي مختار – عنابة

Faculté : de TECHNOLOGIE
Département : Electronique
Domaine : Sciences et Techniques
Filière : .Automatique
Spécialité : Automatique et système

Mémoire

Présenté en vue de l'obtention du Diplôme de Master

Thème:

Diagnosics des Systèmes de Roulements basés sur les machines learning

Présenté par :LADJIMI ILYES et REDJIMI SAOUSSEN

Encadrant : *SAADI MOHAMED NACER* M.C.B *UNIVERSITÉ Badj Mokhtar*
– *Annaba*

Jury de Soutenance :

LAFIFI Mourad	M.C.A	Université	Président
<i>SAADI MOHAMED NACER</i>	M.C.B	Université	Encadrant
BOULEBTATCHE Brahim	M.C.B	Université	Examineur

Année Universitaire : 2021/2022

REMERCIEMENTS

Avant toute chose, on remercie Dieu le tout puissant de m' avoir donné le courage

Tous mes remerciements à Monsieur SAADI MOHAMED NACER

De m' avoir encadré et en particulier pour son soutien, sa gentillesse, ses encouragements, ses conseils pendant la période de la réalisation de ce travail.

Nos sincères remerciements aux Messieurs les membres de jury qui nous ont fait l'honneur en acceptant d'examiner ce travail.

Mes salutations aux enseignants du département d'électronique qui ont contribué à notre formation.

Mes remerciements aussi à mes collègues au travail de m' avoir encouragé de continuer mes études.

*Enfin, un remerciement spécial aux étudiants de la 2eme année Master **2021/2022** du département d'électronique plus spécialement de l'option automatique et système.*

DÉDICACE

*Je dédie ce modeste travail à ceux qui sont le soleil de ma vie et
la lune de mes nuits mes plus chers parents*

A mes frères

A ma soeur

A mes grands parents

A toute la famille

Et à tous ce qui m'ont encouragé

Pour l'accomplissement de ce travail.

Ladjimi ilyes

SOMMAIRE

Introduction générale.....	1
----------------------------	---

Chapitre I : les machines tournantes, principales défaillances et techniques de surveillance

1- Introduction.....	4
2- généralités sur la maintenance et le diagnostic industriels	4
2.1- concepts et terminologies.....	4
2.1.1- défaut.....	4
2.1.2- dégradation.....	4
2.1.3- défaillance	4
2.1.4- la panne	5
3- maintenance industrielle	5
3.1- maintenance préventive	6
3.1.1- maintenance systématique	6
3.1.2- maintenance prévisionnelle.....	7
3.1.3- maintenance conditionnelle	7
3.2- maintenance corrective	7
3.2.1- maintenance palliative	8
3.2.2- maintenance curative.....	8
4- diagnostic industriel	7
4.1- les différentes méthodes de diagnostic	9
4.1.1- les méthodes internes	10
4.1.2- les méthodes externes	10
5- les machines tournantes	11
5.1- défauts roulement de roulement des machines tournantes.....	12
6- conclusion	16

Chapitre II : les méthodes de l'intelligence artificielle

II.1- ensemble décomposition en mode empirique (EEMD)	18
II.2- introduction à l'intelligence artificielle	18
II.2.1- introduction	18
II.2.2.1- l'apprentissage profond (DL)	20
II.2.2.2- réseaux de neurones à convolution (CNN)	20
II.3- architecture des réseaux de neurones convolutifs	20
II.4- conclusion.....	24

Chapitre III : application au diagnostic des défauts de roulements.

III.1- introduction	26
III.2- méthodologie de diagnostic proposée	26
III.3.1- application de la méthode proposée au banc d'essai CWRU.....	27
III.3.1.1- banc d'essai CWRU	27
III.3.1.1- prétraitement des données	29
III.4- traitement des signaux vibratoires à base de L'EEMD.....	30
III.4.2- sélection d'IMFS.....	31
III.5- application des réseaux CNN.....	35
III.5- Conclusion	38
Conclusion générale	38

LISTE DES FIGURES

Figure 1 : Cas de figure conduisant à la défaillance.....	5
Figure 2 : Différents types de maintenance.....	6
Figure 3 : Structure de la maintenance Conditionnelle	7
Figure 4 : Les différentes étapes du diagnostic industriel	8
Figure 5 : Classification des méthodes de diagnostic	9
Figure 6 : Eléments d'une machine tournante.....	14
Figure 7 : Différentes composantes d'un roulement	15
Figure 8 : Défauts des roulements à billes. (a) sur la bague interne ; (b) sur la cage ; (c) sur une bille et (d) sur la bague externe	18
Figure 9 : L'organigramme de la méthode EEMD	19
Figure 10 : Intelligence artificielle, machine learning e, deep learning et convolutional network.....	21
Figure 11 : Architecture des réseaux de neurones convolutifs.....	27
Figure 12 : Organigramme de la méthode proposée pour le diagnostic de.....	28
Figure 13 : Banc d'essai CWRU	29
Figure 14 : Les signaux de vibration sous charge de 0 h	30
Figure 15 : Segmentation imbriquée des signaux de vibration	31
Figure 16 : Signal vibratoire et ses 9 premiers IMFs sous le défaut de la cage interne (à une charge de 0 hp et une vitesse égale à 1797 tr/min	32
Figure 17 : Nouveaux signaux vibratoires reconstruits sous la condition de charge 1 hp	34
Figure 18 : Processus de conversion du signal 1D en image vibratoire 2D.....	34
Figure 19 : Matrice de confusion	37
Figure 20 :(a) Précision de l'entraînement et de la validation, (b) Perte de l'entraînement et de la validation of novel BiLSTM method	38

Liste des Tableaux

Tableau I : Les fonctions d'activation les plus utilisées dans les réseaux CNN.....	22
Tableau II: Les différentes classes sélectionnées de la base des données de CWRU. (ORF : défaut de la cage externe, IRF : défaut de la cage interne, BAF : défaut de la bille).....	28
Tableau III: Arrangement des ensembles d'images vibratoires de CWRU après les processus de reconstruction de signaux et de conversion 1D à 2D	35
Tableau V: Description des hyper-paramètres du modèle CNN de référence	36

RÉSUMÉ

Ce travail s'inscrit dans la thématique de la surveillance et diagnostic des défauts des machines tournantes et plus particulièrement les défauts de roulements. L'objectif de ce travail est de mener une étude sur un ensemble de signaux vibratoires qui décrivent les états de défaillance des roulements dans les machines tournantes. On a utilisé deux base de données dans notre travail à savoir : la base de données de la Case Western Reserve University ainsi que le banc d'essai fourni par l'Unité de Recherche en Matériaux Avancés (URMA / CRTI). L'analyse se base sur l'application de la méthode EEMD combinée avec un réseau de neurone convolutif (CNN) qui s'avérée adéquate pour le diagnostic des défauts des roulements.

Mots clés: Traitement du signal, machine tournante, défauts de roulements, EEMD,IMFs ,CNN.

ABSTRACT

This work is part of the theme of monitoring and diagnosis of faults in rotating machines and more particularly bearing faults. The objective of this work is to conduct a study on a set of vibration signals that describe the failure states of bearings in rotating machines. We used two databases in our work, namely: the Case Western Reserve University database and the test bench provided by the Advanced Materials Research Unit (URMA / CRTI). The analysis is based on the application of the EEMD method combined with a convolutional neural network (CNN) which has proven to be adequate for the diagnosis of bearing faults.

Keywords: Signal processing, rotating machine, bearing faults, EEMD ,IMFs, CNN..

INTRODUCTION GENERALE

La machine tournante est un élément central du processus de fabrication où sa santé et sa disponibilité ont leurs effets directs sur les calendriers de production, de même sur la qualité et les coûts de production. Des pannes imprévues sur la machine peuvent entraîner des temps d'arrêt imprévus, des accidents et même des blessures. En réalité, les composants de la machine tournante, y compris les engrenages, les roulements, les boîtes de vitesse, etc., sont engagés à fonctionner efficacement afin de maintenir un état stable et sain de la machine tournante. Pour cette raison, la maintenance est effectuée afin de s'assurer que ces machines restent en bon état, en réparant, modifiant ou remplaçant ces composants.

La surveillance des machines tournantes s'appuie depuis des décennies sur l'analyse vibratoire. Pour but de détecter les éventuels pannes et à suivre leurs évolutions afin de planifier une intervention. Le défaut apparaît sous la forme d'une signature dans le signal de vibration. Dans ce domaine, le traitement du signal est une méthode très utilisée pour effectuer le diagnostic des défauts, parce qu'il cherche à déterminer directement l'état du système.

Un diagnostic de défaillances d'un système industriel réalisé avec efficacité et permettant de détecter d'une façon fiable les anomalies des systèmes améliore d'une façon conséquente les performances et la productivité des systèmes industriels. Le diagnostic peut être effectué selon deux méthodes principales : avec ou sans connaissance préalable. La première technique cherche à modéliser les systèmes tandis que la seconde utilise les techniques de l'intelligence artificielle.

Les méthodes sans connaissance préalable présentent plusieurs avantages, en particulier le fait qu'il n'est pas nécessaire d'utiliser le modèle du système à diagnostiquer. Cette catégorie comprend les méthodes basées sur la reconnaissance de formes, les systèmes experts et les réseaux de neurones. La reconnaissance de formes consiste à évaluer la ressemblance entre le vecteur de paramètres observés et le vecteur des paramètres de référence. Elle regroupe l'ensemble des méthodes permettant de classer les défauts en plusieurs catégories dans le cas de la détection des défauts industriels.

La méthode originale proposée basée sur la combinaison de l'EEMD et le CNN. Ces sections fournissent des détails de diverses expériences qui ont été menées afin d'évaluer la nouvelle méthode proposée et démontrer sa validité dans le diagnostic des défauts de roulements avec

un large nombre de défaut de différents diamètres et de sévérités en utilisant des signaux vibratoires acquis à partir du banc d'essai de CWR

Par ailleurs, ce mémoire présente une étude sur la détection et la classification des défauts de roulements dans les machines tournantes. L'étude qui suit est organisée autour de trois chapitres. On commencera par présenter au chapitre I, des généralités sur les défaillances et les techniques de surveillance dans les machines tournantes et maintenance de système. Les approches de diagnostic basé sur les méthodes de l'intelligence artificielle seront examinées au chapitre II.

Le chapitre III est destiné l'explication de la méthode proposé pour le diagnostic des défauts de roulements. Enfin, on présentera au dernier chapitre les résultats expérimentaux obtenus par la méthode EEMD_CNN pour le diagnostic des défauts de roulements.

Nous termineront ce travail par une conclusion et les perspectives qui sous-tendent notre travail ainsi que les horizons de recherches futures dans ce domaine.

**CHAPITRE I : LES MACHINES
TOURNANTES, PRINCIPALES
DÉFAILLANCES ET TECHNIQUES DE
SURVEILLANCE**

1 Introduction :

La maintenance industrielle est un ensemble d'opérations ayant pour but d'assurer le fonctionnement correct et continu d'appareillage conformément aux normes exigées par l'utilisateur.

L'approche moderne consiste à mesurer l'état d'une machine tout au long de son fonctionnement afin de n'intervenir que lorsque les paramètres obtenus en imposent la nécessité. Cette méthode est appelée maintenance conditionnelle.

2 Généralités sur la maintenance et le diagnostic industriels

2.1 Concepts et terminologies:

La maintenance industrielle a pour but de vérifier l'état de fonctionnement machine, puis apporter les corrections nécessaires en cas de panne. Une machine, comme tout autre équipement, peut être en bon état de fonctionnement ou problèmes actuels, qui peuvent être de nature différente. Si nous classés par gravité, nous pouvons les définir comme suit :

2.1.1 Défaut :

La notion de panne est importante dans le suivi des opérations et de la maintenance processus industriel. Elle est déterminée par les caractéristiques constatées sur l'appareil et Caractéristiques de référence lorsqu'elles dépassent la spécification autorisée.

2.1.2 Dégradation :

Une rétrogradation représente une baisse de performance pour l'une des fonctionnalités fournies à travers l'appareil. Si la performance tombe en dessous du seuil défini dans le cahier des charges pour de tels équipements, il ne s'agit plus d'un problème de dégradation, mais de

2.1.3 Défaillance :

On dit défaillance quand un défaut apparaît, c'est un écart entre ce qui devrait être et ce qui est. Pour mettre en place une politique de maintenance efficace, il importe de comprendre les phénomènes de dégradation et de défaillance de matériels.

On peut classer les défaillances selon leur degré de sévérité par :

1. Défaillance absorbable : pouvant être ignorée dans un premier temps.

- Défaillance significative : nécessitant un processus de traitement

- Défaillance critique : nécessitant une intervention d'urgence.

On peut aussi distinguer trois types de défaillances classées par leurs apparitions dans le temps :

-Défaillance progressive : La défaillance se développe au fur et à mesure jusqu'à l'arrêt définitif du système.

-Défaillance aléatoire : Dans ce cas la défaillance se présente d'une façon aléatoire, c'est-à-dire, le système s'arrête et reprend son fonctionnement plusieurs fois pendant une période de temps avant sa défaillance complète.

- Défaillance soudaine : C'est le basculement soudain et définitif d'un système au-dessous du seuil du fonctionnement normal.




Figure I.1: Cas de figure conduisant à la défaillance

2.1.4 La panne :

Une panne est une interruption permanente de la capacité du système ou d'un dispositif à réaliser une fonction requise.

3 Maintenance industrielle :

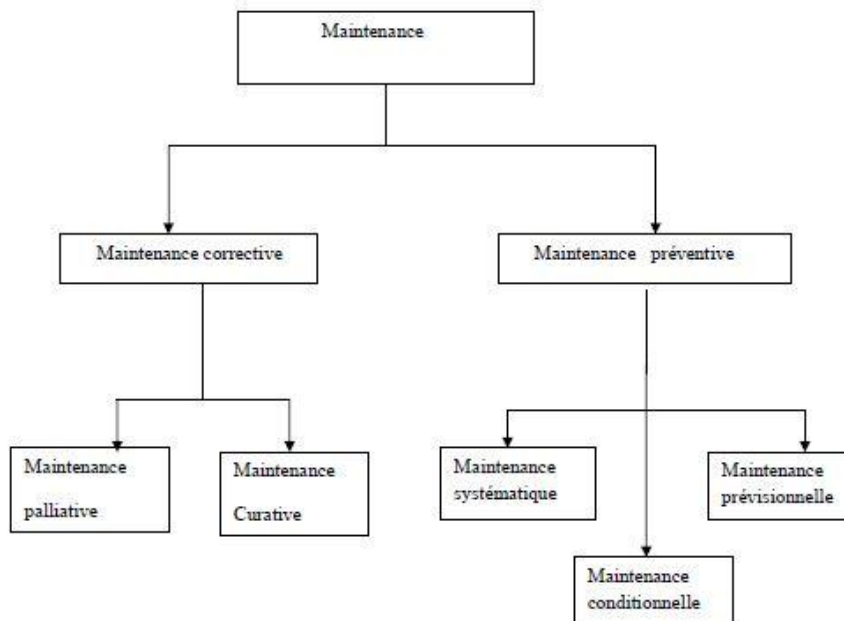
La maintenance est l'ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise.

En pratique, on parle d'une surveillance de l'état des machines et ceci pendant les phases de démarrage, de fonctionnement et d'arrêt. La connaissance et le traitement de ces données

permettent de déceler les anomalies de fonctionnement et de décider les interventions nécessaires.

Cette méthode présente donc l'avantage d'éviter la surprise et de permettre généralement la planification de l'intervention ainsi de limiter au strict minimum les arrêts des machines.

- La maintenance conditionnelle aujourd'hui, fait l'objet d'une demande croissante dans



un grand nombre d'applications industrielles.

Figure I.3 : Différents types de maintenance.

3.1 Maintenance préventive :

Maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien

3.1.1 .Maintenance systématique :

Maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage mais sans contrôle préalable de l'état du bien

3.1.2 Maintenance prévisionnelle :

La maintenance préventive prévisionnelle est liée à la dégradation des composants et son évolution dans le temps. Son rôle consiste à retarder la dégradation et à planifier des interventions.

3.1.3 Maintenance conditionnelle :

Maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent. La surveillance du fonctionnement et des paramètres peut être exécutée selon un calendrier, ou à la demande, ou de façon continue

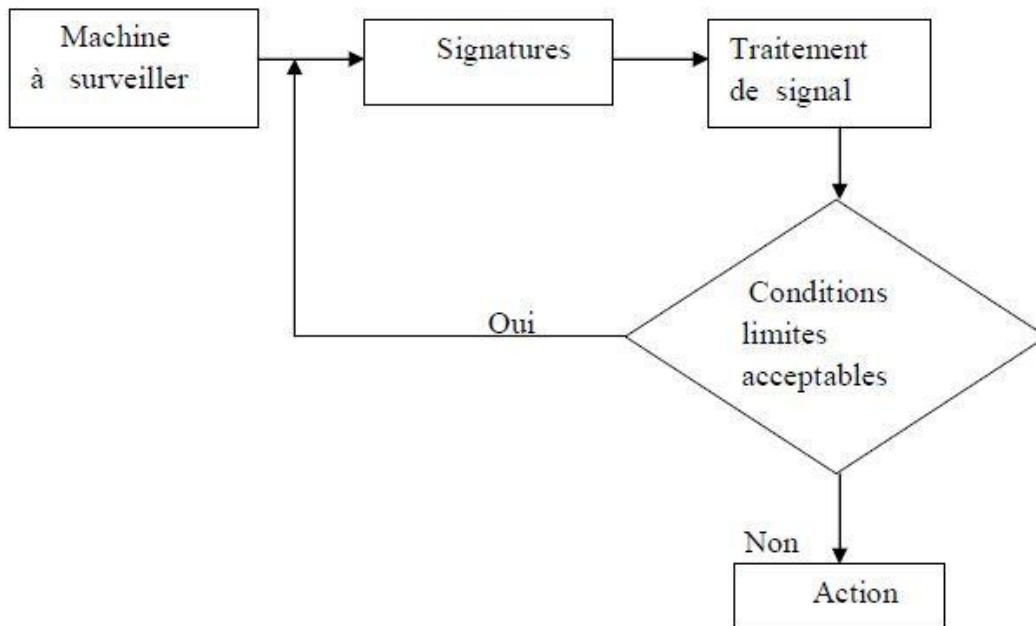


Figure I .3: Structure de la maintenance Conditionnelle

3.2 Maintenance corrective :

Maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise

3.2.1 Maintenance palliative :

L'action de dépannage permet de remettre provisoirement le matériel à un niveau de performance acceptable mais inférieur au niveau optimal.

3.2.2 Maintenance curative :

L'intervention qui suit la défaillance permet le rétablissement du niveau de performance optimal du matériel.

4 Diagnostic industriel :

Le diagnostic est l'identification des causes possibles de défaillance

Utiliser un raisonnement logique basé sur un ensemble d'informations

Vérifier, inspecter ou test.

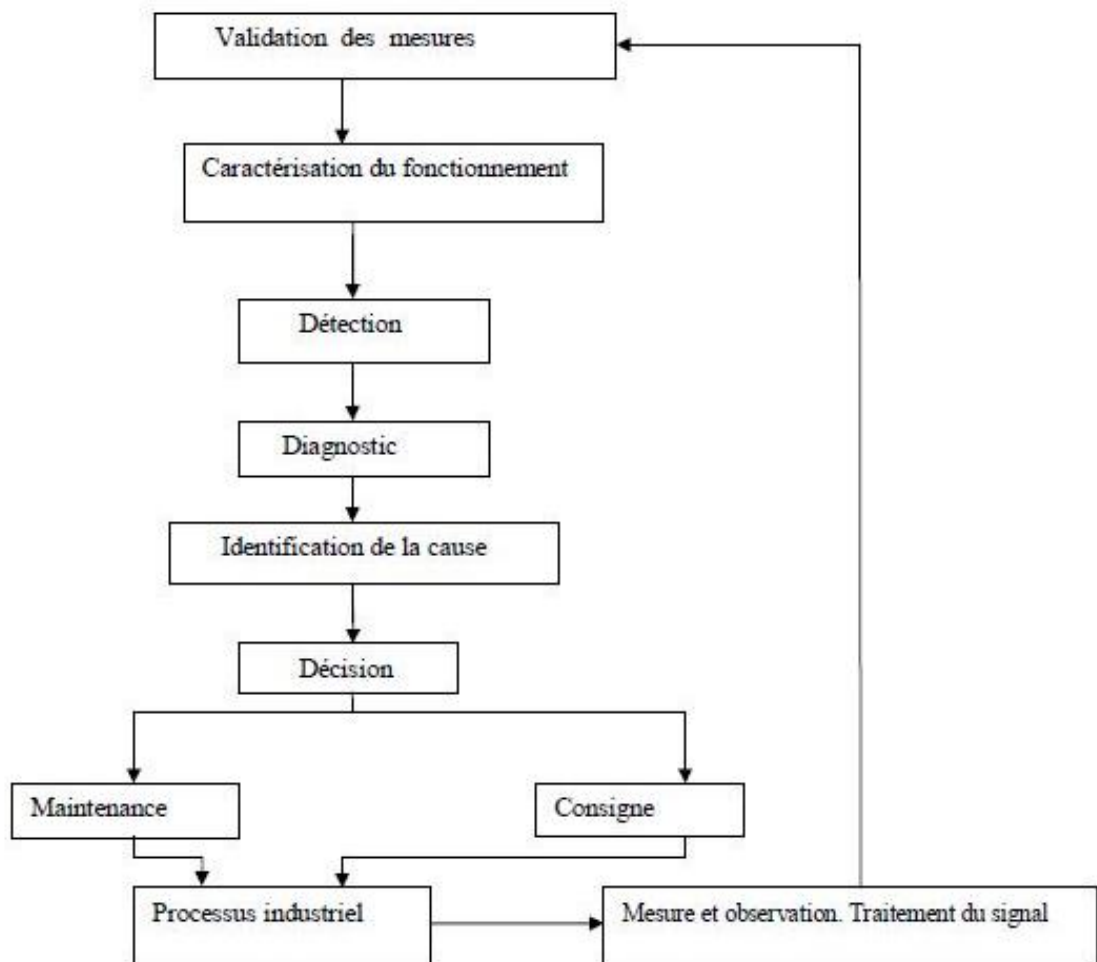


Figure I.4: Les différentes étapes du diagnostic industriel

La première étape en diagnostic industriel consiste à extraire des informations nécessaires à la mise en forme des caractéristiques associées aux fonctionnements normaux et anormaux. Ces mesures sont réalisées par un personnel compétent avec des moyens de mesure (capteurs), afin de détecter un défaut et identifier ses causes.

La décision consiste à fixer des seuils d'alarme sur la valeur de l'écart mesuré entre la signature nominale (théorique) et celle observée.

La maintenance et la consigne (changements) interviennent pour corriger les anomalies existantes à l'aide d'un processus industriel. Pour s'assurer de l'efficacité de ce processus mis en œuvre, des mesures doivent être réalisées et traitées.

4.1 Les différentes méthodes de diagnostic :

Les méthodes de diagnostic peuvent, aussi, être divisées en deux grandes familles :

- Les méthodes internes.
- Les méthodes externes.

Ce qui différencie ces deux méthodes est le fait de disposer, au moins, d'un modèle mathématique décrivant le système.

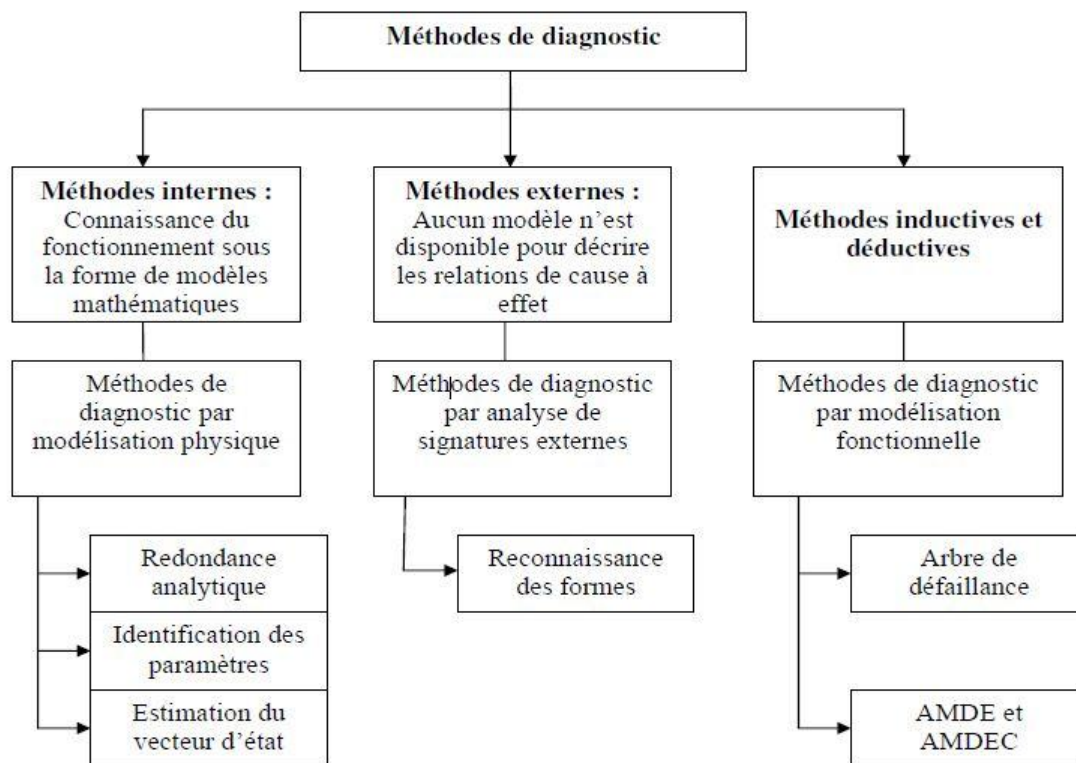


Figure I.5– Classification des méthodes de diagnostic

4.1.1 Les méthodes internes :

Ces méthodes sont basées sur des modèles physiques ou comportementaux (modèles Mathématiques) vérification expérimentale par des techniques d'identification d'installation.

- La méthode du modèle :

L'objectif est de comparer le comportement prédit produit par le modèle

Représente (normalement fonctionnel) le comportement réel observé pour détecter

Incohérence et déduire la cause de la panne (défaut d'instrumentation

« Capteurs ou actionneurs » ou défaillances de processus « commandes, systèmes d'information, etc. »).

- La méthode d'identification des paramètres ou d'estimation du vecteur d'état :

Son principe repose sur la surveillance de l'évolution de certains paramètres physiques lors du fonctionnement d'un processus et qui ne sont pas mesurables directement.

4.1.2 Les méthodes externes :

Ces méthodes supposent qu'aucun modèle n'est disponible pour décrire cause et effet. La seule connaissance est l'expertise humaine basée sur un support solide retour d'information. Dans cette catégorie on retrouve tous les

Intelligence artificielle et/ou méthodes probabilistes.

Dans ce cas, nous pouvons citer :

- Les réseaux de neurones artificiels :

Les réseaux de neurones artificiels et leur caractère associatif, leur confère la possibilité de reconnaître des données incomplètes et bruitées.

On distingue plusieurs types de signatures :

- signatures vibratoires : adaptées à la détection des anomalies affectant des ensembles mécaniques tournants,
- signatures acoustiques : d'identification des fuites apparaissant dans des matériels sous pression.

5 Les machines tournantes

Une machine est un ensemble des pièces mécaniques, hydrauliques ou électriques concourant à exercer une ou plusieurs fonctions données et, en particulier, l'application d'une force modulée ou non, destinée à vaincre une résistance ou à assurer un mouvement avec ou sans transmission de force.

Les machines tournantes sont des systèmes dans lesquels on peut distinguer : un rotor, une structure, des liaisons [1]. la figure suivante montre un exemple d'une machine tournante

- Le rotor :

Le rotor est une structure dont les éléments tournent autour d'une ligne de rotation définie en fonction de l'état mécanique de ce dernier, en général distincte d'un axe (ligne droite). Le rotor fabriqué avec plusieurs matériaux (acier, cuivre, bois, plastique...) réalise une fonction bien définie : (manipulation fluide, de solide, parcours dans un champ électromagnétique, ...etc.).

- La structure :

La structure non rotative comprend les éléments essentiels suivants :

- Les coussinets : ils sont de faible dimension au droit des tourillons des rotors. Des bagues peuvent être substituées aux coussinets (roulements).

- Les paliers : relient les coussinets (bagues) au stator.

- Le stator : (enveloppe de la machine) : il contient les éléments essentiels, à savoir les circuits magnétiques dans les machines électriques, les ailettes pour les turbomachines.

- Le massif : il peut prendre des formes beaucoup plus variées que celles des systèmes terrestres dont les massifs sont liés au radier.

- Le radier : c'est un élément spécifique au système. Il assure la liaison entre le massif et le sol et a pour mission de diminuer les pressions exercées au sol dans des limites acceptables. C'est par lui que les séismes perturbent les machines tournantes.

-Les liaisons

Le rotor est lié à la structure non rotative par des liaisons qui assurent le guidage des rotors.

Les liaisons sont classées dans trois ensembles : à fluide, à roulements, magnétique

- Les liaisons fluides : ce sont les paliers lisses, en fait c'est l'huile de lubrification qui constitue la liaison entre le rotor et le coussinet. Pendant le fonctionnement, des rotors montés sur des paliers lisses, c'est à l'huile de lubrification (de grande viscosité) d'apporter plus d'amortissement indispensable au fonctionnement tranquille des machines tournantes.

- Les liaisons à roulements : la bague intérieure est montée sur le rotor et la bague extérieure dans le palier, la liaison s'organise par un épilâmes entre les billes et les bagues figure (I.2).

5.1 Défauts de roulement des machines tournantes :

Une étude statistique effectuée par Bonnett en 2008, a dévoilé que 69% de défaillances affectant les moteurs asynchrones à grande puissance, sont des défauts des roulements. Cela signifie que les roulements sont les organes les plus importants et les plus fragiles des machines tournantes.

Ces composants sont conçus pour assurer plusieurs fonctions parmi lesquelles : assurer la liaison mobile en rotation entre deux surfaces avec un minimum de frottement et en supportant des différentes charges radiales ou axiales ; corriger les défauts d'alignement en assurant un positionnement précis de l'arbre

Ces composants sont conçus pour assurer plusieurs fonctions parmi lesquelles : assurer la liaison mobile en rotation entre deux surfaces avec un minimum de frottement et en supportant des différentes charges radiales ou axiales ; corriger les défauts d'alignement en assurant un positionnement précis de l'arbre.

Un roulement est un élément mécanique qui s'interpose entre deux parties d'une machine dont l'une est tournante et l'autre est fixe. Le roulement a été utilisé depuis longtemps, mais sous une forme simpliste

Un roulement est composé des bagues interne et externe, d'une cage et de billes (Figure I.4). Des vibrations sont produites quand les conditions de roulement ne sont pas parfaites, et qui peuvent être induites par des dommages extérieurs ou des forces agissant sur les roulements (déséquilibre, désalignement, etc.).

Les dommages surfaciques sont dus à la fatigue en présence des efforts élevés aux points de contact. Plus spécifiquement, les vibrations sont produites par les impacts qui se produisent quand la surface d'une composante heurte une autre surface.




Figure I-6 : Différentes composantes d'un roulement

Les roulements sont parmi les composants les plus sollicités des machines et représentent une source de panne fréquente. Comme le roulement tourne, les impulsions résultantes se produisent périodiquement. Les fréquences de ces impulsions sont uniquement déterminées par l'emplacement où le défaut se produit, soit sur la bague interne, sur la bague externe, ou sur les éléments de billes. La géométrie du roulement est aussi un paramètre très important.

Les défauts que l'on peut y rencontrer sont les suivants : écaillage, grippage, corrosion (qui entraîne l'écaillage), faux effet Brinell, etc... Tous ces défauts se traduisent par une perte de métal et provoquent des chocs répétés des billes sur la cage de roulement




(a)



(b)



(c)



(d)

Figure I.7 Défauts des roulements à billes. (a) sur la bague interne ; (b) sur la cage ; (c) sur une bille et (d) sur la bague externe

On peut distinguer plusieurs avaries affectant les roulements, et causées par quatre grandes familles de causes, qu'on peut les répertoriées comme suit :

-Dégradations liées à une mauvaise lubrification, couvrant 36% des cas : quel que soit un manque ou un excès de lubrifiant qui peut produire une augmentation de la température du roulement, conduisant à une rupture des bagues, écaillage, grippage et détérioration des cages.

-Dégradations liées à des contraintes mécaniques excessives, couvrant 34% des cas : comme la vitesse, les charges radiales et axiales exercées sur les points de contact entre les éléments roulants et les bagues, pouvant causer un écaillage, détérioration des cages et grippage.

Dégradations liées au montage incorrect, couvrant 16% des cas : comme le défaut d'alignement, traces de coups, empreintes des corps roulants, corrosion par contact et certaines détériorations de cages.

Dégradations liées au milieu industriel difficile, couvrant 14% des cas : comme l'environnement humide et la présence des acides causant la corrosion du roulement, la présence des polluants de nature abrasive comme la poussière et le sable, qui contaminent le lubrifiant, dégradent la surface de roulement et causant son usure.

6 Conclusion :

Dans ce présent chapitre nous avons défini les notions de base de la maintenance industrielle, en particulier la maintenance conditionnelle, en s'appuyant sur la surveillance qui consiste à détecter les défauts puis les diagnostiquer pour les localiser et identifier les causes.

Notre travail porte sur la détection et la classification des défauts intervenant lors de fonctionnement des machines tournantes, nous allons, dans ce qui suit, étudier les phénomènes de vibrations qui constituent le paramètre utilisé pour caractériser l'état de fonctionnement du système.

Une machine est un ensemble des pièces mécaniques, hydrauliques ou électriques concourant à exercer une ou plusieurs fonctions données et, en particulier, l'application d'une force modulée ou non, destinée à vaincre une résistance ou à assurer un mouvement avec ou sans transmission de force.

CHAPITRE II : LES MÉTHODES DE L'INTELLIGENCE ARTIFICIELLE

II.1. Ensemble Décomposition en Mode Empirique (EEMD) :

L'EMD d'ensemble consiste à effectuer un certain nombre de fois l'EMD sur des réalisations bruitées d'un signal, puis à faire la moyenne IMF par IMF. On obtient ainsi une décomposition semblable à l'EMD, mais où l'on a amélioré la séparation fréquentielle et réduit le mélange de modes. En effet, le bruit introduit artificiellement crée de nombreux extrema, ce qui force la séparation ; par ailleurs en prenant un grand nombre de réalisations, on espère que le mélange de mode s'annulera, la décomposition sans mélange étant, on l'espère, la plus probable. Notons que l'EEMD, à cause de la moyennisation, n'est pas une décomposition complète : le signal n'est plus la somme de ses IMFs. Lorsque cet aspect est nécessaire, il vaudra mieux utiliser l'approche alternative qui est complète.

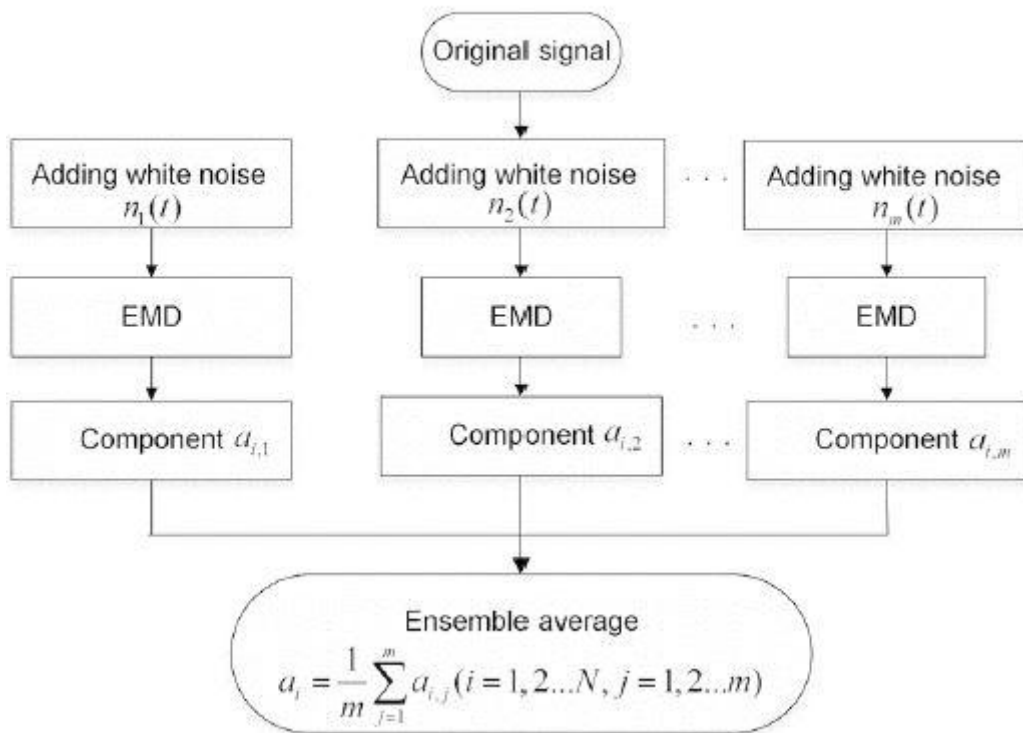


Figure II.1. L'organigramme de la méthode EEMD

II.2. Introduction à l'intelligence artificielle

II.2.1 Introduction:

L'intelligence artificielle est une technique en plein essor dans plusieurs domaines.

De la découverte de visages, aux assistants conversationnels, en passant par les véhicules autonomes et les systèmes de conseils d'achats sur internet et le domaine de traitement et surveillance des systèmes industriels. Ces nouvelles technologies approprient notre quotidien.

Et dans ce large domaine, un type de méthodes fait plus particulièrement parler de lui : le Deep Learning. Le Deep Learning, ou apprentissage profond, est par exemple à l'origine du très médiatique succès, Le potentiel de ces technologies semble étonnant. D'ailleurs, dans les dernières années, l'Institut Gartner les a placées tout en haut, au pic des souhaits qu'elles peuvent générer. Mais entre le potentiel et ce que l'on doit réellement en attendre, entre Deep Learning et autres domaines de l'intelligence artificielle, il n'est pas forcément facile de s'y retrouver... En effet, le Deep Learning est déjà exploré depuis quelque temps dans le domaine de la surveillance des systèmes industriels. D'abord par le monde de la Recherche puis par celui de la Recherche et du Développement.

L'intelligence artificielle (IA) et plus particulièrement les méthodes d'apprentissage approfondis ont permis de concevoir des outils efficaces, tels que les algorithmes de classification, qui sont très présents dans les applications industrielles dans divers domaines. Partant de ce fait, ce mémoire vise à exploiter le potentiel des techniques de l'IA et les fusionner avec la technique EEMD dans le cadre d'une automatisation du processus de diagnostic de défauts. Ce chapitre sera consacré à la démarche de diagnostic intelligent où ses différentes étapes décrivent les principales méthodes d'IA utilisées actuellement dans l'intérêt d'une stratégie de maintenance efficace.

La figure ci-dessous (Figure II .1) décrit les différentes zones de l'évolution l'intelligence artificielle jusqu'au système le plus développé dans ce domaine (convolutional Neural Network), cas de l'application utilisé de notre travail de mémoire.




Figure II.2 Intelligence artificielle, machine learning , deep learning et convolutional network

II.2.2.1 L'apprentissage profond (DL) :

Comme on l'a décrit précédemment, les algorithmes d'apprentissage profond (DL) font partie de la famille ML et utilisent des architectures profondes basées sur les couches utilisées dans les ANN avec la capacité d'extraire automatiquement plusieurs indicateurs sophistiqués ou des représentations hiérarchiques à partir des données brutes sans avoir besoin d'une extraction manuelle ou d'une intervention d'un expert du domaine. L'approche DL a le potentiel de surmonter les déficiences des méthodes conventionnelles, ce qui permet de mettre en œuvre des algorithmes pour créer des systèmes de surveillance fiables et détecter les défauts affectant les machines tournantes avec des performances élevées. Cette approche est de plus en plus riche englobant des algorithmes d'apprentissage supervisés ou non supervisés, une variété de réseaux de neurones avec différentes couches de traitement et des modèles probabilistes hiérarchiques. Parmi les outils les plus puissants de l'approche DL, on distingue les réseaux de neurones de convolution (CNN) qui vont être décrits dans la section suivante.

II.2.2.2 Réseaux de neurones à convolution (CNN) :

Les CNN ont d'abord été proposés par LeCun pour le traitement d'image. C'est un modèle de réseau de neurones profonds dont les poids et les biais sont ajustables par apprentissage. Ces réseaux possèdent de puissantes capacités d'extraction de caractéristiques grâce à ses structures en forme de maillage conçues pour le traitement de données multidimensionnelles.

II.3 Architecture des réseaux de neurones convolutifs :

Les réseaux de neurones à convolution sont basés sur le perceptron multicouche (MLP), et inspirés du comportement du cortex visuel des vertébrés. Bien qu'efficaces pour le traitement d'images, les MLP ont beaucoup de mal à gérer des images de grande taille, ce qui est dû à la croissance exponentielle du nombre de connexions avec la taille de l'image.

Un réseau de neurone convolutif se compose de plusieurs couches comme le montre la figure

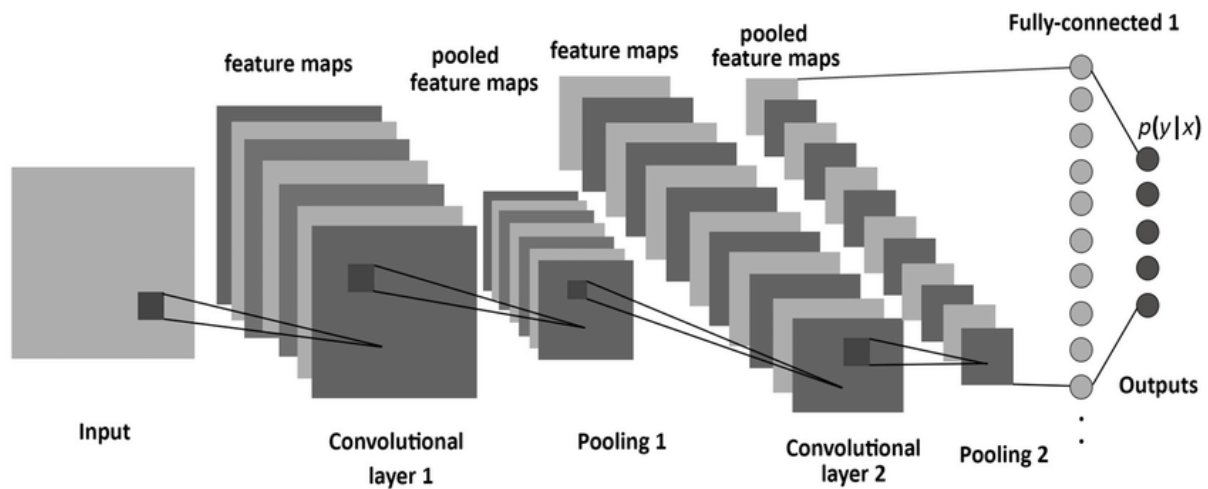


Figure II.3: Architecture des réseaux de neurones convolutifs

Une architecture typique de CNN se compose de trois types de couche : couche de convolution, couche de sous-échantillonnage connue aussi sous le nom « couche de regroupement » et la couche entièrement connectée.

- La Couche de convolution (CL) : est la brique de base des CNN. Cette couche fait le produit de convolution de la carte d'indicateurs de l'entrée avec un tas de noyaux afin de générer de nombreuses nouvelles cartes d'indicateurs en entrée de la couche suivante où les résultats des opérations de convolution sont soumis à la fonction d'activation pour obtenir la sortie. Généralement, le modèle mathématique de CL peut être décrit par l'équation suivante :

$$x_j^l = f \left(b_j^l + \sum_{i \in M_j} x_i^{l-1} * k_{ij}^l \right) \quad (\text{II.1})$$

où (*) définit l'opérateur de convolution, M_j illustre la sélection de cartes d'entrée, l désigne l'indice de la $l^{\text{ème}}$ couche du réseau, k est la matrice du noyau (le filtre de convolution) de taille $S \times S$, b est le biais, x représente la carte d'indicateurs générée à partir de la $(l - 1)^{\text{ème}}$ couche et f est la fonction d'activation non linéaire.

Les fonctions d'activation qui sont couramment utilisées dans les réseaux CNN sont la fonction sigmoïde, la tangente hyperbolique et la fonction d'unité linéaire rectifiée (Relu), qui a une bonne capacité d'adaptation conduisant à une faible densité du réseau, ce qui améliore

considérablement l'efficacité du calcul et empêche efficacement l'élimination du gradient. Les expressions mathématiques qui définissent les fonctions d'activation les plus courantes, sont présentées dans le tableau II.1

Tableau II.1 : Les fonctions d'activation les plus utilisées dans les réseaux CNN.

Nom de la fonction	Expressions
Relu	$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$
Tanh	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$

- *La Couche de sous-échantillonnage (SL)*

Connue aussi sous le nom « couche de *pooling* en anglais » est située derrière la couche de convolution où l'entrée de la SL est la sortie de la CL. Sa fonction est de réduire progressivement la dimension et la quantité de paramètres entraînaibles d'un CNN. Par conséquent, elle diminue le calcul pour les couches supérieures et améliore la capacité de calcul du réseau. La SL peut être décrit mathématiquement par l'équation suivante :

$$x_j^l = f(\beta_j^l \mathbf{down}(x_j^{l-1} + b_j^l)) \quad (\text{II.2})$$

où **down(.)** représente la fonction de sous-échantillonnage. Cette fonction fait la somme de chaque bloc n par n distinct dans l'image d'entrée de sorte que l'image de sortie soit n fois plus petite des deux dimensions spatiales. Chaque carte d'indicateurs de sortie reçoit son propre biais multiplicatif β et son biais additif b . Il existe plusieurs fonctions de *pooling* telles que la moyenne, la norme L2 et la moyenne pondérée en fonction de la distance du pixel central, etc. Cependant, la fonction la plus couramment utilisée dans les CNN est la fonction de pooling maximum ou max-pooling, qui sélectionne le maximum de la région de restriction comme nouvelle caractéristique pour une utilisation ultérieure dans les couches suivantes.

- La couche entièrement connectée (FL) : La FL est un réseau neuronal classique à propagation avant qui est utilisé dans l'étape de classification dans l'architecture CNN. Il utilise généralement la fonction Softmax comme fonction d'activation dans la sortie du réseau. La fonction Softmax est définie par l'équation suivante :

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, \quad \text{For } j = 1, \dots, K \quad (\text{II.3})$$

Dans un réseau FL, tous les neurones entre les couches sont interconnectés, comme défini par l'équation (II.16) :

$$O(X) = f(W.X + b) \quad (\text{II.4})$$

Où $f(.)$ est la fonction d'activation, X est l'entrée de la couche entièrement connectée, $O(X)$ est la sortie de FL, W et b sont les poids et les biais de FL, respectivement.

Le but du FL est de collecter toutes les caractéristiques de la carte d'indicateurs précédente pour la classification. La sortie finale de FL est un vecteur unidimensionnel où chaque valeur de ce vecteur 1D est une valeur quantitative de la n classification.

Les réseaux CNN ont également eu la plus grande attention par les chercheurs où ils ont été appliqués à une variété de problèmes d'apprentissage. Cet outil d'apprentissage profond s'est avéré un potentiel élevé pour la résolution des problématiques liées à la reconnaissance des formes et aux tâches de vision par ordinateur. Ces dernières années, cet algorithme est considéré comme un outil de tendance, exploité dans la conception des systèmes de surveillance à haute performance pour le diagnostic de différents défauts affectant les machines tournantes, notamment les défauts de roulements. ont appliqué un réseau CNN pour le diagnostic de défaut de roulement où les résultats obtenus indiquant que le schéma proposé surpasse les performances de l'approche conventionnelle qui nécessite une extraction et une sélection manuelle d'indicateurs. Ding et He ont pris l'image d'énergie de paquet d'ondelettes (WPE) comme une entrée à un réseau de neurones à convolution (ConvNet) pour le diagnostic de défauts de roulements. dans laquelle il a pris les signaux vibratoires à leur état brut comme une entrée d'un réseau de neurones à convolution monodimensionnel (1D CNN) pour la détection rapide et précise de défauts de roulements. Il a combiné les tâches d'extraction d'indicateurs et de classification de défauts en un seul corps d'apprentissage à travers la mise en œuvre de 1D CNN. L'avantage de cette méthode est sa capacité à extraire automatiquement les caractéristiques optimales sensibles aux défauts à partir des signaux bruts ce qui ne nécessite aucune approche supplémentaire de prétraitement ou de traitement du signal. Les performances obtenues démontrent que la complexité de calcul est réduite sans compromettre le taux de classification de défauts.

Données allouées de l'ensemble d'apprentissage. De plus, le taux de classification peut encore augmenter jusqu'à 99,61% lorsque le pourcentage de données d'entraînement augmente de

5% à 20%. ont proposé une méthode de diagnostic intelligente basée sur l'apprentissage profond pour le diagnostic de défauts de roulements. Les signaux bruts sont convertis en images bidimensionnelles pour les prendre ensuite comme une entrée d'un réseau de neurones à convolution qui peut automatiquement accomplir le processus d'extraction de caractéristiques et de diagnostic de défauts. Les résultats obtenus vérifient la validité de la méthode proposée où l'efficacité du diagnostic n'était pas influencée par la taille de défauts et la variation de charges.

II.4.Conclusion

Dans ce chapitre, les réseaux de neurones à convolution ont été définis et leur rôle a été mis en relief. Ces réseaux sont capables d'extraire des caractéristiques d'images ou des données en général, présentées en entrée et de classifier ces données en se basant sur les caractéristiques (de ces données) extraites automatiquement. Ils implémentent aussi l'idée de partage des poids qui permettant de réduire beaucoup le nombre de paramètres libres de l'architecture. Ce partage des poids permet en outre de réduire les temps de calcul et l'espace mémoire nécessaire et également d'améliorer les capacités de généralisation du réseau.

CHAPITRE III : APPLICATION AU DIAGNOSTIC DES DÉFAUTS DE ROULEMENTS.

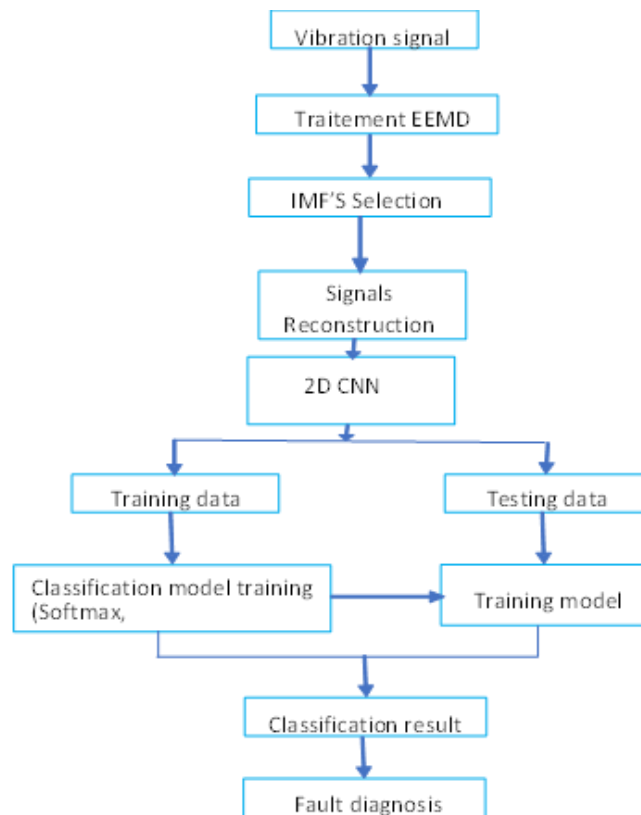
III.1.Introduction :

Comme nous l'avons vu précédemment, il existe plusieurs façons de surveiller l'état de fonctionnement d'une machine tournante, des méthodes plus ou moins complexes qui nécessitent la présence d'un expert et une connaissance approfondie de la dynamique et de la cinématique de la machine. à atteindre, en particulier dans le cas de systèmes complexes. Alors que les entreprises industrielles continuent d'évoluer, la nécessité de disposer d'un système de surveillance automatisé capable de détecter plus ou moins les pannes à un stade précoce est considérée comme une priorité absolue pour améliorer les tâches de maintenance prédictive. L'intégration des méthodes d'intelligence artificielle dans les systèmes de diagnostic offre une solution prometteuse pour transformer les tâches de diagnostic en tâches de classification.

III.2 Méthodologie de diagnostic proposée

La technique de diagnostic proposée se base principalement sur le traitement d'images vibratoires à l'aide des réseaux de neurones de convolution, où les signaux collectés sont traités par des outils de traitement de signal avant leurs conversions en images. L'organigramme du système de diagnostic réalisé est exposé dans la figure III.1.

Figure III.1 Organigramme de la méthode proposée pour le diagnostic de défauts.



Les étapes de la méthode proposée sont décrites ci-dessous :

- 1) Prétraitement des données issues des capteurs de vibration
- 2) Traitement EEMD
- 3) Sélection des IMFs
- 4) Reconstruction du signal de vibration
- 5) Conversion du signal reconstruit 1D en une image 2D
- 6) Application des réseaux CNN pour l'apprentissage et le test
- 7) Classification des défauts
- 8) Diagnostic des défauts

III.3.1 Application de la méthode proposée au banc d'essai CWRU

III.3.1.1 Banc d'essai CWRU :

La base de données de la Case Western Reserve University (CWRU) contient des mesures de vibrations collectées lors des tests de roulements à billes normaux et défectueux sur un banc d'essai composé de moteurs, d'accouplements et de générateurs (Figure III.2). Les défauts

apparaissent sous forme de points de différents diamètres. Ces défauts sont créés par des machines EDM sur divers éléments de roulement. Dans ce travail, le signal vibratoire considéré est un signal échantillonné à 12 000 Hz avec plusieurs défauts de roulement : ORF (défaut bague externe), IRF (défaut bague interne) et BAF (défaut de bille). Selon l'application de la charge, nous avons quatre régimes moteur : 1797, 1772, 1750 et 1730 tr/min correspondent respectivement à des charges de 0, 1, 2 et 3 Hp. Dans cette section, nous n'avons sélectionné que 3 types de défauts dont la dimension minimale est égale à 0,007 pouce (équivalent à 0,1778 mm).

Le tableau III.1 décrit les différents signaux sélectionnés dans cette base de données, où chaque signal est indiqué avec un index pour faciliter l'interprétation ultérieure des résultats. La Figure III.2 montre les signaux de vibration pour les quatre états fonctionnels du roulement sous une charge de 0 Hp.




Figure III.2 Banc d'essai CWRU

Tableau III.1 Les différentes classes sélectionnées de la base des données de CWRU. (ORF : défaut de la cage externe, IRF : défaut de la cage interne, BAF : défaut de la bille).

Etat de roulement	Fault diameter (inch)	Charge (hp)	Indice
Sain	/	0,1,2 et 3	0
ORF	0.007	0,1,2 et 3	1
IRF	0.007	0,1,2 et 3	2
BAF	0.007	0,1,2 et 3	3

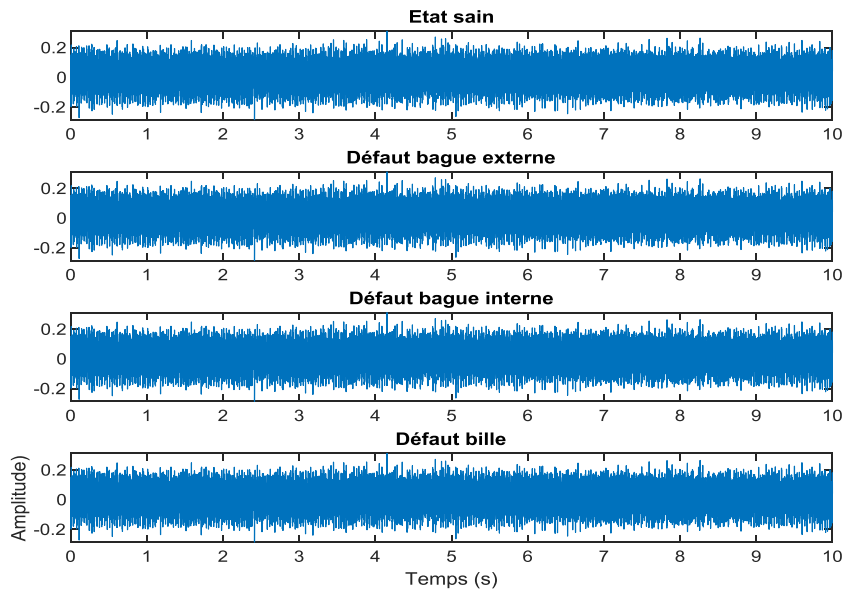


Figure III.3 Les signaux de vibration sous charge de 0 *hp*

III.3.1.1 Prétraitement des données :

Les classifieurs doivent avoir suffisamment d'échantillons pour que la phase d'apprentissage et de test soit correcte. Afin de satisfaire cette condition, les données de vibration sont divisées en segments imbriqués de la même longueur avec un pas de 512 points, comme clarifié dans la figure IV.5, La longueur de segment n'était pas choisie au hasard, elle est basée sur le choix d'une longueur qui est égale à un nombre carré pour que la conversion des segments en images soit facile dans les niveaux supérieurs de cette étude ($32^2 = 1024 \text{ points}$). De plus, Le choix d'une segmentation imbriquée a comme objectif de ne pas perdre l'information qui subsiste entre les segments. Nous obtenons 620 échantillons contenant 1024 points chacun, sont sélectionnés pour chaque état de santé. Pour chaque état de santé 620 échantillons sont générés, on aura donc pour quatre états de roulements, $620 \times 4 = 2480$ segments pour chaque vitesse du moteur.




Figure III.4 Segmentation imbriquée des signaux de vibration

III.4. Traitement des signaux vibratoires à base de l'EEMD :

La technique EEMD est appliquée aux signaux de vibration qui peuvent être décomposés en plus de 10 IMFs. La figure III.5 montre un exemple de décomposition EEMD d'un signal vibratoire sous un défaut de cage interne (IRF), où on peut visualiser que cet outil nous a permis de décomposer le signal brut en un ensemble de modes dans un ordre décroissant : IMFs rapidement oscillantes (haute fréquence) au lentement oscillantes (basse fréquence). En outre, les amplitudes de vibration des fonctions oscillantes sont générées dans un ordre décroissant, ce qui signifie que l'énergie diminue rapidement.

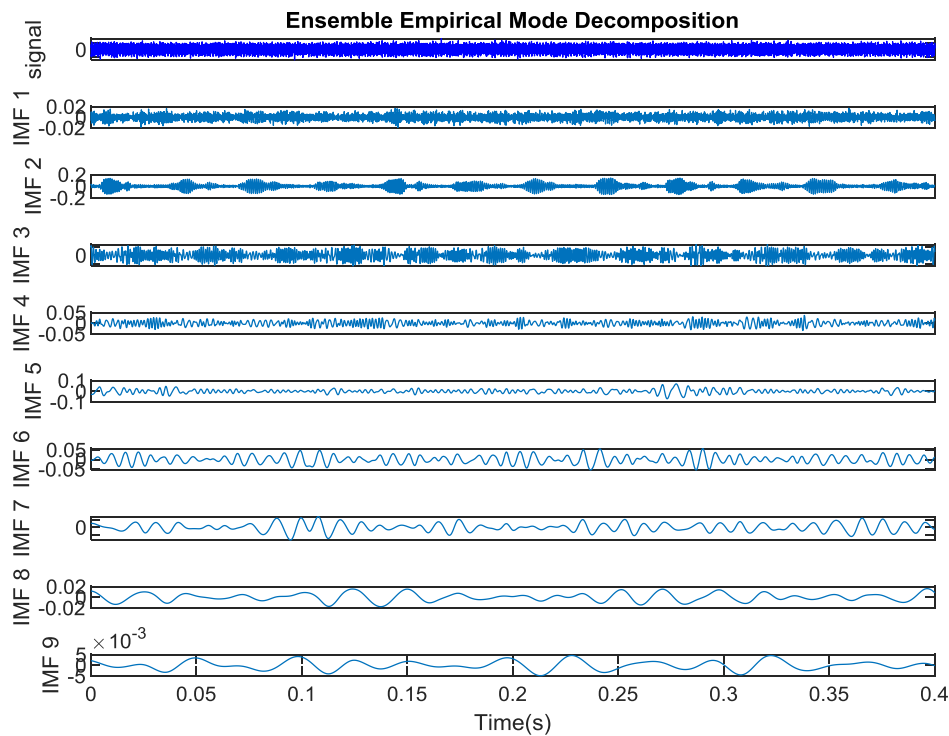


Figure III.5 Signal vibratoire et ses 9 premiers IMFs sous le défaut de la cage interne (à une charge de 0 hp et une vitesse égale à 1797 tr/min).

III.4.2.Sélection d'IMFs

La méthode de sélection des IMFs est basée sur le calcul de coefficient de corrélation entre le signal original et ses propres IMFs extraites dans le but de rendre les signaux vibratoires reconstruits moins affectés par le bruit.

Nous calculons le coefficient de corrélation entre le signal vibratoire symbolisé par X et son n IMFs correspondant symbolisé par Y pour vérifier la force et la direction d'une relation linéaire entre ces variables. Cette relation monotone entre deux variables X et Y , est définie par la formule :

$$r_{XY} = \frac{Cov(X,Y)}{\sigma(X)\sigma(Y)} \quad (\text{III.1})$$

où r_{XY} varie de -1 à +1 ($-1 \leq r_{XY} \leq 1$) et les différentes interprétations des valeurs de coefficients de corrélation.

En résumé, une mauvaise IMF choisie entraîne une perte d'informations et peut affecter de manière indésirable l'exactitude de la classification de défauts. Chaque IMF sélectionnée doit avoir une valeur de corrélation égale ou supérieure à un seuil fixe équivalant

approximativement à 25% d'une relation de corrélation forte qui est égale à 1. Cela signifie qu'on veut garder toutes les IMFs qui contiennent au minimum 30% des informations pertinentes contenues dans le signal original et que les IMFs qui ont une corrélation inférieure au seuil fixé sont éliminées et considérées comme des éléments perturbateurs. Généralement, une valeur de corrélation équivalente à 0.30 correspond à la sélection des trois ou quatre premières IMF, qui ont la plus grande énergie.

En effet, Les IMFs choisies sont présumées être les composants les plus importants contenant les bonnes informations reflétant l'état réel des roulements et qui sont ensuite assemblés par une simple opération d'addition afin de reconstruire un nouveau signal de vibration, comme décrit par l'équation suivante :

$$Signal = \sum_{i=1}^N IMF_i \quad (III.2)$$

où *Signal* désigne le signal vibratoire reconstruit, et *N* définit le nombre d'IMFs sélectionnées. Ces signaux reconstruits ont un bruit réduit et moins d'informations inutiles, ce qui améliorent les performances du processus d'apprentissage adopté au stade de la classification.

Après le processus de décomposition, un nouveau signal vibratoire est reconstruit selon la méthode décrite ci-dessus, basée sur la sélection des IMFs les plus pertinentes ; les signaux reconstruits pour les quatre états de fonctionnement du roulement dans des conditions de charge de 1 Hp sont tracés dans la figure III.4.

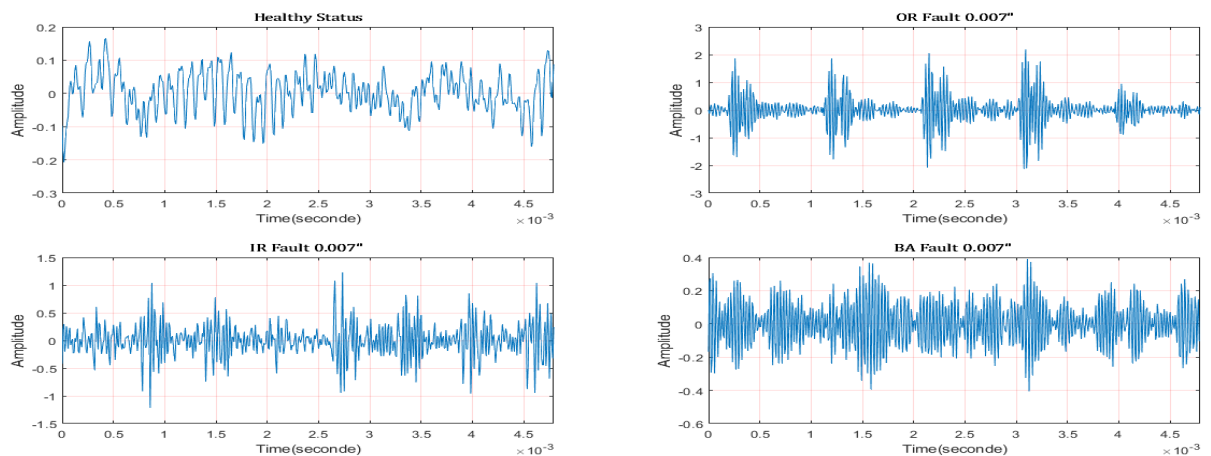


Figure III.6 : Nouveaux signaux vibratoires reconstruits sous la condition de charge 1 hp.

Le processus de reconstruction du signal préserve les impulsions périodiques ou même aléatoires dans la mesure des vibrations pour chaque état de fonctionnement du roulement, offrant une similitude significative avec le signal d'origine.

Les signaux reconstruits ci-dessus seront utilisés pour extraire les caractéristiques des défauts afin de les identifier par la méthode d'apprentissage profond.

III.5 Application des réseaux CNN pour l'apprentissage et le test

III.5.1 Conversion signal 1D en image 2D

On prend les mêmes données vibratoires du CWRU arrangées dans le tableau III.2, dans lequel la longueur des segments a été choisi comme étant un nombre carré pour transformer facilement les segments en images vibratoires. La longueur de segment choisie dans la première partie (section III.2.1) est égale à 1024 points, ce qui correspond à une image vibratoire de taille 32 x 32 et qui contient 1024 pixels au total. Le processus de conversion du signal de vibration « 1D » à une image en niveaux de gris « 2D », est expliqué ci-dessous :

L'amplitude de chaque échantillon du signal de vibration est normalisée dans l'intervalle [0, 255]. Cette valeur définit l'intensité lumineuse d'un pixel et elle peut se varier du noir (0) jusqu'au blanc (255) en passant par les nuances qui sont contenues dans cet intervalle. Pour cela, l'amplitude normalisé de chaque échantillon du signal devient l'intensité du pixel correspondant dans l'image $M \times N$ correspondante. Le processus de conversion de données 1D en 2D, est illustré sur la figure III.7 et cette relation de conversion entre l'amplitude normalisé et le pixel correspondant peut-être décrite par l'équation suivante :

$$P[i, j] = A[(i - 1) * M + j] \quad (\text{III.12})$$

où $i = 1:N$; $j = 1:M$; $P[i, j]$ est l'intensité du pixel (i, j) correspondant à l'image vibratoire en niveaux de gris $M \times N$. $A[.]$ est l'amplitude d'échantillon normalisé dans le signal de vibration. Le nombre de pixels dans l'image de vibration doit être égal au nombre de points dans le signal vibratoire.

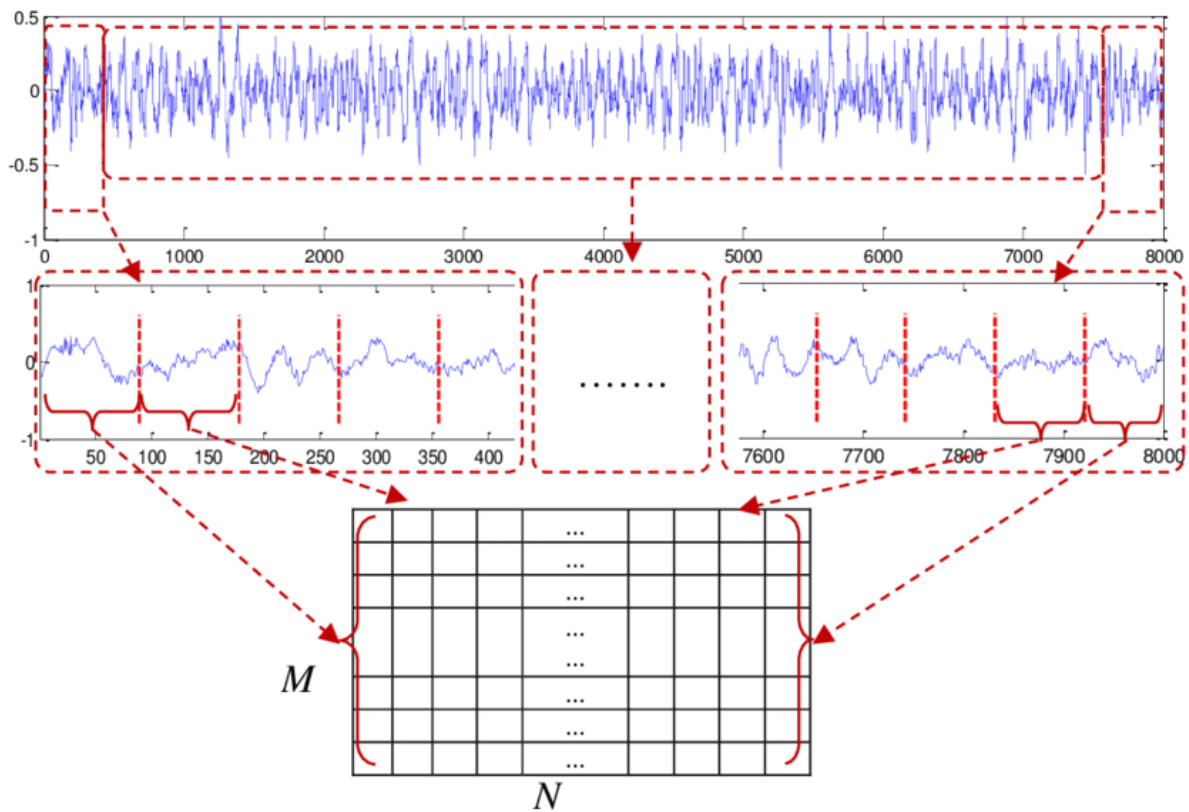


Figure III.1 Processus de conversion du signal $1D$ en image vibratoire $2D$

Dans notre cas, tous les segments de longueur '1024' sont converties en images vibratoires de taille '32x32 pixels'. A ce niveau, nous avons 500 images de vibration pour chaque état de roulement. Pour trois types de défauts, y compris la condition normale, nous obtenons 2000 images vibratoires pour chaque condition de charge. Le tableau III.6 décrit l'arrangement des ensembles de données des images vibratoires construites, et la figure III.8 montre les images vibratoires obtenues correspondantes à la charge 0 hp.




Figure III.2 Images vibratoires correspondantes à la charge 0 hp.

Tableau III.6 Arrangement des ensembles d'images vibratoires de CWRU après les processus de reconstruction de signaux et de conversion 1D à 2D.

Indice	Nombre de classes	Charge (<i>hp</i>)	Nombre d'images
0	4	0, 1, 2, 3	6152
1			
2			
3			

III.5. Modèle de référence CNN

Dans le processus de construction du modèle 2D-CNN, la sélection des hyper-paramètres adéquats du CNN peut améliorer efficacement la précision du diagnostic de défaut ainsi que les vitesses d'apprentissage et de test du modèle CNN-Softmax conçu. Généralement, les principaux hyper-paramètres incluent le nombre de couche, la taille des noyaux de convolution, les noyaux de sous-échantillonnage, les optimiseurs, les fonctions d'activation et le coefficient d'apprentissage, etc. Ces configurations ont un impact direct sur les performances du modèle CNN adopté. L'apprentissage se fait par l'algorithme de rétro propagation et pour mieux entraîner notre modèle CNN, nous utilisons un optimiseur de type « Adam » avec un coefficient d'apprentissage égal à 0.001 et on utilise aussi la « cross-entropy » comme une fonction de perte.

Le modèle CNN de référence se compose d'une couche de convolution (CL), d'une couche de pooling (SL), d'une couche entièrement connectée (FL) et doté aussi d'un classifieur Softmax dans la sortie. Dans l'étape de sélection de la taille des noyaux, le CL ultérieur doit avoir une taille de noyau plus petite que celle du CL antérieur, car après chaque opération CL et SL, la taille des données de sortie sera diminuée, ce qui réduit significativement le coût des calculs et améliore la vitesse d'apprentissage.

La première couche de convolution est formée de 32 filtres avec une taille de noyau de 5x5, et elle est suivie par une couche de sous-échantillonnage de type Max-Pooling de taille 2x2. Puis après, suit une couche entièrement connectée FL ayant un nombre de neurones dans égal au nombre de classe étudiées dans notre problématique. La couche de sortie utilise une fonction softmax pour la classification des défauts de roulements. Le tableau III.7 présente une description détaillée concernant les hyper-paramètres du modèle de référence adopté.

Les fonctions d'activation couramment utilisées dans les réseaux CNN incluent les fonctions Sigmoid, Relu et Tanh. Dans le cadre de notre travail, nous optons pour la fonction Relu comme fonction d'activation. Le modèle CNN initial sera entraîné par 4429 images vibratoires et testé ensuite par 1230 images vibratoires puis validé par 493.

Tableau IV.1 Description des hyper-paramètres du modèle CNN de référence.

Layer Number	Type	Layer specification	Size Out
Layer 01	'Input'	Input Size=32x32	32x32
Layer 02	'CL'	Filter Num = 20, Stride=1, Pad=0 kernel size = 5x5	28x28
Layer 03	Activation function	Relu	28x28
Layer 04	'SL' (Max-Pooling)	Size 2x2	14x14
Layer 05	'Fc'	4 hidden layer neuron nodes	1x4
Layer 06	'Softmax'	\	1x4
Layer 07	'OutPut'	LossFunc=@CrossEnt	1x4

Confusion Matrix: Modele CNN

Output Class	1	95 40.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	47 19.8%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	48 20.3%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	47 19.8%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	1	2	3	4	Target Class	

Figure III.9 Matrice de confusion

Les résultats de la matrice de confusion montrent que le taux de classification de toutes les classes est égal à 100 %. Ce qui démontre que l'efficacité de la méthode proposée.

La figure III.10 montre l'évolution de la précision et des pertes pour l'entraînement et la validation. Comme le montre la figure III.10, l'entraînement et la validation du modèle atteignent un taux de précision 100% au bout de la neuvième époque, tandis que les pertes de l'entraînement et de la validation s'annulent à la même époque.

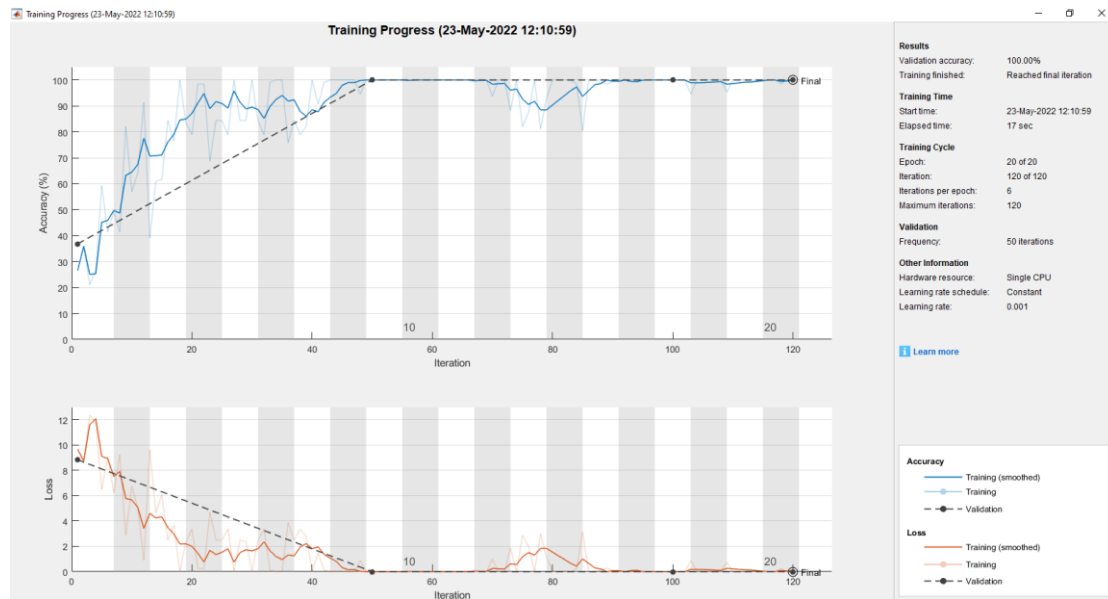


Fig. III.10 (a) Précision de l'entraînement et de la validation, (b) Perte de l'entraînement et de la validation of novel BiLSTM method

III.5 Conclusion :

Nous avons présenté dans ce chapitre, plusieurs méthodes basées sur plusieurs applications exploitant les données vibratoires du banc d'essai de CRWU. Un algorithme de traitement de signaux basé sur l'EEMD, a été exposé en premier lieu suivi par une méthode de sélection des IMF, afin de reconstruire ces signaux vibratoires à nouveau. Un ensemble d'indicateurs statistiques a été extrait à partir des signaux reconstruits, dans le but de composer un vecteur de caractéristiques qui est alimenté ensuite à trois classifieurs différents

Les résultats obtenus signifient que la méthode EEMD-CNN proposée est non seulement une méthode puissante qui surpasse les autres approches de diagnostic existantes, mais a également le potentiel d'être appliquée dans le diagnostic de défauts des autres systèmes.

Conclusion générale

La détermination de la détérioration des roulements est d'une grande importance dans le domaine des machines tournantes. Ce qui nous a amené à proposer une méthode de diagnostic des défauts des roulements.

Notre travail a pour but d'utiliser les approches avancées du traitement de signal dans la maintenance industrielle, en effectuant un diagnostic pour la détection et la caractérisation des défauts qui peuvent affecter les différents éléments de roulements d'une machine tournante. Pour ce faire, on a employé des méthodes de deep learning combiné avec la méthode EEMD afin de détecter les défauts de roulements.

Les résultats de la matrice de confusion montrent que le taux de classification de toutes les classes est égal à 100 %. Ce qui démontre que l'efficacité de la méthode proposée.

Références bibliographiques

- [1] Li, B., Chow, M.y., Tipsuwan, Y., Hung, J. C., Neural-Network-Based Motor Rolling Bearing Fault Diagnosis, IEEE Transaction on Industrial Electronics, Vol. 47, Issue 5, 1060-1069 (2000).
- [2] Morel J., «surveillance vibratoire et maintenance prédictive», Techniques de l'ingénieur R 6 100, 2007.
- [3] MALKI NAR IMENE, Classification automatique des textes par Les réseaux de neurones à convolution, thèse MASTER ACADEMIQUE, Domaine : Mathématique et Informatique, Filière : Informatique, Spécialité : Vision Artificielle, Faculté sciences exactes et sciences de la nature et de la vie, Département de mathématiques et d'informatique, Université LARBI ben M'HIDI O.E.B, 2018/2019.
- [4] François Blayo et Michel Verleysen, Les réseaux de neurones artificiels, 1re éd., 1996.
- [5] Yi, W., Sun, Y., Ding, T., & He, S. (2019). Detecting retail products in situ using CNN without human effort labeling. arXiv preprint arXiv:1904.09781.
- [6] L. Eren, M.J. Devaney, Bearing Damage Detection via Wavelet Packet Decomposition of the Stator Current, IEEE Trans. Instrum. Meas. 53 (2004) 431–436. doi:10.1109/TIM.2004.823323.
- [7] Bingcai Zhang and Riad I. Hammoud "Fast and accurate target detection in overhead imagery using double convolution neural networks", Proc. SPIE 10988, Automatic Target Recognition XXIX, 109880O (14 May 2019); <https://doi.org/10.1117/12.2519795>.