

**République Algérienne Démocratique et Populaire**  
**Ministère de l'Enseignement Supérieure et de la Recherche Scientifique**

**BADJI MOKHTAR-ANNABA UNIVERSITY**  
**UNIVERSITE BADJI MOKHTAR-ANNABA**



**جامعة باجي مختار - عنابة**

**Année 2020/2021**

Faculté des Sciences de l'Ingénieur  
Département de Génie Mécanique

## *Thèse*

Présentée en vue de l'obtention du diplôme de DOCTORAT 3<sup>ème</sup> CYCLE

**SURVEILLANCE ET DIAGNOSTIC DES DÉFAUTS DES MACHINES  
TOURNANTES DANS LE DOMAINE TEMPS-FRÉQUENCES UTILISANT  
LA DECOMPOSITION MODALE EMPIRIQUE**

Spécialité : Génie Mécanique

Option : Diagnostic et Surveillance des défauts

Par :

**AMAROUAYACHE Iskander Imed Eddine**

<b>DIRECTEUR DE THÈSE:</b>	<b>GUERSI Noureddine</b>	Professeur	Université d'Annaba
<b>CO-DIRECTEUR:</b>	<b>SAADI Mohamed Nacer</b>	MC.B	Université d'Annaba

### DEVANT LE JURY

<b>PRÉSIDENT:</b>	Pr.	<b>BOURAS Slimane</b>	Université d'Annaba
<b>RAPPORTEUR :</b>	Pr.	<b>GUERSI Noureddine</b>	Université d'Annaba
<b>CO-RAPPORTEUR :</b>	MCB.	<b>SAADI Mohamed Nacer</b>	Université d'Annaba

<b>EXAMINATEURS:</b>	Pr.	<b>LAACHOURI Abderezak</b>	Université de Skikda
	Pr.	<b>FARAH Nadir</b>	Université d'Annaba
	Dr. HDR	<b>AMIRAT Yacine</b>	ISEN YNCREA Ouest, Brest-France



**Titre** SURVEILLANCE ET DIAGNOSTIC DES DÉFAUTS DES MACHINES TOURNANTES DANS LE DOMAINE TEMPS-FRÉQUENCES UTILISANT LA DECOMPOSITION MODALE EMPIRIQUE.

**Résumé** La surveillance et le diagnostic des machines tournantes sont devenues un concept très efficace pour la détection de façon précoce et précise des défauts et en suivre leurs évolutions dans le temps. La réalisation d'un système de diagnostic efficace présente un grand intérêt industriel et économique (rentabilité, productivité et compétitivité des entreprises). La maintenance nécessite des connaissances poussées et une bonne compréhension des phénomènes liés à l'apparition et à l'aggravation des défauts. Les techniques classiques de traitement de signal appliquées au diagnostic des machines tournantes s'avèrent inadaptées dans le cas des défauts de roulements ou d'engrenages. C'est dans cette optique que s'inscrit notre étude par la mise en œuvre des techniques plus élaborées et en temps réel afin d'atteindre les objectifs escomptés.

Plusieurs méthodes ont été proposées dans ces travaux de thèse en se basant sur la combinaison de la décomposition modale empirique d'ensemble (EEMD) et les différentes techniques d'apprentissage machine à travers lesquelles la tâche de diagnostic est convertie en une tâche de classification.

L'EEMD est utilisée comme un filtre coupe bande afin d'améliorer la qualité des signaux vibratoires en éliminant le bruit résiduel dans ces derniers. Les techniques d'apprentissage machine entre autres les CNNs, sont intégrés dans notre approche afin d'automatiser la phase d'extraction d'indicateurs pertinents des défauts sans une intervention manuelle.

Cette stratégie de surveillance a été testée pour diagnostiquer les défauts de roulement et validées sur des signaux vibratoires issues de plusieurs compagnes d'essais (bancs d'essai), incluant les différentes conditions opérationnelles des machines. Les résultats obtenus prouvent l'efficacité et la robustesse des méthodes suscitées pour le diagnostic des défauts de roulements.

**Mots-clés** défauts de roulements, diagnostic de défauts, machines tournantes, analyse vibratoire, EEMD, apprentissage machine, apprentissage profond.

**Title** MONITORING AND FAULT DIAGNOSIS OF ROTATING MACHINERY IN THE TIME-FREQUENCY DOMAIN USING EMPIRICAL MODE DECOMPOSITION.

**Abstract** The monitoring and diagnosis of rotating machinery have become a very effective concept for the early and accurate detection of faults and monitor their development over time. The realization of an effective diagnostic system offers a great industrial and economic interest (profitability, productivity, and competitiveness of companies). Maintenance requires extensive knowledge and a good understanding of the phenomena associated with the appearance and aggravation of faults. Conventional signal processing techniques applied to the diagnosis of rotating machines have proven to be unsuitable in the case of bearing or gear faults. It is in this perspective that fits our study by the implementation of more sophisticated techniques and in real-time to achieve the desired objectives.

Several methods have been proposed in this thesis based on the combination of ensemble empirical modal decomposition (EEMD) and different machine learning techniques through which the diagnostic assignment is converted into a classification task.

The EEMD is used as a band cut filter to improve the quality of the vibration signals by eliminating the residual noise therein. Machine learning techniques including the CNN's, are integrated into our approach to automate the extraction phase of relevant indicators of defects without manual intervention.

This monitoring strategy has been tested to diagnose bearing faults and validated on vibration signals from several test campaigns (test benches), including various operating conditions of the engine. The obtained results demonstrate the effectiveness and robustness of the proposed methods for bearing faults diagnosis.

**Keywords** bearing faults, fault diagnosis, rotating machinery, vibratory analysis, EEMD, machine learning, Deep learning.

**عنوان** رصد وتشخيص أعطاب الآلات الدوارة في مجال ترددزمن باستخدام التحليل النموذجي التجريبي

**ملخص** أصبح رصد وتشخيص الآلات الدوارة أداة فعالة للغاية للكشف المبكر والدقيق عن الأعطال ورصد تطورها بمرور الوقت. إن إنشاء نظام تشخيص فعال له أهمية صناعية واقتصادية كبيرة (الربحية، الإنتاجية والقدرة التنافسية للشركات). تتطلب الصيانة معرفة واسعة وفهمًا جيدًا للظواهر المرتبطة بظهور الأعطال وتفاقمها. أثبتت تقنيات معالجة الإشارات التقليدية المطبقة في تشخيص الآلات الدوارة أنها غير مناسبة في حالة أعطال المحمل أو التروس المسننة. من هذا المنظور، تعد دراستنا جزءًا من تنفيذ تقنيات أكثر تعقيدًا وفي الوقت الفعلي من أجل تحقيق الأهداف المتوقعة. تم اقتراح عدة طرق في هذه الأطروحة بناءً على الجمع بين التحليل النموذجي التجريبي للمجموعة وتقنيات التعلم الآلي المختلفة التي يتم من خلالها تحويل مهمة التشخيص إلى مهمة تصنيف. تم استخدام التحليل النموذجي التجريبي للمجموعة كمرشح درجة لتحسين جودة الإشارات الاهتزازية من خلال التخلص من الضوضاء العالقة فيها و تم دمج تقنيات التعلم الآلي، بما في ذلك شبكات 'س ن ن'، في نهجنا لأتمتة مرحلة استخراج مؤشرات الأعطال ذات الصلة دون تدخل يدوي

تم اختبار إستراتيجية المراقبة المقترحة لتشخيص أعطاب المحمل والتحقق من صحتها على إشارات الاهتزاز المستخرجة من عدة حملات فحص (منصات الاختبار)، بما في ذلك ظروف التشغيل المختلفة للآلات. النتائج التي تم الحصول عليها تثبت كفاءة ومثانة الطرق المستخدمة لتشخيص الأعطاب التي تؤثر على المحامل

**كلمات البحث** أعطاب المحامل، تشخيص الأعطاب، الآلات الدوارة، التحليل الاهتزازي، التحليل النموذجي

التجريبي للمجموعة، التعلم الآلي، التعلم العميق



# Dédicaces

*À mes parents,  
À mon frère et ma sœur,  
À toute ma famille,  
À tous mes amis.*

# Remerciements

*Ce travail a été réalisé au sein du laboratoire L2RCS, Département de Génie Mécanique, Université Badji Mokhtar Annaba.*

*En premier lieu, je remercie Dieu le Tout Puissant de m'avoir donné la volonté, le courage et la santé pour réaliser ce travail.*

*Je tiens à remercier Monsieur GUERSI Noureddine, Professeur à l'université d'Annaba et, Monsieur SAADI Mohamed Nacer, Docteur à l'université d'Annaba qui ont dirigé ces travaux de thèse, et m'ont accordé leurs confiances pour réaliser ce travail de recherche.*

*Je remercie très vivement Monsieur BOURAS Slimane, Professeur à l'université d'Annaba, pour l'honneur qu'il me fait en présidant le jury de cette thèse.*

*Je remercie également :*

*Monsieur LAACHOURI Abderezak, Professeur à l'université de Skikda*

*Monsieur FARAH Nadir, Professeur à l'université d'Annaba*

*Monsieur AMIRAT Yassine, Docteur-HDR à l'ISEN YNCREA Ouest, Brest-France*

*de l'intérêt qu'ils ont montré pour mon travail et d'avoir accepté d'être examinateurs de ma thèse.*

*Je voudrais aussi exprimer ma reconnaissance à tous les membres du département de Génie Mécanique, du laboratoire L2RCS et du centre CRTI (staff, chercheurs, etc.) pour l'aide que chacun d'eux a pu m'apporter.*

*Mes pensées vont également à ma famille : Parents ; frère et sœur. Je les remercie de leurs aides, soutien et encouragements tout au long de mes études.*

*Enfin, Merci à tous les "anonymes" qui auraient certainement mérité d'être cités.*

Annaba le 01 Mars 2021

# Table des matières

<b>Table des matières</b> .....	<b>vii</b>
<b>Liste des figures</b> .....	<b>x</b>
<b>Liste des tableaux</b> .....	<b>xii</b>
<b>Liste des abréviations</b> .....	<b>xiv</b>
<b>Introduction générale</b> .....	<b>1</b>
<b>Chapitre I : Introduction aux machines tournantes, principales défaillances, et techniques de surveillance</b> .....	<b>5</b>
<b>I.1. Introduction</b> .....	<b>6</b>
<b>I.2. Politiques et objectifs de la maintenance</b> .....	<b>7</b>
<b>I.3. Principales défaillances des machines tournantes</b> .....	<b>9</b>
I.3.1 Défaits de roulement .....	9
I.3.2 Défaits d'engrenage .....	11
I.3.3 Le balourd .....	13
I.3.4 Défaits d'alignement .....	14
<b>I.4. Classification des méthodes pour l'élaboration d'un système de diagnostic industriel</b> .....	<b>15</b>
I.4.1 Méthodes de diagnostic à base de modèles .....	16
I.4.2 Méthodes de diagnostic sans modèles .....	17
<b>I.5. Chaines d'acquisition et sources d'information</b> .....	<b>18</b>
I.5.1 L'analyse vibratoire .....	19
I.5.2 L'analyse de lubrifiant .....	20
I.5.3 L'émission acoustique .....	21
I.5.4 Thermographie .....	21
<b>I.6. Outils de traitement du signal vibratoire adaptés pour la recherche de défauts</b> .....	<b>22</b>
I.6.1 Indicateurs statistiques .....	22
I.6.2 Analyse spectrale .....	23
I.6.3 Analyse d'enveloppe .....	25
I.6.4 Analyse temps-fréquence .....	25
I.6.4.1 Transformée de Fourier à Court Terme (STFT) .....	25
I.6.4.2 Transformée en Ondelettes (WT) .....	26
I.6.4.3 Méthodes de décomposition adaptative .....	27
I.6.4.3.1 Transformée en Ondelettes Empiriques (EWT) .....	27
I.6.4.3.2 Décomposition en Modes Variationnels (VMD) .....	29
I.6.4.3.3 Décomposition en Modes Empiriques (EMD) .....	29

<b>I.7.</b>	<b>Etat de l’art.....</b>	<b>32</b>
<b>I.8.</b>	<b>Conclusion .....</b>	<b>35</b>
 <b>Chapitre II : Diagnostic basé sur les méthodes de l’intelligence artificielle</b>		<b>36</b>
<b>II.1</b>	<b>Introduction à l’intelligence artificielle .....</b>	<b>37</b>
<b>II.2</b>	<b>Stratégie d’un diagnostic intelligent de défauts .....</b>	<b>38</b>
II.2.1	Extraction d’indicateurs de défauts .....	38
II.2.2	Sélection et transformation d’indicateurs pour la réduction de dimensionnalité.....	39
II.2.2.1	Approche 01 : sélection d’indicateurs .....	40
II.2.2.2	Approche 02: transformation d’indicateurs.....	41
II.2.3	Classification de défauts.....	43
II.2.3.1	Apprentissage statistique conventionnel .....	43
II.2.3.1.1	Machine à Vecteurs de Support (SVM) .....	43
II.2.3.1.2	Réseau de Neurones Artificiels (ANN).....	49
II.2.3.1.3	Autres méthodes d’apprentissage conventionnel .....	52
II.2.3.2	Apprentissage profond (DL).....	53
II.2.3.2.1	Réseaux de neurones à convolution (CNN).....	54
II.2.3.2.2	Autres méthodes d’apprentissage profond.....	58
<b>II.3</b>	<b>Conclusion.....</b>	<b>59</b>
 <b>Chapitre III : Application au diagnostic des défauts de roulements</b>		<b>61</b>
<b>III.1</b>	<b>Introduction .....</b>	<b>62</b>
<b>III.2</b>	<b>Banc d’essai de « CWRU » .....</b>	<b>63</b>
<b>III.3</b>	<b>Partie 01 : Diagnostic des défauts à base du traitement EEMD à l’aide des méthodes conventionnelles d’apprentissage automatique .....</b>	<b>65</b>
III.3.1	Traitement de données.....	65
III.3.2	Analyse par décomposition modale empirique d’ensemble « EEMD ».....	65
III.3.3	La méthodologie de diagnostic proposée .....	66
III.3.4	Sélection d’IMF.....	66
III.3.5	Application de la méthode proposée sur la base de données de CWRU .....	68
III.3.5.1	Extraction d’indicateurs statistiques et classification de défauts.....	70
III.3.5.2	Evaluation de performance sous la même condition de charge et de vitesse .....	72
III.3.5.3	Evaluation de performance sous conditions de charge et de vitesse variables.....	72
<b>III.4</b>	<b>Partie 02 : Diagnostic des défauts à base de l’apprentissage profond .....</b>	<b>74</b>
III.4.1	Traitement de données.....	74
III.4.2	Méthodologie de diagnostic proposée .....	76
III.4.2.1	L’architecture proposée du modèle CNN.....	76
III.4.2.2	Evaluation de performance sous la même condition de charge et de vitesse .....	77

III.4.2.3	Evaluation de performance sous conditions de charge et de vitesse variables .....	79
III.4.2.4	Evaluation de performance sous conditions de bruit.....	80
<b>III.5</b>	<b>Conclusion.....</b>	<b>83</b>
<b>Chapitre IV : Application de la méthode EEMD-CNN pour le diagnostic des défauts de roulements</b>		<b>85</b>
<b>IV.1</b>	<b>Introduction .....</b>	<b>86</b>
<b>IV.2</b>	<b>Banc d’essai URMA/CRTI .....</b>	<b>86</b>
<b>IV.3</b>	<b>Diagnostic des défauts de roulements par la méthode proposée .....</b>	<b>89</b>
IV.3.1	Traitement de données.....	89
IV.3.2	La reconstruction des signaux vibratoires à base d’application d’EEMD.....	90
IV.3.3	Extraction des caractéristiques et classification des défauts.....	93
IV.3.3.1	La première méthode: EEMD-MCSVM .....	93
IV.3.3.2	La deuxième méthode:EEMD-2DCNN.....	95
IV.3.3.3	Évaluation de performance sous la même condition de vitesse .....	100
IV.3.3.4	Évaluation de performance sous des conditions de vitesses variables .....	103
IV.3.3.5	Évaluation sous différents quantités de données apprentissage/test.....	104
IV.3.4	Validation de la méthode proposée sur la base de données de CWRU .....	105
<b>IV.4</b>	<b>Conclusion.....</b>	<b>111</b>
<b>Conclusion générale et perspectives .....</b>		<b>113</b>
<b>Annexe : Caractéristiques des roulements de CWRU .....</b>		<b>117</b>
<b>Bibliographie.....</b>		<b>119</b>

# Liste des figures

<b>Chapitre I : Introduction aux machines tournantes, principales défaillances et techniques de surveillance</b>	<b>5</b>
<b>Figure I.1</b> Constitution d'un roulement à bille. ....	10
<b>Figure I.2</b> Principaux types de roulements. ....	10
<b>Figure I.3</b> Exemples de défaillances affectant les roulements; <i>a: grippage, b: fracture, c: usure de contact, d: corrosion de contact, e: écaillage de la bague interne.</i> ....	11
<b>Figure I.4</b> Différents types d'engrenages utilisés dans l'industrie; <i>a: engrenage droit à denture droite, b: engrenage droit à denture hélicoïdale, c: engrenage conique, d: engrenage roue et vis sans fin.</i> ....	12
<b>Figure I.5</b> Défauts de piqûres ou pitting. ....	12
<b>Figure I.6</b> Défauts de grippage. ....	13
<b>Figure I.7</b> Défauts d'engrenages; <i>a: écaillage, b: fissuration de dent, c: rupture de dents.</i> ....	13
<b>Figure I.8</b> Écart d'usinage: excentricité et parallélisme. ....	14
<b>Figure I.9</b> Défauts d'alignement. ....	15
<b>Figure I.10</b> Principe des méthodes de diagnostic à base de modèles. ....	17
<b>Figure I.11</b> Chaîne d'acquisition de données. ....	18
<b>Figure I.12</b> Organigramme de l'algorithme EEMD. ....	31
<b>Chapitre II : Diagnostic basé sur les méthodes de l'intelligence artificielle</b>	<b>36</b>
<b>Figure II.1</b> Exemple d'hyperplan séparateur d'une classification binaire par l'outil SVM. ....	45
<b>Figure II.2</b> MCSVM avec la technique Un-Contre-Un (OVO). ....	46
<b>Figure II.3</b> MCSVM avec la technique Un-Contre-Tous (OVA). ....	48
<b>Figure II.4</b> Exemple d'un réseau de neurones artificiels. ....	50
<b>Figure II.5</b> Modèle d'un neurone artificiel. ....	51
<b>Chapitre III : Application au diagnostic des défauts de roulements</b>	<b>61</b>
<b>Figure III.1</b> Banc d'essai de l'Université CWR. ....	64
<b>Figure III.2</b> Signaux de vibration sous charge de 0 hp. ....	64
<b>Figure III.3</b> Signal vibratoire et ses 9 premiers IMFs sous le défaut de la cage intérieure (à une charge de 0 hp et une vitesse égale à 1797 tr/min). ....	69
<b>Figure III.4</b> Procédure de sélection d'IMF après la décomposition du signal IRF par l'EEMD. ....	69
<b>Figure III.5</b> Nouveaux signaux vibratoires reconstruits sous la condition de charge 1 hp. ....	70
<b>Figure III.6</b> Organigramme de l'approche utilisée. ....	71
<b>Figure III.7</b> Processus de conversion du signal 1D en image vibratoire 2D. ....	75
<b>Figure III.8</b> Images vibratoires correspondantes à la charge 0 hp. ....	75
<b>Figure III.9</b> Organigramme de la méthode proposée pour le diagnostic de défauts. ....	77
<b>Figure III.10</b> Matrice de confusion détaillant les résultats du diagnostic dans la même condition de charge et de vitesse (la même matrice de confusion pour les 4 expériences). ....	78
<b>Figure III.11</b> Signaux vibratoires bruités sous une valeur de SNR = -4 Db. ....	81

<b>Figure III.12</b> Histogramme des performances de la technique proposée dans différentes conditions de bruit. ....	82
<b>Figure III.13</b> Matrice de confusion obtenue à la 3ème expérience (le cas SNR= - 4db). ....	83
<b>Chapitre IV : Application de la méthode EEMD-CNN pour le diagnostic des défauts de roulements</b>	<b>85</b>
<b>Figure IV.1</b> Banc d'essai du CRMA/CRTI. ....	87
<b>Figure IV.2</b> Étape d'acquisition de données. ....	87
<b>Figure IV.3</b> Roulements défectueux utilisés dans notre travail : (a)- <i>Défaut de la cage interne « IRF »</i> , (b)- <i>Défaut de la bille « BAF »</i> , (c)- <i>Défaut de la cage externe « ORF »</i> . ....	88
<b>Figure IV.4</b> Signaux vibratoires sous la même condition de vitesse ( <i>fréquence de rotation équivalente à de 35 Hz</i> ). ....	89
<b>Figure IV.5</b> Segmentation imbriquée des signaux de vibration ....	90
<b>Figure IV.6</b> Signal de vibration et ses 9 premiers IMFs sous défaut de cage interne à une vitesse de 30Hz. ....	91
<b>Figure IV.7</b> Exemple décrivant la procédure de sélection d'IMFs et de reconstruction des signaux vibratoires après le traitement d'EEMD. ....	92
<b>Figure IV.8</b> Signaux de vibration originaux contre les signaux reconstruits sous une fréquence de rotation équivalente à 30Hz. ....	92
<b>Figure IV.9</b> Organigramme des méthodes de diagnostic proposées. ....	93
<b>Figure IV.10</b> Images vibratoires construites relatives à l'ensemble de données A ( <i>fréquence de rotation équivalente à 30 Hz</i> ). ....	96
<b>Figure IV.11</b> Architecture du réseau CNN proposé. ....	99
<b>Figure IV.12</b> Matrices de confusion détaillant les résultats de test obtenus par la méthode EEMD-CNN. ....	101
<b>Figure IV.13</b> Performances d'apprentissage et de classification sous vitesses variables. ....	103
<b>Figure IV.14</b> Matrices de confusion relatives aux deux derniers cas étudiés. ....	105
<b>Figure IV.15</b> Tous les signaux reconstruits sous une charge de 2 hp. ....	108
<b>Figure IV.16</b> Matrice de confusion dans différentes conditions de charge pour 20% d'images vibratoires utilisées dans la phase d'apprentissage. ....	109

# Liste des tableaux

<b>Chapitre I : Introduction aux machines tournantes, principales défaillances, et techniques de surveillance</b>	<b>5</b>
<b>Tableau I.1</b> Principales techniques de diagnostic et leurs utilisations. ....	8
<b>Tableau I.2</b> Indicateurs statistiques les plus utilisés avec leurs définitions mathématiques. ....	23
<b>Tableau I.3</b> Fréquences caractéristiques des principales défaillances affectant les machines tournantes. ....	24
<b>Chapitre II : Diagnostic basé sur les méthodes de l'intelligence artificielle</b>	<b>36</b>
<b>Tableau II. 1</b> Les fonctions d'activation les plus utilisées dans les réseaux CNN. ....	55
<b>Chapitre III : Application au diagnostic des défauts de roulements</b>	<b>61</b>
<b>Tableau III.1</b> Les différentes classes sélectionnées de la base de donnée de <i>CWRU</i> . ( <i>ORF</i> : défaut de la cage externe, <i>IRF</i> : défaut de la cage interne, <i>BAF</i> : défaut de la bille).....	64
<b>Tableau III.2</b> Arrangement de données vibratoires après la segmentation.....	65
<b>Tableau III.3</b> Indicateurs temporels extraits à partir des signaux reconstruits. ....	71
<b>Tableau III.4</b> Résultats de classification de différents classifieurs sous la même condition de charge et de vitesse. ....	72
<b>Tableau III.5</b> Résultats de classification de différents classifieurs sous des conditions variables de charge et de vitesse.....	73
<b>Tableau III.6</b> Disposition des images vibratoires construites. ....	75
<b>Tableau III.7</b> Structure de notre modèle CNN.....	76
<b>Tableau III.8</b> Résultats de classification par notre méthode de diagnostic de défauts.....	78
<b>Tableau III.9</b> Taux de classification sous des conditions de charge et de vitesse variables. ....	80
<b>Tableau III.10</b> Résultats de classification par rapport au nombre de filtres dans les deux couches de convolution.....	82
<b>Chapitre IV : Application de la méthode EEMD-CNN pour le diagnostic des défauts de roulements</b>	<b>85</b>
<b>Tableau IV.1</b> Les spécifications techniques des roulements utilisés.....	88
<b>Tableau IV.2</b> Labellisation des différents états de roulements. ....	88
<b>Tableau IV.3</b> Distribution des ensembles de données.....	90
<b>Tableau IV.4</b> Caractéristiques statistiques extraites dans le domaine temporel et fréquentiel. ....	94
<b>Tableau IV.5</b> Résultats de la classification en utilisant le MCSVM. ....	94
<b>Tableau IV.6</b> Distribution des ensembles d'images vibratoires.....	96
<b>Tableau IV.7</b> Description des hyper-paramètres du modèle CNN de référence. ....	98
<b>Tableau IV.8</b> Résultats de classification du modèle CNN sous différentes fonctions d'activation utilisées.....	99

<b>Tableau IV.9</b> Résultats obtenus dans la phase de test des classifieurs MCSVM et Softmax dans quatre conditions de fonctionnement.....	100
<b>Tableau IV.10</b> Résultats de classification de notre technique EEMD-CNN sous des quantités variables d'images vibratoires dans le processus apprentissage/test. ....	104
<b>Tableau IV.11</b> Défauts de roulements étudiés. ....	106
<b>Tableau IV.12</b> Arrangement des ensembles d'images vibratoires de CWRU après les processus de reconstruction de signaux et de conversion 1D à 2D. ....	107
<b>Tableau IV.13</b> Résultats de classification obtenus par l'application de la méthode de diagnostic proposée EEMD-CNN. ....	107
<b>Tableau IV.14</b> Résultats de comparaison des performances de classification des techniques de diagnostic existantes dans la littérature utilisant les données vibratoires de CWRU. ....	110
<b><u>Annexe :</u></b> Caractéristiques des roulements de CWRU	<b>117</b>
<b>Tableau A.1</b> Spécifications de défauts des roulements. ....	117
<b>Tableau A.2</b> Caractéristiques du roulement coté entraînement.....	117
<b>Tableau A.3</b> Fréquences caractéristiques des défauts (roulement coté entraînement) .....	118
<b>Tableau A.4</b> Caractéristiques du roulement coté ventilateur.....	118
<b>Tableau A.5</b> Fréquences caractéristiques des défauts (roulement coté ventilateur).....	118

# Liste des abréviations

AE	Emission Acoustique
AMC	Composantes Modulées en Amplitude
ANFIS	Système Neuro-Flou Adaptatif
ANN	Réseau de Neurones Artificiels
BPNN	Réseau de Neurones à Rétro-Propagation
CFT	Transformée de Fourier Continue
CL	Couche de Convolution
CM	Surveillance Conditionnelle
CNN	Réseau de Neurones de Convolution
CRTI	Centre de Recherche en Technologie Avancée
CWRU	Université de Case Western Reserve
CWT	Transformée en Ondelettes Continues
DBN	Réseau de Croyance Profonde
DFT	Transformée de Fourier Discrète
DL	Apprentissage Profond
DNN	Réseau de Neurones Profond
DT	Arbre de Décision
DWT	Transformée en Ondelettes Discrètes
EDM	Usinage par Décharge Electrique
EEMD	Décomposition Modale Empirique d'Ensemble
ELM	Machine d'Apprentissage Extrême
EMD	Décomposition Modale Empirique
EWT	Transformée en Ondelettes Empiriques
FFT	Transformée de Fourier rapide
FL	Couche Entièrement Connectée
FMC	Composantes Modulées en Fréquence
FT	Transformée de Fourier
HHT	Transformée d'Hilbert-Huang

HT	Transformée d'Hilbert
IA	Intelligence Artificielle
ICA	Analyse en Composantes Indépendantes
IMF	Fonction en Mode Intrinsèque
KNN	Les K plus Proches Voisins
LDA	Analyse Discriminante Linéaire
LSTM	Mémoire à Court-Terme Long-Terme
MCSVM	Machine à Vecteur de Support Multi-Classe
ML	Apprentissage Machine
MLP	Perceptron Multicouches
MPC	Maintenance Préventive Conditionnelle
NB	Bayésien Naïf
PCA	Analyse en Composantes Principales
PNN	Réseau de Neurones Probabilistes
RBF	Réseau à Fonction de Base Radiale
Relu	Unité Linéaire Rectifiée
RMS	Racine Quadratique Moyenne
RNN	Réseau de Neurones Récurent
SL	Couche de Sous-échantillonnage
SNR	Rapport Signal sur Bruit
STFT	Transformée de Fourier à Court Terme
Tanh	Tangente Hyperbolique
VMD	Décomposition en Mode Variationnel
WPT	Transformée en Paquets d'Ondelettes
WT	Transformée en Ondelettes

# INTRODUCTION GÉNÉRALE

**L**e besoin d'un plan ou d'un système efficace de contrôle, de surveillance de l'état des machines ainsi que leurs entretiens, existe partout dans les firmes de l'industrie moderne dans divers domaines où des machines complexes et coûteuses sont implémentées afin d'assurer les fonctions essentielles des entreprises.

A titre d'exemple, les entreprises manufacturières font de leur mieux pour réduire les coûts de maintenance et améliorer la qualité des produits afin de maintenir leurs compétitivités mondiales.

La machine tournante est un élément central du processus de fabrication où son état 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.

Cette dernière peut être réalisée en utilisant deux approches principales, à savoir, la maintenance corrective et la maintenance préventive [1].

La maintenance corrective est la technique la plus élémentaire, utilisées après la manifestation d'un défaut, peut être très coûteuse surtout dans le cas d'utilisation de machines tournantes aux applications à grande échelle.

Quant à la maintenance préventive peut être appliquée pour éviter une défaillance à l'aide d'une maintenance basée sur les conditions, ce que l'on appelle « MPC : maintenance préventive conditionnelle » [2, 3]. De nombreuses études ont montré les divers avantages économiques de la MPC liés à plusieurs applications des machines tournantes [4- 6].

Dans la MPC, la décision de maintenance est prise en fonction de l'état de santé actuel de la machine, qui peut être identifié à travers le système de surveillance conditionnelle (CM). Une fois qu'un défaut se produit, la technique CM permet une détection précoce des défauts et une identification correcte du type de défauts. Ainsi, plus le système CM est précis et sensible, plus la décision de maintenance est correcte et plus de temps pour planifier et effectuer la maintenance avant la dégradation totale de la machine ou de l'installation entière.

La surveillance de l'état des composants des machines tournantes est un aspect important à prendre en considération dans les différentes politiques de gestion de tout système de production, afin de minimiser le risque de défaillance, en identifiant l'état de santé de la machine à travers une détection précoce des défauts.

L'objectif principal de la CM est d'éviter une défaillance catastrophique affectant la machine, pouvant entraîner des dommages secondaires, des temps d'arrêt, une perte de production, des incidents potentiels de sécurité et des coûts plus élevés associés aux réparations.

Les techniques de CM englobent la pratique de la surveillance de données mesurables (par exemple, les vibrations, l'acoustique, la température etc.), qui peuvent être utilisées individuellement ou ensemble pour analyser les changements dans l'état de la machine. Cela permet d'organiser le programme MPC ou de prendre d'autres mesures pour éviter les pannes au niveau de l'installation [7].

La surveillance s'appuie essentiellement sur l'extraction d'informations révélatrices contenant les signatures de défauts à partir des données acquises de plusieurs sources d'information, qui peuvent être regroupées comme suit : analyse des vibrations, analyse d'huile, analyse des émissions acoustiques, analyse du courant électrique, et analyse de la température, etc. Parmi ces techniques, la surveillance de l'état des roulements basée sur les vibrations, qui a été largement étudiée, est devenue la technique la plus répandue dans de nombreuses directions de maintenance [8].

En réalité, les différents types de défauts génèrent différents modèles de spectres de vibration, et éventuellement par l'analyse de ces vibrations nous pouvons examiner les parties internes de la machine et même identifier son état de santé sans l'ouvrir physiquement.

Les techniques de surveillance basées sur l'analyse vibratoire visent à analyser les caractéristiques physiques contenues dans les signaux de vibration acquis, où la problématique de diagnostic repose sur la possibilité de classer correctement le signal vibratoire acquis dans l'état correspondant, ce qui est généralement un problème de classification multi-classe.

Pour surveiller l'état de fonctionnement des machines tournantes, qui sont le cœur de l'industrie moderne, il est impératif de développer de nouvelles méthodes de surveillance conditionnelle, qui n'ont pas seulement la capacité de réaliser une détection et une identification précise des états de santé de la machine, mais sont également capable de relever deux défis principaux : réduction des coûts d'apprentissage à partir d'une grande quantité de données vibratoires et enfin, la réalisation d'une détection précise et précoce de défauts.

La portée fondamentale de cette thèse est le développement et l'application des méthodes de diagnostic à base d'analyse vibratoire d'une grande quantité de données de vibration acquises pour la surveillance de l'état des roulements.

L'objectif principal de cette analyse est d'implémenter un traitement spécifique à base d'EEMD (décomposition modale empirique d'ensemble) qui sert à décomposer le signal vibratoire et extraire ses fonctions en modes intrinsèques (IMF).

Les IMF extraites sont soumises à une procédure de sélection, où les modes choisis sont utilisés pour reconstruire le signal vibratoire, qui est exploité ensuite dans la phase d'extraction d'indicateurs et de classification.

Cette technique de traitement vise à éliminer le bruit résiduel dans les signaux originaux et conserver ainsi les informations utiles contenant les signatures de défauts, afin de rendre l'information claire, ce qui facilite la tâche d'extraction d'indicateurs utiles et améliore significativement la performance de la classification.

Cette étude présente aussi plusieurs méthodes de diagnostic exploitant les outils de l'intelligence artificielle, notamment l'apprentissage profond, exploité et appliqué pour la surveillance des défauts de roulements sous différentes conditions opérationnelles, à savoir, des contraintes variables de charge, de vitesse et de bruit.

L'EEMD est utilisé comme un outil de traitement de signal et les réseaux de neurones de convolution, sont implémentés comme un extracteur automatique d'indicateurs de défauts et leur combinaison, nous permet de fournir un diagnostic efficace, à savoir : l'amélioration de la performance de détection précoce de défauts et la diminution du coût d'apprentissage.

Les travaux menés dans cette étude regroupent quatre chapitres :

Le premier chapitre se présente comme une introduction dans le domaine des machines tournantes, où ses principales défaillances, les stratégies et techniques mises en place pour leur surveillance, seront décrites. Une synthèse bibliographique sera dressée à la fin de ce chapitre afin de visualiser quelques applications dans le domaine de détection et diagnostic des défauts affectant les machines tournantes.

Le deuxième chapitre est destiné pour décrire la procédure d'un diagnostic intelligent en utilisant les outils de l'intelligence artificielle. Ce processus de diagnostic a été abordé en trois étapes clés, qui seront largement décrites et détaillées [9] : (i) Extraction d'indicateurs pertinents contenant les signatures de défauts à partir les signaux vibratoires collectés ; (ii) Transformation et sélection d'information afin de réduire la dimensionnalité des vecteurs d'entrée ; (iii) Classification des défauts pour prendre une décision concernant l'état de santé de la machine. Chaque étape est accompagnée par un état de l'art présentant quelques applications de différentes techniques d'IA dans le cadre du diagnostic des machines tournantes avec une attention particulière donnée au diagnostic des défauts de roulements.

Dans le troisième chapitre, nous employons plusieurs applications pour le diagnostic des défauts de roulements en utilisant des données réelles extraites de la source universelle ouverte CWRU. Ce chapitre est scindé en deux parties :

La première partie présente une approche conventionnelle basée sur le traitement de l'EEMD dans laquelle les indicateurs sont extraits manuellement. L'application d'EEMD était suivie par une procédure de sélection d'IMF dans le but de choisir les fonctions intrinsèques les plus pertinentes qui sont exploitées ensuite pour reconstruire à nouveau ces signaux vibratoires avec moins de bruit. Les indicateurs statistiques extraits manuellement de ses signaux reconstruits, sont exploités pour construire un vecteur de caractéristique utilisé ensuite comme une entrée à plusieurs classifieurs.

La deuxième partie est basée sur l'application d'une méthode de diagnostic par l'apprentissage profond. Cette technique est totalement différente à celles appliquées dans la première partie et elle repose principalement sur la conversion des signaux vibratoires en

images en niveaux de gris utilisées ensuite comme une entrée à un réseau de neurone de convolution. Cette méthode est autonome, ne nécessite aucun traitement de signal et aucune extraction manuelle d'indicateurs ; où la méthode proposée est testée sous diverses conditions opérationnelles liées aux variations de la charge, de la vitesse et du bruit.

Quant au quatrième chapitre nous exposons la méthode originale basée sur la combinaison d'EEMD et CNN. Ses 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 sévérités et ce en utilisant des signaux vibratoires acquis à partir du banc d'essai de CRMA/CRTI et de CWRU.

Cette thèse a fait l'objet des travaux suivants :

**Article de revue :**

Amarouayache, I.I.E., Saadi, M.N., Guersi, N. et al. "Bearing fault diagnostics using EEMD processing and convolutional neural network methods". *Int J Adv Manuf Technol* 107, 4077–4095 (2020). <https://doi.org/10.1007/s00170-020-05315-9>.

**Article de conference:**

Amarouayache, I.I.E., Saadi, M.N., Guersi, N. "Bearing Fault Diagnosis Method Based on Vibration Image and Convolutional Neural Network". Conference: Multi-Conference OCTA on: "Organization of Knowledge and Advanced Technologies." Tunisia, 5-8 February 2020.

# Chapitre I : Introduction aux machines tournantes, principales défaillances et techniques de surveillance

## **I.1. Introduction**

Les objectifs assignés de performances des machines tournantes exigent une attention particulière de la part des concepteurs et les utilisateurs pour assurer une continuité de fonctionnement en anticipant les phénomènes de défaillance.

Au-delà de la continuité de fonctionnement des systèmes, les performances exigées sont plus globales, d'où on parle de la sureté de fonctionnement, ce qui regroupe la fiabilité, la minimisation des risques majeurs (humains, environnementaux, de sécurité), ainsi que la réduction des coûts de maintenance des parcs de machines et des éventuels arrêts forcés liés aux pannes.

Cependant, les exigences liées à la sécurité de fonctionnement de telles machines jouent un rôle important dans les contraintes qu'elles apportent. Par conséquent, il est essentiel d'intégrer les modules de surveillance et de diagnostic dans de telles applications, afin que les utilisateurs et même les concepteurs puissent être alertés immédiatement en cas de défaut pour garantir la sécurité et l'intégrité du système. Afin de répondre à ces exigences, le but de notre travail repose et propose une approche de diagnostic de défauts basée sur l'analyse des signaux vibratoires, issus principalement des machines tournantes.

Le travail effectué dans cette thèse s'intéresse aux défauts de roulements. Plusieurs études sur les machines tournantes ont montré que les roulements sont les organes les plus susceptibles d'engendrer des défaillances. La défaillance du roulement peut être d'origine mécanique (fatigue, désalignement, manque de lubrifiant) ou électrique. L'alimentation des machines par variateurs industriels induit de nouveaux phénomènes électriques de hautes fréquences conduisant à une dégradation accélérée des roulements. Dans le but d'améliorer la maintenance prédictive et la continuité de service des machines tournantes, les travaux de cette thèse s'intéressent en particulier à la surveillance de l'état de santé des roulements en présence d'un défaut.

Ce chapitre est présenté comme une introduction au domaine des machines tournantes.

Une fois leur criticité démontrée, les différents défauts susceptibles d'altérer leur fonctionnement, ainsi que les techniques et moyens actuellement mis en place pour leur surveillance seront décrits. Enfin, un état de l'art dans la surveillance des machines tournantes sera érigé et des conclusions seront extraites pour orienter les axes de recherche de ces travaux de thèse.

## I.2. Politiques et objectifs de la maintenance

Avant les années 1950, l'industrie a entamé ses premières étapes de développement où les systèmes étaient dotés d'une conception simple et d'une mécanisation très limitée.

La première approche de maintenance peut être décrite comme la maintenance corrective [10], et visait à faire fonctionner les équipements et les machines jusqu'à l'apparition d'une panne, ce qui conduisait à un arrêt de production qui pouvait être important et coûteux financièrement, et qui pouvait en plus mettre en danger la sécurité des personnes en contact avec cet équipement.

L'évolution de la technologie en nombre et en complexité était dans le but de répondre aux besoins des industries de production de masse qui doivent faire face à des marchés de plus en plus tendus. Ceci a imposé des exigences sécuritaires plus strictes en termes de maîtrise des moyens de production et a permis la naissance des premières politiques de maintenance préventive.

La maintenance préventive est effectuée selon des critères prédéterminés, dont l'objectif est de réduire la probabilité de défaillance ou la dégradation d'un système. Il existe deux types de maintenance préventive à savoir :

- Maintenance préventive systématique.
- Maintenance préventive conditionnelle.

Les opérations de la maintenance préventive systématique sont exécutées conformément à un calendrier déterminé a priori dans le but de rétablir complètement ou partiellement la fonction requise d'une installation. Cette approche de maintenance est intéressante dans le cas des systèmes ayant une productivité monotone et un coût d'entretien faible [11].

La maintenance préventive conditionnelle que l'on appelle aussi maintenance prédictive, est la stratégie de maintenance la plus efficace et elle est subordonnée à un type d'événement prédéterminé où les actions reposent sur la surveillance du fonctionnement du système et / ou des paramètres de fonctionnement importants.

Ces paramètres significatifs de fonctionnement sont des mesures caractéristiques des systèmes telles que les vibrations, le degré d'érosion, la température, etc. On peut voir dans le tableau I.1, une liste non exhaustive des principales sources d'information et leur utilisation pour le cas spécifique des machines tournantes [13].

**Tableau I.1** Principales techniques de diagnostic et leurs utilisations [13].

<b>Source d'information</b>	<b>Principaux avantages</b>	<b>Principales limitations</b>	<b>Champ d'applications Privilégié</b>
<b>Analyse d'huile</b>	<ul style="list-style-type: none"> <li>-Détection d'une pollution anormale du lubrifiant, avant que celle-ci n'entraîne une usure ou un échauffement.</li> <li>-Possibilité de connaître l'origine de l'anomalie par analyse des particules.</li> </ul>	<ul style="list-style-type: none"> <li>– Ne permet pas de localiser précisément le défaut.</li> <li>– Nécessite de prendre de nombreuses précautions dans le prélèvement de l'échantillon.</li> </ul>	<ul style="list-style-type: none"> <li>-Contrôle des propriétés physico-chimiques du lubrifiant, détection d'un manque de lubrification, analyse des éléments d'usure, analyse de contamination par le process (étanchéité), etc.</li> </ul>
<b>Thermographie IR</b>	<ul style="list-style-type: none"> <li>– Permet de réaliser un contrôle rapide de l'installation.</li> <li>– Interprétation souvent immédiate des résultats.</li> </ul>	<ul style="list-style-type: none"> <li>– Détection de défauts à un stade moins précoce que l'analyse vibratoire.</li> <li>– Contrôle limité à ce que " voit" la caméra (échauffements de surface).</li> <li>– Ne permet pas de réaliser un diagnostic approfondi.</li> </ul>	<ul style="list-style-type: none"> <li>– Détection de tous les défauts engendrant un échauffement (manque de lubrification en particulier).</li> </ul>
<b>Analyse acoustique</b>	<ul style="list-style-type: none"> <li>– Permet de détecter l'apparition de défauts audibles.</li> <li>– Autorise une surveillance continue.</li> </ul>	<ul style="list-style-type: none"> <li>– Sensibilité au bruit ambiant.</li> <li>– Diagnostic souvent difficile à réaliser.</li> <li>– Problèmes de répétabilité des mesures.</li> </ul>	<ul style="list-style-type: none"> <li>– Détection d'un bruit inhabituel pouvant ensuite être analysé par analyse vibratoire.</li> </ul>
<b>Analyse vibratoire</b>	<ul style="list-style-type: none"> <li>– Détection de défauts à un stade précoce.</li> <li>– Possibilité de réaliser un diagnostic approfondi.</li> <li>– Autorise une surveillance continue.</li> <li>– Permet de surveiller l'équipement à distance (télémaintenance).</li> </ul>	<ul style="list-style-type: none"> <li>– Spectres parfois difficiles à interpréter.</li> <li>– Dans le cas de la surveillance continue, installations relativement coûteuses.</li> </ul>	<ul style="list-style-type: none"> <li>– Détection des défauts de tous les organes cinématiques de la machine (balourd, défauts d'alignement, jeux, etc.) et de sa structure.</li> </ul>

Les objectifs principaux d'une stratégie de maintenance préventive sont [14] :

- Diminuer les probabilités de la manifestation des défaillances au niveau des installations en service afin de réduire les temps d'arrêt en cas de révision ou de panne.
- Empêcher et prévoir les interventions coûteuses de la maintenance corrective.
- Augmenter la durée de vie des équipements en optimisant la stratégie de surveillance et d'entretien des installations.
- Maitriser la production et optimiser les ressources financières des entreprises afin qu'elles puissent rester compétitives.
- Meilleure gestion du budget de maintenance en réduisant la consommation irrégulière des pièces détachées, d'énergie et de lubrifiant.
- Améliorer les conditions de travail du personnel de production en prévenant les risques d'accidents.

### **I.3. Principales défaillances des machines tournantes**

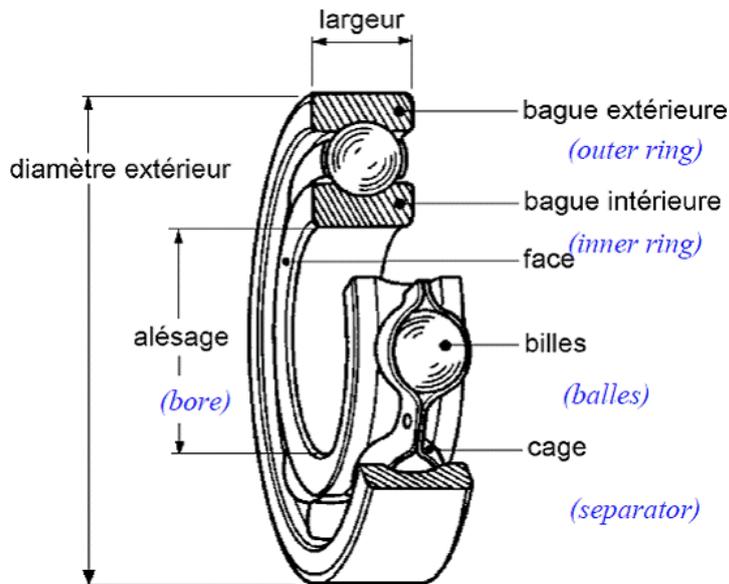
#### **I.3.1 Défaits de roulement**

Une étude statistique effectuée par Bonnett en 2008, a dévoilé que 69% de défaillances affectant les moteurs asynchrones à grande puissance, sont des défauts de roulements [106]. Cela signifie que les roulements sont les organes les plus importants et les plus fragiles des machines tournantes.

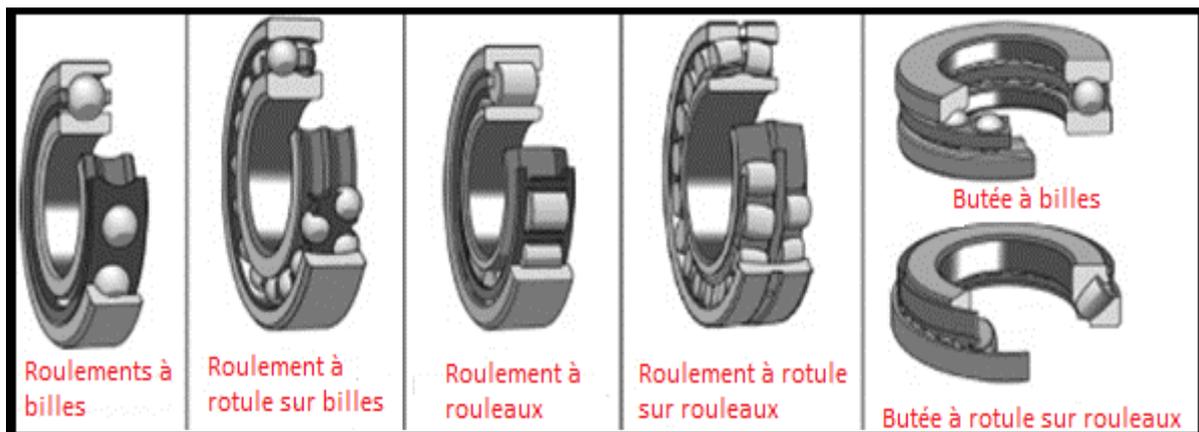
Ces composants sont conçus pour assurer plusieurs fonctions parmi lesquelles : assurer la liaison mobile en rotation entre deux surfaces avec un minimum de frottement et en supportant des différentes charges radiales ou axiales ; corriger les défauts d'alignement en assurant un positionnement précis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

Un roulement est généralement composé de quatre éléments essentiels : une bague extérieure, une bague intérieure, un liquide lubrifiant et des éléments roulants qui peuvent être des billes, des rouleaux ou même des aiguilles.

En pratique, le choix du roulement adéquat dépend du type d'application à réaliser où chaque classe de roulement détient des caractéristiques spécifiques en termes de vitesse limite de rotation, de charges radiales et axiales supportées ou même de défaut d'alignement admissible. La figure I.1 montre les différents composants d'un roulement à bille et les principaux types de roulements sont illustrés dans la figure I.2.



**Figure I.1** Constitution d'un roulement à bille.



**Figure I.2** Principaux types de roulements [102].

On peut distinguer plusieurs avaries affectant les roulements, et causées par quatre grandes familles de causes, qu'on peut les répertoriées comme suit [103-105] :

- 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 les défauts 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.

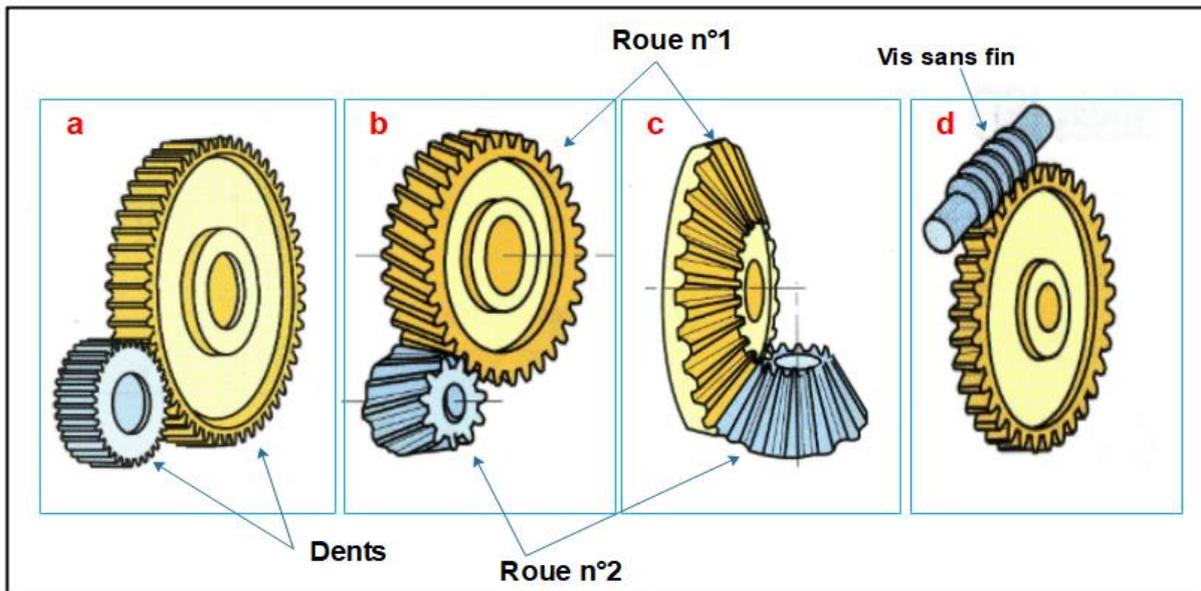
La figure I.3 montre quelques exemples des principales défaillances altérant le fonctionnement des roulements.



**Figure I.3** Exemples de défaillances affectant les roulements ; *a*: grippage, *b*: fracture, *c*: usure de contact, *d*: corrosion de contact, *e*: écaillage de la bague interne.

### I.3.2 Défauts d'engrenage

Les engrenages sont des organes vitaux et des mécanismes élémentaires dans la constitution d'une machine tournante. Cet organe est composé de deux roues dentées, dont l'une entraîne l'autre par l'action de dents en contact, et qui tournent autour d'un axe de rotation à des vitesses différentes. Ils sont utilisés pour transmettre le mouvement de rotation d'un axe à un autre, changer la direction du mouvement rotatif et même pour adapter les vitesses de rotation. La figure I.4 montre les différents types d'engrenage utilisés dans l'industrie.

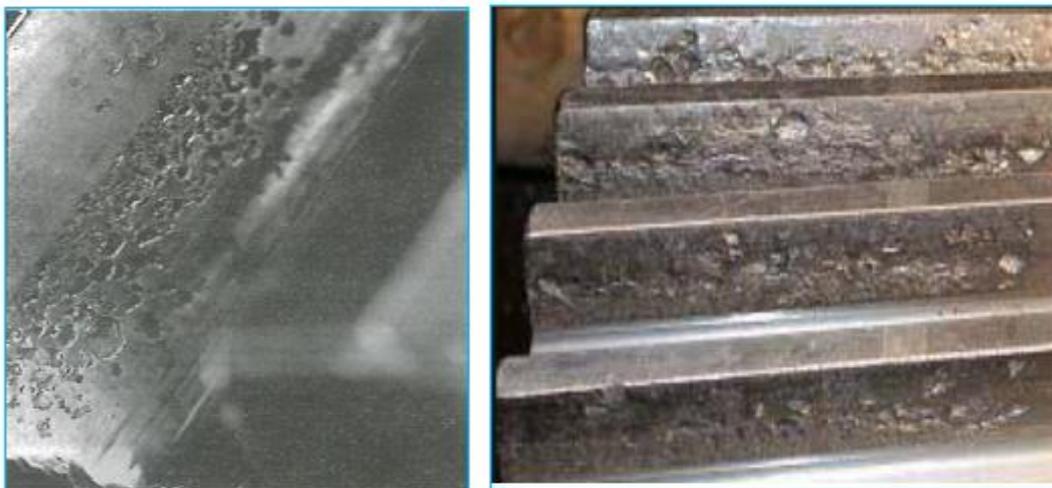


**Figure I.4** Différents types d'engrenages utilisés dans l'industrie ; *a: engrenage droit à denture droite, b: engrenage droit à denture hélicoïdale, c: engrenage conique, d: engrenage roue et vis sans fin.*

Les engrenages sont des organes sensibles dans la chaîne cinématique de la machine et ils sont soumis à un grand nombre d'avaries qui peuvent apparaître lors de leurs fonctionnements dans des conditions de travail pénible. Les figures I.5, I.6 et I.7 illustrent quelques exemples de défauts abimant le fonctionnement sain des engrenages.

Si on met à l'écart les défauts de fabrication et de montage (comme excentricité des roues et les défauts de parallélisme), on peut distinguer principalement deux catégories de défauts pouvant altérer le fonctionnement normal des engrenages [12] :

- Défauts généralisés : sont des défauts qui affectent une grande partie ou toutes les dents d'engrenage comme l'usure abrasive et les piqûres (ou pitting).

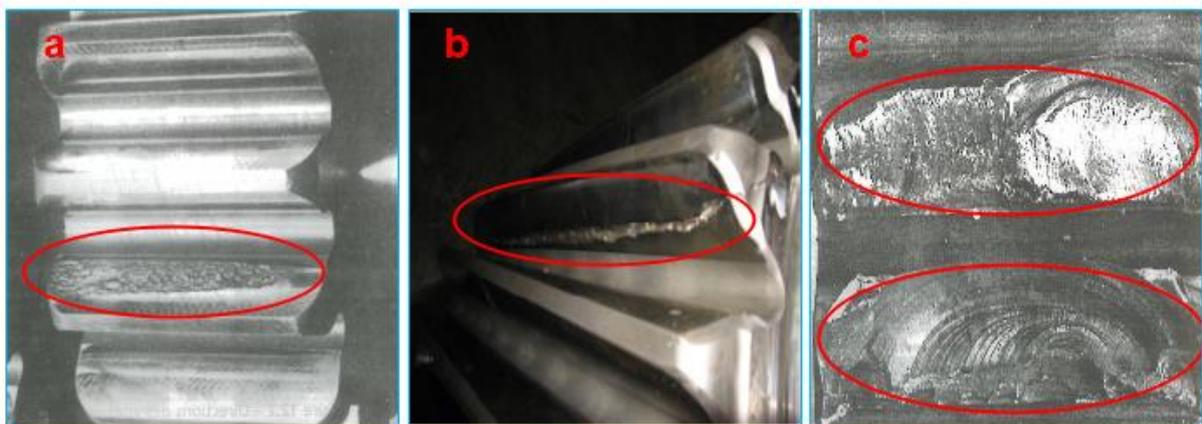


**Figure I.5** Défauts de piqûres ou pitting.

- Défauts localisés : sont généralement des défauts qui se localisent sur des dents particulières et ils peuvent conduire rapidement à la rupture de ces dents, comme l'écaillage, le grippage et la fissuration.



**Figure I.6** Défauts de grippage.



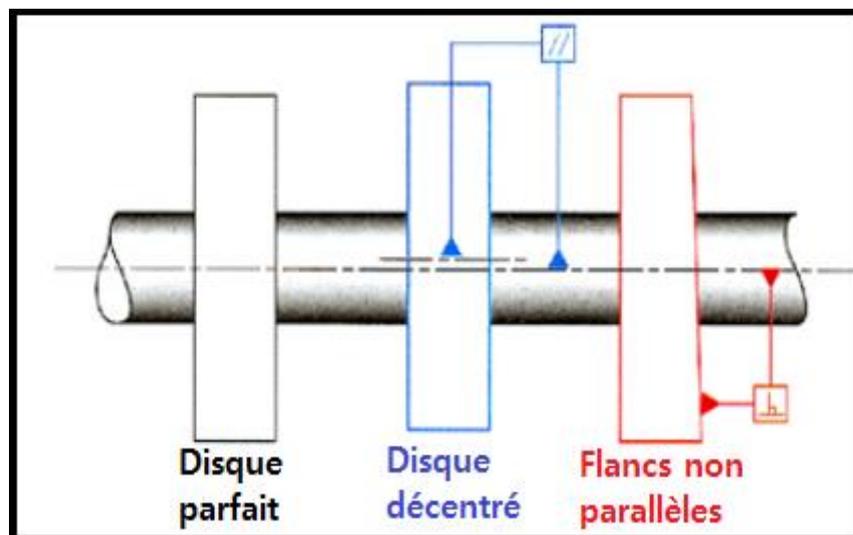
**Figure I.7** Défauts d'engrenages ; *a*: écaillage, *b*: fissuration de dent, *c*: rupture de dents.

### I.3.3 Le balourd

Le balourd ou encore appelé défaut d'équilibrage, est la cause des vibrations la plus fréquemment rencontrée au niveau des machines tournantes. Il est dû à une distribution inégale de la masse d'un rotor autour de son axe.

En réalité, il est impossible de faire coïncider l'axe de rotation avec le centre de gravité de chaque tranche élémentaire du rotor lors de la construction des machines. Les causes de l'apparition d'un déséquilibre (balourd) sont multiples, et ils peuvent avoir comme origines :

- Défaut d'usinage d'assemblage des rotors ou de montage. La figure I.8 clarifie les problèmes d'excentricité et de parallélisme des balourds dus aux écarts d'usinage.
- Balourd évolutif : ce phénomène est dû généralement aux frottements de l'arbre avec un des paliers de la machine tournante, ce qui provoque un échauffement dissymétrique.
- Origines mécaniques : comme la dégradation des pales ou aubages, l'érosion ou dépôt de matière et fluage du rotor, etc.
- Origines thermiques : où la variation de la température modifie la géométrie des parties tournantes, ce qui conduit à une déformation des rotors, fissuration transverse de l'arbre, dissymétrie d'arbre, glissement et dilatation contrariée des bobinages de machines électriques.



**Figure I.8** Écarts d'usinage : excentricité et parallélisme.

### I.3.4 Défauts d'alignement

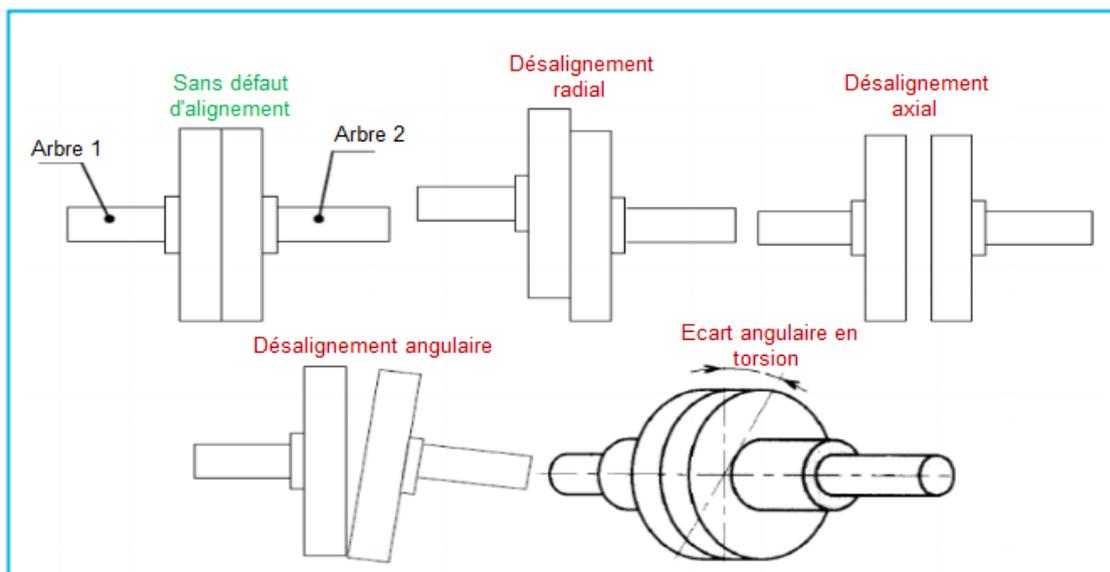
L'arbre est une partie fondamentale de la machine tournante, et il sert à assurer la transmission de la puissance et du mouvement de rotation. Cet organe joue aussi le rôle d'un élément de soutien et de liaison pour les autres parties de la machine.

Le défaut d'alignement connu aussi sous les noms 'désalignement ou délignage', est un problème presque aussi commun que le balourd et il peut apparaître lorsque les axes de rotation de deux ou plusieurs arbres de machines, ne sont pas parfaitement alignés. La figure I.9 montre les différents types de désalignement.

Ce phénomène provoque une augmentation des forces radiales et axiales sur les accouplements, les roulements et les joints, ce qui conduit à l'usure de ces composants et à une flexion de l'arbre en réduisant la quantité de puissance transmise.

Divers facteurs peuvent être l'origine du mauvais alignement de l'arbre, qui se résumant comme suit :

- Avaries liées à des contraintes mécaniques : comme le desserrage des pieds de fixation ou le déplacement des patins de la machine, dus aux vibrations de cette dernière.
- Avaries liées à des contraintes thermiques : tels que la variation de la température et l'expansion thermique des pièces dû à l'échauffement de la machine en fonctionnement.
- La modification des paramètres mineurs de processus comme la pression.



**Figure I.9** Défauts d'alignement.

#### **I.4. Classification des méthodes pour l'élaboration d'un système de diagnostic industriel**

Les stratégies de diagnostic de défauts exploitées dans le milieu industriel sont diverses et variées [15]. Leur principe de base repose sur une comparaison entre les données observées au cours du fonctionnement de la machine et les connaissances acquises sur son comportement normal et son comportement dans le cas d'une éventuelle présence d'un défaut [16].

Le choix d'une méthode de diagnostic par rapport à une autre s'effectue en fonction de deux principaux critères : les connaissances a priori et les connaissances issues des observations.

La connaissance a priori peut être acquise soit par l'analyse de l'historique du système étudié en tirant les indicateurs pertinents pour l'identification des modes de fonctionnement « mode de fonctionnement sans défaut et mode de fonctionnement défaillant », ou par l'analyse d'un expert reliant les différents modes de fonctionnement à leurs causes et symptômes.

Les connaissances issues des observations sont généralement acquises de façon directe à l'aide des capteurs, où la transformation et l'analyse de l'ensemble d'informations recueillies à un instant  $t$  sont nécessaires afin d'identifier le mode de fonctionnement du système.

Nous pouvons faire une classification non exhaustive des principales méthodes de diagnostic rencontrées dans la littérature selon deux grands axes : les approches à base de modèles et les approches sans modèles. Pour plus de détails nous référons les lecteurs aux travaux suivants : [17-19].

#### **I.4.1 Méthodes de diagnostic à base de modèles**

Ces approches sont basées sur la comparaison du comportement observé du système par rapport au comportement prédit du modèle qualitatif et/ou quantitatif établi [20].

La présence d'un écart dans cette comparaison signifie la détection d'une défaillance, comme indiqué dans la figure I.10.

On distingue deux branches de méthodes selon le type du modèle à établir : les méthodes quantitatives et les méthodes qualitatives.

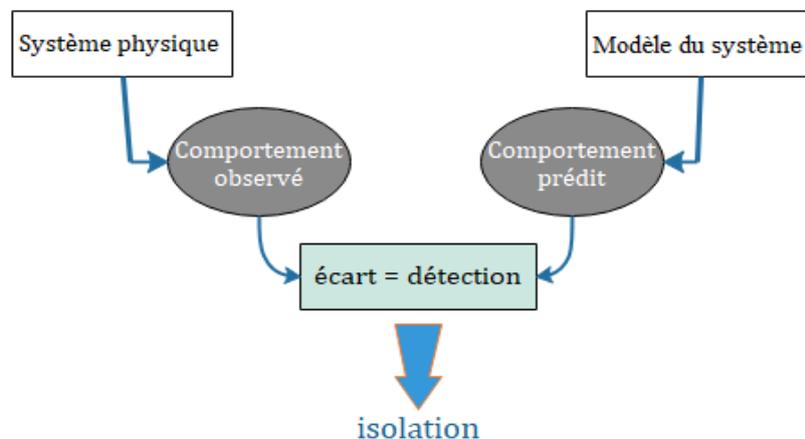
Les méthodes de diagnostic à base de modèles quantitatifs reposent sur l'estimation de l'état de fonctionnement en utilisant des modèles mathématiques simulant le comportement du système. S'il existe un écart dépassant un certain seuil entre ces modèles et les variables du système, une défaillance est alors détectée. Après la phase de détection, un résidu sera généré et comparé avec toutes les signatures de défauts connues pour isoler et localiser la défaillance.

Parmi les différentes méthodes de diagnostic utilisant des modèles mathématiques :

La méthode à base d'observateur [21-22], la méthode d'espace de parité [23] et la méthode d'estimation paramétriques [17].

Les méthodes de diagnostic à base de modèles qualitatifs permettent d'abstraire le comportement du procédé avec un certain degré d'abstraction à travers des modèles de type symbolique (non mathématique) décrivant l'espace d'état continu du système d'une manière qualitative [24]. Les méthodes qualitatives peuvent être classifiées selon le niveau d'abstraction considéré du système à diagnostiquer, tels que les systèmes continus [25], les systèmes à événements discrets [26] ou les systèmes hybrides dynamiques [27-28].

La séparation entre les méthodes quantitatives et les méthodes qualitatives n'implique pas que ces deux aspects sont disjoints parce qu'en réalité, ces deux types de méthode peuvent coexister au sein d'une même stratégie de diagnostic.



**Figure I.10** Principe des méthodes de diagnostic à base de modèles.

#### **I.4.2 Méthodes de diagnostic sans modèles**

Dans certaines applications industrielles, il est difficile ou voire impossible de générer des modèles physiques représentatifs du fonctionnement d'un système et de ses différents composants à cause de la complexité accrue du système à diagnostiquer. Généralement, ces méthodes de diagnostic exploitent les informations issues des capteurs installés au niveau de la machine sans avoir à utiliser le modèle mathématique simulant le comportement du système. Parmi les stratégies de diagnostic sans modèles, on distingue les techniques de l'intelligence artificielle, telles que les systèmes experts [29] et les méthodes de la reconnaissance des formes [30].

Nos travaux de ladite thèse se focalisent sur le diagnostic de défauts affectant les roulements des moteurs asynchrones, où les techniques d'IA sont les outils adéquats pour effectuer cette tâche en exploitant les informations générées à l'aide des capteurs sans la nécessité d'effectuer une modélisation qui est difficile à élaborer dans ce cas complexe.

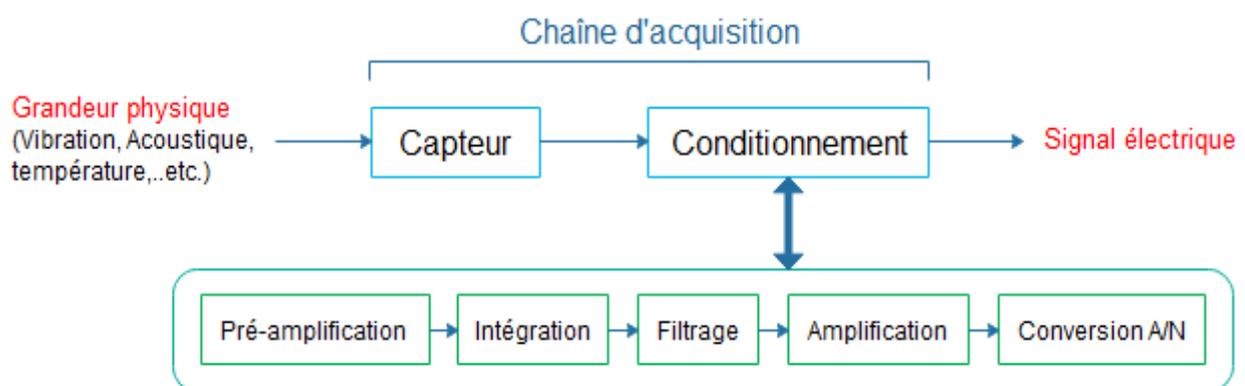
Le processus de diagnostic s'effectue selon plusieurs étapes : l'acquisition de données, l'extraction et la sélection des indicateurs pertinents qui seront ensuite pris comme une entrée d'un classifieur afin d'identifier et localiser les défauts. Les différentes étapes permettant le développement de cette approche de diagnostic sont détaillées dans les sections suivantes.

## I.5. Chaines d'acquisition et sources d'information

La première tâche à réaliser dans le cadre de diagnostic de défauts, est le processus d'acquisition de données à partir de sources multiples ; considéré comme le fondement physique de la maintenance préventive.

L'extraction des informations sur un système est nécessaire pour comprendre son état, décrire son comportement et prédire tout défaut précoce afin de pouvoir entreprendre les actions correctives nécessaires.

Le mécanisme essentiel pour l'acquisition de données est le capteur qui est un élément sensible à une grandeur physique qu'il transforme en grandeur électrique (une tension ou un courant). Il est souvent intégré à une chaîne d'acquisition permettant à la grandeur mesurée d'être conditionnée afin que la mesure (ou signal de sortie) donne une estimation optimisée de la valeur du mesurande, comme montré dans la figure I.11.



**Figure I.11** Chaîne d'acquisition de données.

Peu importe la source de données, l'association capteur-conditionneur détermine les caractéristiques du signal de sortie, où les divers éléments constitutifs de la chaîne d'acquisition doivent permettre le mesurage, le traitement et la restitution de la mesure avec des caractéristiques nécessaires à l'application comme la rapidité (le temps de réaction d'un capteur), la résolution (la plus petite variation qui doit être mesurée), la précision (véracité du résultat de la mesure en pourcentage) et l'immunité aux parasites, etc.

La sélection de sources de données appropriées est la clé de l'efficacité de la maintenance préventive conditionnelle, et un système complet d'acquisition de données peut améliorer directement la capacité et la performance du diagnostic et du pronostic des défauts affectant les machines tournantes. Cette sélection est faite en fonction de plusieurs paramètres tels que [12] :

- Les paramètres de coût d'installation ;
- Les paramètres relatifs à la dynamique et la cinématique de la machine ;
- Les paramètres environnementaux et d'encombrement ;
- Le niveau de criticité de l'application.

Les types de sources de données, qui peuvent être exploités pour réaliser une maintenance prédictive, sont répertoriés comme suit :

### **I.5.1 L'analyse vibratoire**

L'analyse des vibrations est généralement présentée comme la méthode de maintenance conditionnelle la plus efficace, en particulier pour les machines tournantes, car ces machines produisent des vibrations qui sont spécifiques dans leur comportement et leur caractère [32-37].

Une nouvelle machine tournante a un signal de vibration relativement régulier pendant le fonctionnement normal, mais à mesure qu'elle vieillit, la dégradation due à l'usure d'une ou plusieurs de ses composants, modifieront les caractéristiques du signal.

L'intégrité de la machine peut être évaluée par une comparaison détaillée entre les nouveaux et anciens spectres de vibration ; c'est-à-dire, chaque défaut dans une machine produira des vibrations avec des caractéristiques vibratoires distinctives et elles peuvent être captées et comparées à celles de référence afin d'effectuer un diagnostic de défaut.

Il est bien connu que le signal de vibration transporte des informations sur les résonances structurelles et d'autres composants de la machine, il peut ainsi donner des informations sur les conditions de fonctionnement et l'efficacité de la machine. Par conséquent, les méthodes de surveillance basées sur l'analyse vibratoire ont fait l'objet de recherches intensives au cours des dernières décennies.

Des informations caractéristiques vitales à partir des signaux de vibration peuvent être obtenues en employant diverses techniques de traitement de signal. Les techniques d'analyse des vibrations industrielles utilisent des capteurs de vibration avec différentes plages de fréquences en fonction de la machine à surveiller. Ces capteurs sont généralement placés à des endroits critiques où la charge locale est maximale, tels que les axes de roues, les roulements de la boîte de vitesses, les roulements du générateur et le roulement principal.

Différents capteurs sont utilisés pour mesurer les signaux de vibration des machines, notamment les capteurs de déplacement (les proximètres) opérant dans une plage à basse fréquence, les capteurs de vitesse (les vélocimètres) opérant dans la zone de fréquence

moyenne et les capteurs d'accélération (les accéléromètres) dans une plage à haute fréquence, etc.

### **I.5.2 L'analyse de lubrifiant**

Les lubrifiants sont largement utilisés dans presque toutes les pièces mobiles des machines tournantes afin de réduire le frottement, l'usure et également à des fins de refroidissement.

L'analyse de l'huile est l'analyse des propriétés de la composition et aussi des contaminants d'un lubrifiant. C'est une activité de routine utilisée pour déterminer :

- *La présence d'une contamination* : différents types de contamination dus aux particules étrangères provenant de l'environnement de la machine et pouvant affecter l'équipement de différentes manières. Par exemple :  
La présence d'air et d'eau peut affecter le fluide requis pour la séparation de surface.  
La présence de produits chimiques atmosphériques et de procédés peut provoquer une abrasion de surface.
- *La présence de débris d'usure* : L'usure de surface est considérée comme la principale menace pour les performances à long terme des équipements. L'état de la machine peut être évalué en mesurant les débris dans le lubrifiant.
- *Propriétés de lubrifiant* : évalue l'état du lubrifiant qui pourrait affecter les intervalles de vidange.

Les programmes d'analyse de lubrifiant sont conçus pour fournir des informations sur l'état de l'huile et l'état de la machine [31]. Il existe un large éventail de tests utilisés pour fournir ce type d'informations. Voici des exemples spécifiques de la manière dont les propriétés du lubrifiant, l'usure de la machine et la contamination peuvent être testées.

- *La viscosité* : est la propriété la plus importante d'un lubrifiant ; c'est ce qui lui permet de former la couche protectrice nécessaire à la séparation des surfaces mobiles.
- *Mesure de la présence d'eau* : l'eau est un contaminant commun qui a des effets potentiellement dévastateurs, notamment la rouille, une augmentation du taux d'usure et aussi une perte de fonctionnalité additive.
- *L'indice de neutralisation* : mesure un changement de concentration d'acide dans un lubrifiant qui indique une oxydation ou une corrosion.
- *Spectroscopie* : aide à surveiller les métaux contaminants et permet aux analystes de rechercher des espèces de molécules qui n'appartiennent pas à l'huile.

L'utilisation de l'analyse de lubrifiant est inadéquate dans le cadre d'une stratégie de diagnostic de défauts précoces affectants les machines tournantes à cause de la difficulté de

localisation et d'isolation de l'organe défaillant, ainsi que la lenteur des analyses peut réduire les possibilités de suivi dans des situations ou circonstances d'avaries à progression rapide.

### **I.5.3 L'émission acoustique**

La vibration de surface d'une machine tournante est souvent le facteur le plus important dans la génération du signal acoustique de la machine, ce qui signifie la présence d'une relation étroite entre les signaux acoustiques et vibratoires. La différence fondamentale est que les capteurs de vibrations sont montés rigidement sur le composant concerné et enregistrent le mouvement local tandis que les capteurs acoustiques résumant le son provenant de nombreuses sources au niveau de la machine. Cette technique n'est pas appropriée pour les tests en ligne parce que les signaux acoustiques sont contaminés par le bruit de fond de la machine s'ils sont utilisés dans des conditions en ligne.

L'émission acoustique (EA) est une méthode d'examen non destructif et elle est largement utilisée pour la détection précoce des défauts affectant les machines tournantes car sa sensibilité est plus élevée que les accéléromètres normaux et elle peut détecter des signaux de vibration à faible énergie [43-46].

L'EA est la production d'ondes élastiques à haute fréquence (dans une plage approximative de 100 kHz à 1000 kHz) due à la libération rapide de l'énergie de déformation accumulée à partir d'une source localisée dans un matériau, tel qu'une fracture ou une fissure. L'énergie libérée par le changement de condition traverse le matériau et provoque des vibrations élastiques.

### **I.5.4 Thermographie**

La thermographie également connue sous le nom d'inspection thermique ou infrarouge, est l'une des méthodes d'essai ou d'inspection non destructives les plus courantes ; considérée comme une approche d'observation rapide pour surveiller l'état général d'une machine tournante. Elle a été largement utilisée car elle permet d'inspecter l'état des machines et de détecter d'éventuels défauts sans avoir à déconnecter l'équipement de son fonctionnement normal [38-41].

Une caméra thermique est capable de capturer le rayonnement infrarouge émis par un objet. Il se compose d'un réseau de capteurs thermiques et peut créer une image thermique basée sur le diagramme de rayonnement détecté, appelé « thermogramme ». Plus la température est élevée, plus le rayonnement est émis et cela est présenté comme des pixels d'image avec une valeur d'intensité plus élevée sur le thermogramme.

Les images thermiques sont généralement sous forme de niveaux de gris, mais la pseudo-couleur peut être attribuée à l'aide de différentes palettes de couleurs pour aider les utilisateurs à identifier des objets avec des températures différentes [42].

La plupart des défauts qui peuvent altérer le fonctionnement d'une machine, généreront une chaleur excessive à la proximité de la zone du défaut. Ces anomalies thermiques peuvent être facilement capturées par une caméra thermique et apparaître comme un point chaud sur le thermogramme. En analysant ce dernier, il est possible d'évaluer l'état de l'équipement pour identifier d'éventuels signes de défaillance.

## **I.6. Outils de traitement du signal vibratoire adaptés pour la recherche de défauts**

### **I.6.1 Indicateurs statistiques**

Lorsqu'un ou plusieurs défauts se produisent au niveau d'un ou différents composants d'une machine tournante, les signaux vibratoires changent dans le domaine temporel. La distribution et l'amplitude de ces signaux varient avec différentes conditions de défaut et il est vraiment difficile à faire la discrimination entre les signaux de vibration des moteurs normaux et défectueux surtout dans le cas de défauts des roulements où il existe de nombreuses impulsions sur la forme d'onde de vibration.

Les changements ou les variations des signaux vibratoires pour différents défauts, ne peuvent pas être prédits ou séparés en regardant directement ces signaux, en raison d'une présence d'informations non pertinentes ou du bruit élevé dû à plusieurs interférences harmoniques existantes dans l'environnement de la machine, surtout dans le cas d'une apparence d'un défaut à un stade précoce. C'est-à-dire, l'altération des signaux de vibration est trop faible pour être détecté. Par conséquent, la comparaison des signaux bruts dans le domaine temporel des moteurs défectueux et sains n'est pas efficace afin de déterminer si le composant se comporte normalement ou présente des signes de défaillance.

L'analyse temporelle des signaux vibratoires, est généralement basée sur l'extraction et le suivi de plusieurs caractéristiques statistiques qui sont plus ou moins performants et adéquats pour l'observation de certaines défaillances plus que d'autres. L'application de ces techniques donne une première information à partir des signaux, mais exige d'être suivie, assistée et complétée par des investigations plus approfondies dans le cadre du diagnostic. Le Tableau 1.3 résume ces principaux descripteurs temporels.

Afin de révéler les informations importantes à partir des signaux temporels, un procédé de traitement du signal est nécessaire, qui convertit les signaux bruts en une forme condensée appropriée.

**Tableau I.2** Indicateurs statistiques les plus utilisés avec leurs définitions mathématiques

Paramètre statistique	Formule mathématique
RMS	$RMS = \sqrt{\left(\frac{1}{N}\right) \sum_{i=0}^N (x_i - x)^2}$ (I.1)
Crête (Peak)	$Peak = Sup_{1 < i < N}  x_i $ (I.2)
Facteur crête	$FC = \frac{Peak}{RMS}$ (I.3)
Kurtosis	$Ku = \frac{\frac{1}{N} \sum_{n=1}^N (x(n)-x)^4}{\left[\frac{1}{N} \sum_{n=1}^N (x(n)-x)^2\right]^2}$ (I.4)
Skewness	$S = \frac{\frac{1}{N} \sum_{n=1}^N (x(n)-x)^3}{\left[\frac{1}{N} \sum_{n=1}^N (x_i-x)^2\right]^{3/2}}$ (I.5)

## I.6.2 Analyse spectrale

Les techniques d'analyse du domaine fréquentiel ont la capacité de divulguer certaines informations basées sur les caractéristiques de fréquence qui ne sont pas facilement observables dans le domaine temporel.

En pratique, la transformée de Fourier (FT) est l'outil mathématique adéquat pour transformer facilement le signal vibratoire du domaine temporel en une représentation du domaine fréquentiel. Cette méthode décompose ces signaux complexes en une multitude de composantes élémentaires sinusoïdales et de les représenter sous forme d'un spectre « Amplitudes-Fréquence ». Le tableau I.4 montre les défaillances les plus courantes affectant les machines tournantes et leurs fréquences caractéristiques.

Il existe deux principaux types de FT, la transformation de Fourier discrète (DFT) et la transformation de Fourier continue (CFT).

La DFT est un outil important dans l'analyse fréquentielle des signaux temporels discrets 'x(n)' et elle peut être définie par l'équation (I.6) :

$$X_{DFT}(k) = \sum_{n=0}^{N-1} x(n)e^{-2\pi nk/N}, \quad k = 0, 1, \dots, N - 1 \quad (\text{I.6})$$

Ou on pourra écrire aussi :

$$X_{DFT}(k) = \sum_{n=0}^{N-1} x(n)W_N^{nk}, \quad k = 0, 1, \dots, N - 1 \quad (\text{I.7})$$

où 
$$W_N = e^{-(j2\pi/N)} = \cos\left(\frac{2\pi}{N}\right) - j \sin\left(\frac{2\pi}{N}\right) \quad (\text{I.8})$$

L'inverse de DFT qui transforme  $X_{DFT}(k)$  en  $x(n)$ , peut être exprimé en utilisant l'équation suivante :

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X_{DFT}(k)W_N^{-nk}, \quad n = 0, 1, \dots, N - 1 \quad (\text{I.9})$$

**Tableau I.3** Fréquences caractéristiques des principales défaillances affectant les machines tournantes.

Défaut	Fréquence caractéristique
Balourd	Fréquence de rotation ( $F_r$ )
Désalignement	$F_r, 2F_r$ , généralement $2F_r$ est plus élevée que $F_r$ (les vibrations axiales sont plus élevées que les radiales)
Défaut de fixation	$0.5F_r, F_r$ et plusieurs de leurs harmoniques
Tourbillons d'huile	40-50% de $F_r$
<b>Roulements</b>	<p>Fréquences correspondantes aux passages des éléments roulants données par les équations suivantes :</p> $\text{Bague externe} = \frac{F_r}{2} N_b \left(1 - \frac{D_b \cos\theta}{D_p}\right) \quad (\text{I.10})$ $\text{Bague interne} = \frac{F_r}{2} N_b \left(1 + \frac{D_b \cos\theta}{D_p}\right) \quad (\text{I.11})$ $\text{Cage} = \frac{F_r}{2} \left(1 - \frac{D_b \cos\theta}{D_p}\right) \quad (\text{I.12})$ $\text{Bille} = \frac{F_r}{2} \frac{D_p}{D_b} \left[1 - \left(\frac{D_b \cos\theta}{D_p}\right)^2\right] \quad (\text{I.13})$ <p><math>N</math> : Nombre d'éléments roulants  <math>D_b</math> : Diamètre des éléments roulants  <math>D_p</math> : Le diamètre moyen du roulement  <math>\theta</math>: L'angle de contact.</p>
	<p>La fréquence de rotation de la courroie est donnée par :</p> $F_{rc} = \frac{\pi D_1}{L} f_1 = \frac{\pi D_2}{L} f_2 \quad (\text{I.14})$

<b>Courroie</b>	<p>Pour le cas d'usure dans les courroies crantées :</p> $F_c = NF_r \pm kF_{rc} \quad (I.15)$ <p><math>D_1</math> : Diamètre de la poulie 1 <math>D_2</math> : Diamètre de la poulie 2  <math>L</math> : Longueur de la courroie  <math>N</math> : Nombre de dents de la poulie <math>k= 0,1,2,3, \dots</math></p>
<b>Engrenages</b>	<p>Donné par</p> $F_c = NF_r \pm kF_r \quad (I.16)$ <p><math>N</math>= Nombre de dents et <math>k= 0,1,2,3, \dots</math></p>

### I.6.3 Analyse d'enveloppe

L'enveloppe d'un signal vibratoire est calculée à l'aide de la transformée d'Hilbert (HT). Cette technique utilise la modulation de l'amplitude de la fréquence de résonance d'un des organes de la machine tournante par la fréquence caractéristique de défaut approprié. La HT permet de calculer l'enveloppe d'un signal  $x(t)$  et elle est définie par l'expression mathématique suivante :

$$HT[x(t)] = \bar{x}(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \left( \frac{x(\tau)}{t - \tau} \right) d\tau \quad (I.17)$$

où  $\bar{x}(t)$  est la partie imaginaire du signal analytique  $s(t)$  qui est défini par la formule suivante :

$$s(t) = x(t) + j\bar{x}(t) \quad (I.18)$$

Si on veut déduire l'enveloppe d'un signal vibratoire, appelée  $y(t)$ , on calcule le module du signal analytique  $y(t) = |s(t)|$  où la phase et la fréquence instantanée du signal sont définies par les formules suivantes :

$$\begin{cases} \text{phase:} & \theta(t) = \tan^{-1}(\bar{x}(t)/x(t)) \\ \text{fréquence:} & f(t) = d\theta(t)/dt \end{cases} \quad (I.19)$$

### I.6.4 Analyse temps-fréquence

#### I.6.4.1 Transformée de Fourier à Court Terme (STFT)

Connue aussi sous le nom « transformée de Fourier à fenêtre glissante » et proposée par Gabor en 1946 [60]. Cette méthode est basée sur le principe de la transformée de Fourier

standard et elle est éventuellement développée pour résoudre les lacunes de la FFT classique dans l'analyse des signaux réels non-stationnaires de courte durée. C'est-à-dire, la STFT est introduite pour décrire les signaux réels par un moyen permettant d'adapter la FFT au cadre non-stationnaire (la FFT est un outil stationnaire). Cela consiste à faire une multiplication du signal source  $x(t)$  par une fonction  $g(t)$ , appelée « fenêtre de pondération » :

$$X(\tau, \omega) = \int_{-\infty}^{+\infty} x(t)g(t - \tau)e^{-2\pi\omega t} dt \quad (\text{I.20})$$

où  $\tau$  est le paramètre de localisation temporelle de la fenêtre de pondération  $g$  et l'expression  $|X(\tau, \omega)|^2$  représente le « spectrogramme » dans le plan temps-fréquence.

Selon le principe d'incertitude d'Heisenberg, la STFT souffre d'un grand problème de résolution où le signal est estimé stationnaire durant la durée de la fenêtre et la taille de cette dernière a une influence directe sur la résolution temporelle et fréquentielle. Dans d'autres termes, lorsque la taille de la fenêtre  $g$  est large, la résolution fréquentielle est grande mais la résolution temporelle est médiocre à cause de la perte d'une grande quantité d'information relative au temps, et vice versa.

#### I.6.4.2 Transformée en Ondelettes (WT)

Proposée par Morlet en une série d'articles publiés dans le début des années 1980 [57-59]. La transformée en ondelettes WT utilise la fonction de base d'ondelettes contrairement aux fonctions sinusoïdales utilisées dans l'analyse de Fourier.

Cette méthode décompose le signal vibratoire en une série d'ondelettes dilatées ou non et localisées temporellement, ce qui génère une bonne résolution temporelle en hautes fréquences et fréquentielle en basses fréquences.

L'élément de base de la WT est la fonction oscillante  $\psi_{a,b}(t)$ , appelée aussi « ondelette mère » et elle est caractérisé par un coefficient de dilatation  $b$  et un coefficient d'échelle  $a$  :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (\text{I.21})$$

Sa transformée de Fourier  $\hat{\psi}(f) = 0$  si la fréquence  $f < 0$ .

La transformée en ondelettes continues (CWT) de tout signal  $x(t)$  s'exprime par :

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} X(t) * \psi * \left(\frac{t-b}{a}\right) dt \quad (\text{I.22})$$

La transformée en ondelettes discrètes (DWT) est la discrétisation des coefficients d'échelle et de dilatation dans la CWT. En posant  $2^n$  et  $n2^m$  au lieu des paramètres  $a$  et  $b$ , la DWT peut être décrit comme suit :

$$DWT(m, n) = 2^{-\frac{m}{2}} \int_{-\infty}^{+\infty} X(t) * \psi * (2^m(t - n)) dt \quad (I.23)$$

L'inconvénient majeur de la transformée en ondelettes se traduit dans le problème du choix de la bonne ondelette mère lors de l'analyse des signaux vibratoire issus des capteurs dans le cas des défauts qui évoluent graduellement. Ceci a poussé les chercheurs à développer une technique plus poussée basée sur des ondelettes adaptatives, appelée « transformée en ondelettes empiriques » qu'on va l'aborder dans la section ci-dessous.

### I.6.4.3 Méthodes de décomposition adaptative

Contrairement aux méthodes de traitement du signal traditionnelles, les méthodes de décomposition adaptative peuvent décomposer automatiquement un signal vibratoire sans l'intervention d'un expert du domaine et sans la nécessité d'une grande connaissance préalable des signaux.

Ces méthodes sont efficaces dans la représentation transitoire des signaux et qui peuvent être utilisés pour mettre en évidence les caractéristiques locales d'un signal dans le cas d'une présence d'un éventuel défaut. Parmi ces principales méthodes, on mentionne : la décomposition modale empirique (EMD), la décomposition en modes variationnels (VMD) [49] et la transformée en ondelettes empiriques (EWT) [50].

#### I.6.4.3.1 Transformée en Ondelettes Empiriques (EWT)

La transformée en ondelettes empiriques (EWT) est une nouvelle méthode de décomposition adaptative proposée par Gilles [55] en 2013 et qui a le potentiel de surmonter les inconvénients de la transformée en ondelettes classique (WT).

L'algorithme EWT adopte des ondelettes adaptatives, capables d'extraire les composantes modulées en amplitude (AMC) et les composantes modulées en fréquence (FMC) d'un signal. Les ondelettes empiriques sont définies comme un banc de filtres : le filtre passe bas est défini par  $\phi_n(w)$  et le filtre passe bande est défini par  $\hat{\phi}_n(w)$ , comme illustrés par les équations (I.24) et (I.25).

$$\hat{\phi}_n(w) = \begin{cases} 1 & \text{si } |w| \leq (1 - \gamma)w_n \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\gamma w_n} (|w| - (1 - \gamma)w_n) \right) \right] & \text{si } (1 - \gamma)w_n \leq |w| \leq (1 + \gamma)w_n \\ 0 & \text{autrement} \end{cases} \quad (\text{I.24})$$

$$\hat{\phi}_n(w) = \begin{cases} 1 & \text{si } (1 + \gamma)w_n \leq |w| \leq (1 - \gamma)w_{n+1} \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\gamma w_{n+1}} (|w| - (1 - \gamma)w_{n+1}) \right) \right] & \text{si } (1 - \gamma)w_{n+1} \leq |w| \leq (1 + \gamma)w_{n+1} \\ \sin \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\gamma w_n} (|w| - (1 - \gamma)w_n) \right) \right] & \text{si } (1 - \gamma)w_n \leq |w| \leq (1 + \gamma)w_n \\ 0 & \text{autrement} \end{cases} \quad (\text{I.25})$$

où  $\beta$  est une fonction dans  $C^k([0, 1])$  et elle est définie comme :

$$\beta(x) = \begin{cases} 0 & \text{si } x \leq 0 \text{ et } \beta(x) + \beta(1 - x) = 1 \forall x \in [0, 1] \\ 1 & \text{si } x \geq 1 \end{cases} \quad (\text{I.26})$$

et  $\gamma$  est choisi par l'équation suivante :

$$\gamma < \min \left( \frac{w_{n+1} - w_n}{w_{n+1} + w_n} \right) \quad (\text{I.27})$$

Où les  $w_n$  représentent les supports du filtre.

Le signal peut être reconstruit par la transformée en ondelettes empiriques inverse comme suit :

$$x(t) = \widehat{W}_x(0, w) * \widehat{\phi}_1(w) + \sum_{n=1}^N \widehat{W}_x(n, w) \widehat{\phi}_n(w) \quad (\text{I.28})$$

Où  $*$  désigne l'opérateur de convolution.

Les coefficients de détail de produit interne avec les ondelettes empiriques et les coefficients d'approximation par le produit interne avec la fonction d'échelle, sont décrits dans les équations (I.29) et (I.30), respectivement :

$$W_x(n, t) = \hat{x}(w) \cdot \overline{\widehat{\phi}_n(w)} \quad (\text{I.29})$$

$$W_x(0, t) = \hat{x}(w) \cdot \overline{\widehat{\phi}_1(w)} \quad (\text{I.30})$$

Comme dans le cas de la WT, l'EWT sépare le mode empirique de basse fréquence à haute fréquence, cependant, la bande passante n'est pas dyadique.

### I.6.4.3.2 Décomposition en Modes Variationnels (VMD)

La décomposition en modes variationnels (VMD) est un nouvel algorithme de décomposition du signal vibratoire proposé par Dragomiretskiy et Zosso en 2014 [56]. Cette méthode décompose un signal  $x(t)$  en plusieurs composants à bande limitée (un ensemble de fonctions en mode intrinsèque).

Cette technique est une méthode de décomposition non récursive, et elle extrait les AMC-FMC constitutifs d'un signal complexe multi-composant de manière adaptative et concurrente. Via l'application de la VMD, le signal d'entrée  $x(t)$  sera décomposé en une série contenant un nombre  $N$  de fonctions en mode intrinsèque appelées IMF, comme défini par l'équation (I.31) :

$$x(t) = \sum_{n=1}^N u_n(t) \quad (\text{I.31})$$

où tous les mode  $u_n(t)$  doivent respecter les caractéristiques ci-dessous :

- Chaque mode  $u_n(t)$  est un signal modulé en amplitude et en fréquence de la forme :

$$u_n(t) = A_n(t) \cos(\varphi_n(t)) \quad (\text{I.32})$$

où  $A_n(t)$  est l'enveloppe du mode et  $\varphi_n(t)$  définit sa phase.

- Les IMFs ont des enveloppes positives qui varient lentement.
- Chaque mode a une fréquence instantanée  $\varphi'_n(t)$  qui ne décroît pas, varie lentement et se concentre autour d'une valeur fréquentielle centrale  $f_n$ .

La méthode de VMD calcule simultanément toutes les formes d'onde du mode et leurs fréquences centrales. Ce processus consiste à trouver l'ensemble de  $u_n(t)$  et  $f_n(t)$  qui minimise le problème variationnel contraint.

### I.6.4.3.3 Décomposition Modale Empirique (EMD)

L'EMD est une méthode d'analyse temps-fréquence qui a été proposée par Huang et al. [51] et elle est utilisée pour le traitement des signaux non linéaires et non stationnaires. Le contexte fondamental de cette approche est de décomposer le signal complexe  $x(t)$  en une série de fonctions de mode intrinsèque (IMF), sans connaissance préalable.

$$x(t) = \sum_{i=1}^n C_i(t) + r(t) \quad (\text{I.33})$$

où  $C_i(t)$  indique la  $i^{\text{ème}}$  IMF et  $r(t)$  représente le résidu du signal  $x(t)$ . Chaque IMF est une fonction qui doit remplir les deux conditions principales suivantes :

- i. Dans tous les ensembles de données, le nombre d'extrema et le nombre de passage à zéro doivent être inférieurs ou égaux à un.
- ii. En tous points, la valeur moyenne de l'enveloppe définie par les maxima locaux et l'enveloppe définie par les minima locaux, sont nulles.

La méthode EMD a l'avantage de l'auto-adaptabilité par rapport aux techniques utilisées basées sur les ondelettes classiques. Cependant, l'EMD laisse encore certains problèmes compliqués non résolus en raison de l'inconvénient du mélange de modes (mode-mixing en anglais), qui est le résultat de l'intermittence du signal permettant de rendre la signification physique d'IMF peu claire.

Pour éliminer le problème de mélange de modes de l'EMD, l'EEMD a été proposé par Wu et Huang dans la référence [52], qui est une version améliorée de l'EMD originale permettant de réduire l'occurrence du mélange de modes sans affecter la propriété dyadique de la décomposition pour tous les ensembles de données. Cette approche active assistée par le bruit a été largement utilisée dans le diagnostic des défauts des machines tournantes [71, 80].

La figure I.12 montre l'organigramme de l'EEMD, et la brève description de l'algorithme est décrite ci-dessous :

- (1) Ajouter un bruit blanc  $w_i(t)$  au signal analysé  $x(t)$  ;

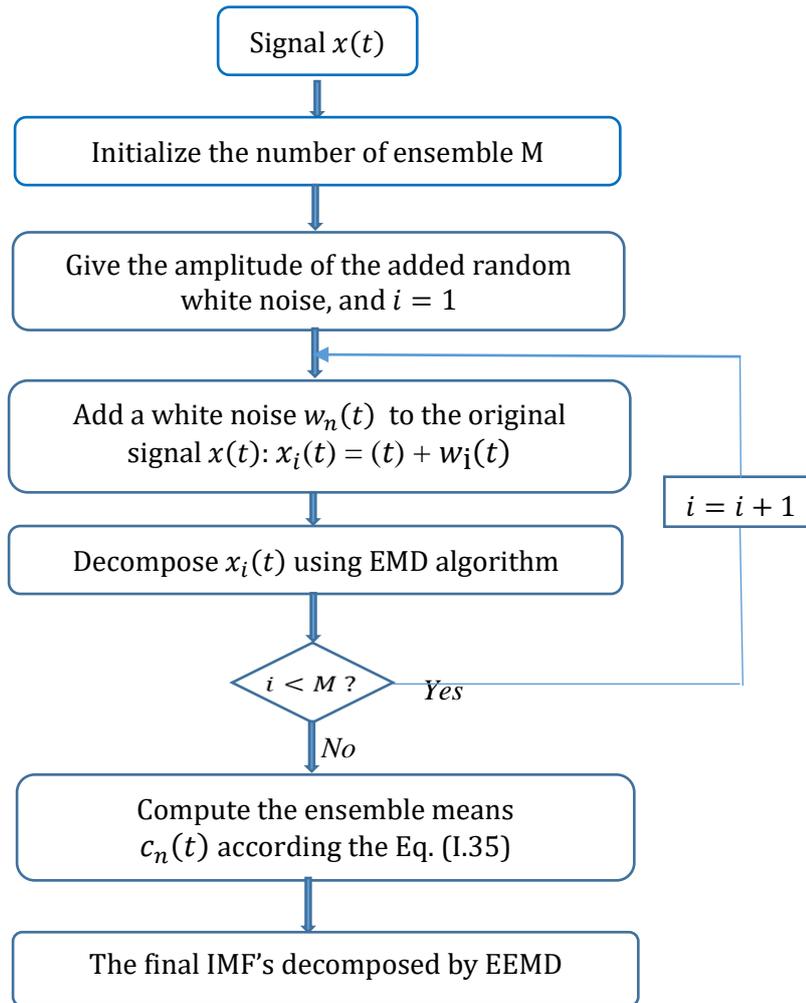
$$x(t) = x(t) + w_i(t) \quad (\text{I.34})$$

- (2) Décomposer le signal  $x(t)$  mélangé avec le bruit blanc par l'EMD de base ;
- (3) Répéter les étapes 1 et 2 une multitude de fois, avec différentes séries de bruit blanc à chaque fois ;
- (4) Faire la moyenne *IMF* par *IMF* pour obtenir « l'Ensemble » des IMF moyennes comme étant le résultat final donné par l'expression (I.35) :

$$c_n(t) = \frac{1}{M} \sum_{i=1}^M c_{i,n}(t) \quad (\text{I.35})$$

- (5) Donc le signal original  $x(t)$  peut être exprimé par :

$$x(t) = \sum_{j=1}^n IMF_j(t) + r_n(t) \quad (\text{I.36})$$



**Figure I.12** Organigramme de l'algorithme EEMD [73, 75].

Dans les références [53, 54], Lei et al. ont noté qu'il n'y avait pas une théorie spécifique rapportée dans la littérature aidant à définir les paramètres critiques de l'EEMD, notamment le nombre d'itération et l'amplitude du bruit à ajouter. Par contre, Wu et Huang [52] ont donné une équation générale combinant l'écart type de l'erreur «  $\varepsilon$  », le nombre d'itération «  $N_e$  » et l'amplitude du bruit blanc à ajouter «  $\alpha$  » qui est définie par la relation (I.37):

$$\ln(\varepsilon) + \frac{\alpha}{2} \ln(N_e) = 0 \quad (\text{I.37})$$

Selon la référence [52], les auteurs ont suggéré que le bruit blanc à ajouter est d'environ 0,2 de l'écart type du signal original «  $x(t)$  », et pour que ce bruit ajouté soit presque entièrement éliminé, le nombre d'ensemble «  $N_e$  » doit être supérieur à 100. Néanmoins, cela n'est pas toujours approprié et applicable pour des signaux dans différentes applications.

## I.7. Etat de l'art

Depuis quelques années, la recherche sur la détection et le diagnostic de défauts des machines tournantes se développe rapidement afin de rendre la stratégie de la maintenance prédictive plus efficace. La conception d'un système de diagnostic performant qui pourra détecter les défauts à un stade précoce, porte des avantages potentiels pour l'aspect productif et économique des entreprises industrielles. Par conséquent, les chercheurs ont porté un grand intérêt pour améliorer la tâche de maintenance prédictive où des centaines d'articles ont été publiés et ce qui représente une opportunité d'apporter une contribution significative aux universitaires au cours de ces dernières années.

Plusieurs méthodes ont été proposées pour résoudre cette problématique où on distingue deux principales approches qui sont couramment utilisées ; (a) diagnostic basé sur un modèle, (b) diagnostic sans modèle.

La première approche effectue le diagnostic de défauts en se basant sur une redondance analytique dans laquelle la cohérence entre les mesures et le comportement attendu du processus est vérifiée par des modèles analytiques [68]. Ces méthodes ont été appliquées avec succès pour diagnostiquer les différents défauts affectant les machines tournantes, tels que les roulements [61-63], les boîtes à vitesse [64-66] et les rotors [67].

Les approches à base de modèles peuvent être plus efficaces si un modèle correct et précis est développé. Son inconvénient majeur est que la réalisation de modèles mathématiques explicites simulant un comportement précis des systèmes complexes, sera très difficiles ou même impossible à établir. De ce fait, les approches de diagnostic sans modèle sont les plus adéquats pour surveiller l'état de fonctionnement de ces systèmes.

Ces approches sont généralement basées sur l'exploitation des données issues de différentes sources d'information à l'aide des capteurs. Dempsey et al. [47], ont fait le diagnostic de défauts affectant les engrenages à l'aide de débris de lubrifiant où ils ont constaté que cette méthode n'a pas le potentiel nécessaire pour localiser les défauts au niveau des boîtes de vitesse compliquées.

Une autre étude effectuée par Anderson [48], basée sur l'utilisation de l'analyse spectrométrique de l'huile afin de chercher les particules d'usure, les contaminants et les additifs dans les lubrifiants. Les résultats obtenus ont révélé que l'analyse des particules d'usure peut aider à déterminer la source d'usure et ainsi à définir l'état de fonctionnement de la machine.

L'émission acoustique est l'une des sources d'information utilisée pour surveiller l'état de santé de différents organes mécaniques au niveau des machines tournantes [98-100].

Faris et al. Dans [97], ont proposé une méthode pour surveiller l'état de fonctionnement d'une boîte à vitesses d'hélicoptère en exploitant les signaux d'émission acoustique.

Cette investigation a prouvé la capacité d'application de l'AE pour la détection des petits défauts du roulement dans la boîte à vitesses d'hélicoptère.

Gang et al. Dans [101], ont suggéré une méthode sans contact basée sur les imageries thermiques pour le diagnostic intelligent de défauts. D'après les résultats obtenus, la méthode semble avoir un bon potentiel à diagnostiquer les défauts affectant les systèmes rotatifs dans les lignes de production de masse.

De nombreuses recherches sont présentées sur la détection de défauts en utilisant l'analyse vibratoire. Les caractéristiques vibratoires peuvent être extraites de trois méthodes principales : l'analyse du domaine temporel, l'analyse du domaine fréquentiel et leur combinaison, connue sous le nom d'analyse temps-fréquence [85, 86].

L'analyse des signaux vibratoire dans le domaine temporel se repose sur l'extraction des caractéristiques statistiques utiles, notamment la moyenne, la variance, l'écart type, le Kurtosis, le RMS, etc [78, 79, 83, 84]. Divers facteurs statistiques affectent l'efficacité de diagnostic à cause de la présence d'un ou plusieurs indicateurs perturbateurs. Il est donc difficile d'estimer quel indicateur est plus sensible aux défauts et qui peut caractériser efficacement les signaux sains et défectueux. De plus, Ces méthodes ne révèlent pas les informations contenues dans le domaine fréquentiel. La transformée de Fourier rapide est l'outil le plus couramment utilisé dans le domaine spectral pour calculer les fréquences fondamentales des signaux où les fréquences significatives et les amplitudes correspondantes sont sélectionnées manuellement comme indicateurs de diagnostic de défaut [81, 82].

Les méthodes d'analyse fréquentielle ne sont pas capables de prendre une décision de diagnostic correcte lorsqu'elles sont utilisées seules, car les caractéristiques du domaine temporel du signal sont ignorées. Cela signifie qu'il est bien recommandé d'extraire les informations pertinentes contenues dans les signaux vibratoires en couvrant les deux domaine temporel et fréquentiel afin de renforcer la tâche de diagnostic.

L'approche d'analyse temps-fréquence a été privilégiée par les chercheurs pour la détection et le diagnostic de défauts des machines tournantes à cause de son potentiel à traiter les signaux vibratoires caractérisés par leurs comportements non-stationnaires et non-linéaires.

Parmi ces principales techniques, la méthode de décomposition en modes empiriques (EMD), qui a montré un excellent potentiel d'analyse pour ce type de signaux [87-89], la transformée en paquets d'ondelettes [90, 91], la transformée de Fourier à court terme [92, 93] et la transformée d'Hilbert-Huang [94, 95].

Singh et Ahmed [76], ont effectué l'analyse par transformée en ondelettes (WT) des signaux de vibration pour la détection de défauts dans les moteurs à induction. Ces travaux ont montré que l'analyse WT des signaux vibratoires dans différentes régions de fréquence améliore l'extraction des informations utiles qui peuvent à son tour renforcer la performance d'un système de diagnostic.

Gao et Yan [77], ont présenté une comparaison de différentes méthodes de traitement du signal, à savoir la transformée d'Hilbert-Huang (HHT), la transformée de Fourier à court temps (STFT), la transformée en paquets d'ondelettes (WPT) et la transformée en ondelettes discrète (DWT). Ces méthodes temps-fréquence sont appliquées pour traiter les signaux vibratoires afin de surveiller les défauts susceptibles d'affecter les roulements. Cette étude a démontré que l'outil WPT fonctionne mieux que toutes les autres méthodes de traitement du signal en détectant tous les composants transitoires intégrés dans les signaux vibratoires.

L'EMD décompose de manière auto-adaptative le signal vibratoire en une série d'IMF, qui représentent les oscillations naturelles intégrées dans le signal de vibration [51]. L'état de santé des machines tournantes peut être reflété en analysant l'information physique contenue dans ces fonctions en mode intrinsèque. Dybała et al. [69], ont utilisé l'EMD et l'analyse spectrale pour la détection précoce de défauts des roulements. Une autre étude menée par le même auteur dans la référence [70] où il a exploité les paramètres statistiques des IMFs pour la détection de défauts des boîtes de vitesse.

Dans les travaux de Chiementin et al. [96], l'EMD est comparé avec la transformée en ondelettes discrètes, et les résultats obtenus ont révélé que les deux méthodes proposées étaient efficaces pour la détection précoce de défauts des roulements.

L'EEMD, qui est une méthode EMD améliorée, conçue pour surmonter le problème du mélange de modes [52], et qui a été utilisée dans plusieurs travaux afin de rendre le diagnostic de défauts plus performant [73-75, 80].

Chen et al. [71] ont utilisé l'EEMD pour décomposer le signal en une série d'IMFs, puis ils ont appliqué une démodulation carrée d'Hilbert aux IMF sélectionnées pour le diagnostic de défauts manifestant au niveau de la boîte de vitesses d'une éolienne.

Žvokelj et al. [72] ont utilisé l'analyse en composante indépendante (ICA) pour sélectionner les IMFs, et l'analyse de l'enveloppe a été utilisée pour détecter et localiser les défauts de roulement. La méthode proposée est validée par des signaux simulés et réels provenant de capteurs de vibration et d'émission acoustique placés à des endroits précis au niveau d'un banc d'essai. La capacité de détecter et de localiser les défauts du roulement à un stade précoce indique que les signaux d'émission acoustique et de vibration contiennent suffisamment d'informations sur l'état du roulement et que la méthode développée est capable de l'extraire efficacement, ce qui représente une stratégie fiable de détection et de diagnostic de défauts des roulements.

## **I.8. Conclusion**

Ce chapitre présente une esquisse sur la maintenance préventive conditionnelle des machines tournantes dont le rôle est indispensable dans l'industrie moderne. Un aperçu a été donné sur un nombre important et non exhaustif des principaux défauts pouvant altérer le fonctionnement de ces machines suivi d'une brève classification des approches de surveillance dédiées à la recherche d'une éventuelle existence d'un défaut.

Le choix d'une stratégie de surveillance sans modèle est souvent nécessaire pour une exploitation optimale des systèmes complexes. De ce qui précède, plusieurs techniques existent nous ont permis de prendre conscience de l'énorme quantité d'information que nous pouvons extraire de l'environnement de ces machines. Une attention particulière a été donnée à l'analyse vibratoire qui est la technique la plus répandue et la plus informative pour la surveillance des conditions de fonctionnement des machines tournantes, où les principales méthodes dédiées à exploiter et traiter l'information vibratoire sont décrites. Enfin, un état de l'art a été présenté afin de visualiser le prodigieux progrès dans le domaine de la détection et le diagnostic de défauts affectant les machines tournantes.

# Chapitre II : Diagnostic basé sur les méthodes de l'intelligence artificielle

## II.1 Introduction à l'intelligence artificielle

L'un des premiers à avoir traité le sujet de l'intelligence artificielle (IA) est John McCarthy, chercheur et professeur dans les célèbres institutions : l'institut de technologie de Massachusetts, l'université de Stanford et de Princeton. En 1971, il a reçu le prix Turing pour ses travaux de recherche, ses nombreuses contributions en IA et l'élaboration des systèmes intelligents.

Le terme IA a été introduit pour la première fois par J. McCarthy en 1955, et le fondement de base de cette approche consiste à réaliser des programmes informatiques qui tentent d'imiter le raisonnement humain afin de rendre les machines intelligentes par la science et l'ingénierie [107]. Ainsi, à l'aide des mathématiques telles que la logique booléenne et les probabilités, nous pouvons rendre un programme intelligent de manière à ce qu'il décide adéquatement de la suite des évènements, ou de prendre une décision finale.

L'ensemble des constituant des branches d'IA, peut se présenter comme étant une combinaison de :

- Logique : le potentiel de juger d'une situation spécifique à l'instant  $t + 1$  grâce au traitement des informations acquises à un instant  $t$  par un ensemble de relations mathématiques logiques.
- Reconnaissance de similarité : via des outils adéquats, l'ordinateur (le programme) reconnaît les similarités entre deux situations spécifiques à partir des formes monodimensionnelles et même multidimensionnelles.
- Inférence : qui est un raisonnement logique de déduction opérant en fonction des connaissances du programme.
- Recherche : grâce à la puissance computationnelle élevée des ordinateurs, l'estimation d'un évènement le plus probable parmi un grand ensemble de situations possibles est permis dans une durée de temps réduite et en fonction des actions passées.

Ces branches d'IA, nous a permis de concevoir des outils efficaces, tels que les algorithmes évolutionnaires [108] ou encore les algorithmes de classification [87, 93], qui sont très présents dans les recherches scientifiques et les applications industrielles dans divers domaines.

Partant de ce fait, cette étude 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 seront décrites et seront attachées par une synthèse bibliographique résumant les principales méthodes d'IA utilisées actuellement dans l'intérêt d'une stratégie de maintenance efficace et orientant les travaux menés dans les chapitres suivants.

## **II.2 Stratégie d'un diagnostic intelligent de défauts**

Comme mentionnée dans le premier chapitre, il existe deux approches principales pour effectuer le diagnostic de défauts des machines tournantes, à savoir le diagnostic à base de modèles et le diagnostic sans modèles.

Le diagnostic à base de modèle est généralement fondé sur le principe de la modélisation mathématique du système à surveiller dans le but de décrire son comportement et aussi les différents modes de défaillance pouvant altérer son fonctionnement. Cette approche peut être plus efficace que les approches sans modèles seulement si un modèle correct et précis est construit pour imiter le comportement réel de la machine dans des conditions de fonctionnement normales et même dans le cas d'une présence d'un ou de plusieurs défauts. L'élaboration d'une modélisation explicite n'est pas toujours facile ou même impossible à réaliser surtout dans le cas des systèmes qui présentent des structures complexes. Pour surmonter cet inconvénient, il y'a eu la création de diagnostic sans modèles ou plus précisément appelé « diagnostic à base des méthodes externes ». Cette approche tente de contourner directement les modèles mathématiques à travers l'exploitation des données de surveillance de l'état collectées par des capteurs provenant de différentes sources d'information abordées précédemment dans la section **I.5**.

L'avantage majeur d'un diagnostic intelligent de défauts est que ses calculs peuvent être réalisés par la programmation et comprend généralement trois étapes cruciales :

- (1) L'extraction des indicateurs contenant les signatures de défauts.
- (2) La sélection et la réduction de la dimensionnalité des indicateurs.
- (3) La classification de défauts par le biais des classifieurs.

### **II.2.1 Extraction d'indicateurs de défauts**

L'acquisition de données est l'étape la plus élémentaire qui se résume dans la collecte et le traitement de signaux par un système de capteurs. Ces signaux collectés contiennent à la fois des informations utiles, et des contenus bruyants inutiles dus à des conditions sévères liées à l'environnement de la machine.

L'extraction de l'information liée à la santé de la machine, vient après l'étape d'acquisition de données. Elle consiste à extraire un ensemble de paramètres statistiques, pouvant traduire réellement l'état de fonctionnement d'un ou de plusieurs organes du système surveillé.

Ces paramètres extraits sont également appelés indices de santé, et ils doivent être les indicateurs à tout changement ou toute évolution dans le temps du mode de fonctionnement de la machine.

Plusieurs indicateurs peuvent être calculés à partir des signaux provenant de différentes sources d'information, tels que : les descripteurs temporels (vus dans la section I.6.1), comme la racine quadratique moyenne (RMS), l'asymétrie, le facteur crête, le kurtosis, l'écart type, et etc [109, 84]. Les pics de la FFT, l'énergie de la bande de fréquence et le spectre de puissance qui sont des caractéristiques importantes du domaine fréquentiel ainsi que les coefficients d'ondelettes qui sont considérés comme des descripteurs d'état temps-fréquence très utilisés par les chercheurs.

Il n'est pas toujours courant de garder ou de maintenir un nombre important d'indicateurs statistiques dans la tâche de diagnostic. Certains de ces paramètres sont très sensibles à la manifestation d'une défaillance et peuvent même indiquer la présence d'un défaut dans un stade précoce tandis que d'autres descripteurs peuvent ne pas être aussi sensibles et sont considérés comme des éléments perturbateurs, nuisibles, ou redondants qui dégradent les performances de diagnostic dans la phase de classification.

La sensibilité de ces indicateurs dépend à la fois à des conditions environnementales et opérationnelles existantes.

Lors du calcul des caractéristiques insensibles aux facteurs externes, il y aura un compromis entre la sensibilité et la capacité de détection d'un défaut [111]. Il est très important d'utiliser des méthodes avancées de traitement de signal afin de réduire le bruit contenu dans les signaux avant l'étape d'extraction d'information, ce qui améliore la qualité des descripteurs d'état extraits et rend l'opération de surveillance plus efficace [110].

### **II.2.2 Sélection et transformation d'indicateurs pour la réduction de la dimensionnalité**

La dimension des indicateurs extraits ou de données est l'une des problématiques majeures liées à la représentation de données. Ce problème a un effet explicite sur la capacité de stockage, le coût de calcul (la vitesse de l'algorithme) et même peut dégrader la performance de la prédiction de défauts.

Il existe deux approches principales dédiées à la réduction de l'espace de représentation des indicateurs, ce qui nous permettent de surmonter tous les impacts indésirables et éventuellement d'avoir une meilleure compréhension et visualisation de ces données.

### II.2.2.1 Approche 01 : sélection d'indicateurs

C'est une approche basée sur la sélection d'un ensemble de caractéristiques extraites à partir de leur ensemble complet. C'est-à-dire, cette approche choisit les sous ensemble d'indicateurs les plus discriminants parmi l'ensemble initial d'indicateurs disponibles.

Cela améliore la qualité des descripteurs, élimine les éléments non pertinents et supprime toute redondance possible, ce qui aide à faire la discrimination et à caractériser chacune des classes étudiées dans l'application.

Les approches de sélection sont classées en trois groupes principaux :

- **L'approche filtre** : est basée sur l'utilisation des mesures statistiques déduites à partir des indicateurs initiaux pour filtrer les indicateurs non pertinents ou peu informatifs. Ces mesures peuvent être : la similitude, la dépendance et la corrélation.

Les méthodes filtres sont caractérisées par leurs rapidités, leur robustesse face au sur-apprentissage et nécessitent une faible complexité de calcul par rapport aux autres méthodes. L'inconvénient majeur de cette approche, est qu'elle ne tient pas compte entre les indicateurs et qu'elle est orientée beaucoup plus vers la sélection de descripteurs contenant des informations redondantes plutôt que vers des informations complémentaires.

Parmi les principales méthodes filtres qui peuvent être utilisées pour évaluer les caractéristiques d'un signal vibratoire, on trouve : Score de Fisher (*Fisher score*) [122], Relief F [124], coefficient de corrélation de Pearson (*Pearson correlation coefficient*) [125], score Laplacien (*Laplacian score*) [123] ..., etc.

- **L'approche enveloppante** : c'est l'approche la plus explorée et la plus utilisée (appelée '*wrapper approach*' en anglais). Elle est basée sur l'apprentissage supervisée, où elle intègre les algorithmes d'apprentissage machine (ML) pour la sélection des indicateurs les plus informatifs.

L'objectif principal des Wrappers, est de chercher l'espace des sous-ensembles d'indicateurs et de prendre la décision d'ajouter ou de retirer un indicateur du sous ensemble par le calcul de la précision estimée à travers un algorithme d'apprentissage prédéfini.

Cela signifie qu'elles évaluent la qualité d'un ensemble de caractéristiques sélectionnées via un classifieur spécifique. Cette approche est plus coûteuse en terme du temps de calcul par rapport à l'approche filtre, par contre elle est plus fiable et précise.

Les méthodes enveloppantes peuvent être classées en deux catégories :

- Méthodes de sélection séquentielle : parmi les méthodes les plus utilisées pour la surveillance des machines, on cite la méthode de sélection ascendante (*SFS* : *Sequential Forward Selection*) [127] et la méthode de sélection descendante (*SBS* : *Sequential Backward Selection*) [126].
- Méthodes de recherche heuristique : parmi ces principales méthodes utilisées pour le diagnostic des roulements, on distingue l'algorithme génétique (*GA* : *Genetic Algorithm*) [127, 133] et l'optimisation par essaims particulaires (*PSO* : *Particle Swarm Optimization*) [128].

- **L'approche intégrée** (appelée '*Embedded approach*' en anglais) : son principe consiste à incorporer la tâche de sélection de caractéristiques lors de l'opération d'apprentissage et de construction de classifieur.

Les méthodes de l'approche intégrée sont plus rapides par rapport à celles de l'approche enveloppante et on peut les trouver intégrées dans les algorithmes de classification ; tels que l'arbre de classification et de régression (CART) [129], LASSO [131] et les machines à vecteurs de support [130].

### II.2.2.2 Approche 02 : transformation d'indicateurs

C'est une approche basée sur la transformation des indicateurs dans un espace de représentation réduit à partir de l'espace original. Ce principe consiste à la création de nouveaux sous-ensembles de caractéristiques non physiques ou synthétiques, partant de leur espace de représentation original vers un nouvel espace de plus faible dimension sans perdre beaucoup d'informations. Cette transformation permet d'éliminer les éléments perturbateurs ou redondants de l'ensemble de données original car ils peuvent avoir un effet indésirable sur la performance de diagnostic comme l'augmentation inutile des coûts de calcul et la diminution de la précision de classification.

Il existe deux types de méthodes permettant la réduction de la dimension, en combinant l'ensemble des paramètres d'origine pour la création de nouveaux attributs :

- Méthodes utilisées pour la création de nouveaux indicateurs comme des combinaisons linéaires à partir de l'ensemble de données initiales, telles que : l'analyse en composantes principales (PCA), l'analyse en composantes indépendantes (ICA) [72] et l'analyse discriminante linéaire (LDA) [119, 84].

Les méthodes PCA et ICA, sont largement utilisées pour effectuer la tâche de diagnostic de défauts, où on trouve plusieurs articles publiés parlant du sujet [120, 121]. B. Kamiel et al dans [117], ont combiné la transformée en ondelettes, les indicateurs statistiques et l'outil PCA pour diagnostiquer les défauts de roulements.

F. Wang et ses collègues dans [116], ont utilisé PCA pour classifier les défauts de roulements. Ils ont calculé un ensemble important de paramètres statistiques dans le domaine temporel et fréquentiel à partir des signaux vibratoires. Puis, ils ont appliqué l'outil PCA pour réduire la dimension des vecteurs de caractéristiques tirés des signaux bruts, ce qui a réduit le temps de calcul et a amélioré la performance du diagnostic.

J. Huang et al dans [118], ont proposé une méthode de prétraitement de signaux vibratoires basée sur l'ICA pour le diagnostic de défauts d'une boîte à vitesse. Les auteurs ont montré que le système établi a le potentiel de détecter les différents défauts de petite taille, et que la technologie ICA appliquée a réduit le taux de bruit au niveau des mesures, ce qui a amélioré la qualité d'informations liée aux défauts.

- Méthodes utilisées pour la création de nouveaux indicateurs non-linéaires, telles que l'analyse en composantes principales à noyau (KPCA), les projections à localité préservés (LPP) [114], et la carte auto-adaptative (SOM) [115].

Plusieurs chercheurs ont utilisé la méthode KPCA pour diagnostiquer les défauts de roulement. Z. Chen et H. Yuan dans la référence [113], ont combiné l'EMD (outil de traitement de signal auto-adaptatif) avec le KPCA comme un outil de réduction de dimensionnalité non-linéaire. En premier, l'EMD est appliqué pour décomposer les signaux de vibration collectés en un nombre fini de fonctions en mode intrinsèque (IMF), dans lequel les valeurs d'énergie correspondantes sont sélectionnées comme un vecteur initial de caractéristiques. Puis, le KPCA est utilisé pour réduire davantage la dimensionnalité du vecteur de caractéristiques initial en un autre plus simplifié contenant des entités de faible dimension et qui est considéré par la suite comme une entrée d'un classifieur. Les résultats expérimentaux obtenus, ont montré que le système de diagnostic proposé peut identifier et classer efficacement les différents défauts de roulements.

S. Dong et al dans la référence [112], ont utilisé l'algorithme de décomposition en moyenne locale (LMD) et l'analyse en composantes principales à noyau afin d'identifier les défauts de roulements. Les signaux vibratoires sont décomposés en une série de composantes par la méthode LMD. Puis, ils ont appliqué la méthode KPCA juste après le calcul d'entropie de Shannon de ces composantes extraites. L'outil KPCA est utilisé pour extraire les caractéristiques typiques, réduire la dimension et améliorer davantage l'apprentissage du classifieur utilisé dans la phase de classification. A la fin, Ils ont conclu que les différentes méthodes réunies peuvent atteindre une précision élevée dans le diagnostic de défauts des roulements.

### II.2.3 Classification de défauts

#### II.2.3.1 Apprentissage statistique conventionnel

La première difficulté rencontrée lors de développement d'un système de surveillance de défauts utilisant les outils d'apprentissage classique, est la nécessité de faire une extraction manuelle d'indicateurs pertinents qui doivent contenir les signatures de défauts. Cela signifie que la réalisation d'un diagnostic efficace avec des performances souhaitées dépend implicitement de la qualité de descripteurs extraits. Malheureusement, la probabilité d'avoir un ensemble d'indicateurs insensible aux défauts, redondant ou bien encore incomplet, est extrêmement élevée. Par conséquent, on doit étudier et extraire le maximum d'informations à partir des signaux collectés avant de trouver une description satisfaisante de ces données. Après la tâche de sélection d'indicateurs significatifs, un vecteur de caractéristiques est construit pour être utilisé comme une entrée d'un modèle précis à des fins d'apprentissage et de classification.

Parmi les méthodes d'apprentissage conventionnel qui sont largement utilisées dans la tâche de diagnostic de défaut, on distingue les SVM et les ANN.

##### II.2.3.1.1 Machine à Vecteurs de Support (SVM)

Les machines à vecteurs de support appelés aussi séparateurs à vaste marge, traitent des problématiques de classification binaire, où leur contexte de base consiste à trouver l'hyperplan de séparation optimale entre deux classes en se basant sur le critère de marge maximisée, comme illustré dans la figure II.1. De plus, ces algorithmes utilisent la fonction noyau appelée « *Kernel* » pour la recherche d'un meilleur hyperplan séparateur, en transformant les données d'un espace à un autre [151].

Soit l'ensemble d'apprentissage de  $n$  exemples suivants :  $(x_i, y_i)$  où  $i \in [1, n]$ , et  $x_i \in \mathbb{R}$  ;  $x_i$  appartient à une classe labellisée par  $y_i$  ; tel que :  $y_i$  doit avoir seulement deux valeurs  $+1$  ou  $-1$ .

Le problème d'optimisation consiste à maximiser la marge séparant les classes [152], et il peut être défini par la formule mathématique suivante :

$$\min_{w,b} \left\{ \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i \right\} \quad (\text{II.1})$$

$$\text{Sous les contraintes: } \begin{cases} y_i(\omega \cdot X_i - b) \geq \xi_i, & i = 1, \dots, l \\ \xi_i \geq 0 & i = 1, \dots, l \end{cases} \quad (\text{II.2})$$

où  $C$  désigne le paramètre de pénalité et  $\xi$  les variables ressort permettant de relâcher les contraintes sur les vecteurs d'apprentissage. La révision du problème d'optimisation en termes de multiplicateur lagrangiens conduit à l'équation II.3 :

$$\text{Maximiser: } \tilde{L}(\alpha) = \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (\text{II.3})$$

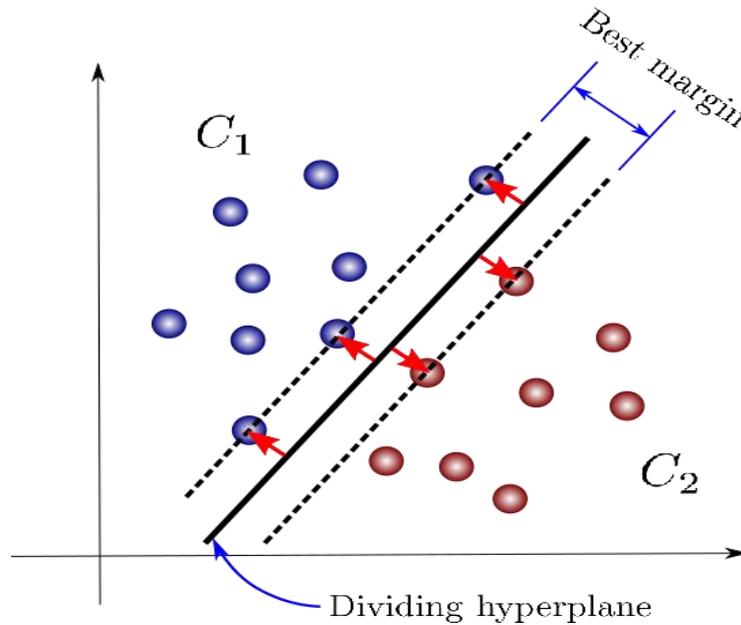
$$\text{Sous les contraintes: } \begin{cases} \alpha_k \geq 0 \\ \sum_{k=1}^n \alpha_k y_k = 0 \text{ et } k = 1, 2, \dots, n \end{cases} \quad (\text{II.4})$$

Dans les cas non linéaires, on introduit les noyaux de Kernel et la formule de l'hyperplan séparateur sera définie par :

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i y_i K(x_i, x_j) + b) \quad (\text{II.5})$$

$$\text{Telle que: } \begin{cases} \omega = \sum_{i=0}^N \alpha_i x_i y_i \\ y_i(\omega^T \cdot x_i + b) - 1 = 0 \end{cases} \quad (\text{II.6})$$

où  $K(x_i, x_j)$  représente la fonction noyau « Kernel », et  $\alpha_i$  représente le multiplicateur de Lagrange. Parmi les fonctions Kernel les plus utilisées, on distingue : la fonction polynomiale, la fonction de base radiale Gaussienne (RBF), et la fonction sigmoïde.



**Figure II.1** Exemple d'hyperplan séparateur d'une classification binaire par l'outil SVM.

Le SVM décrit ci-dessus, ne peut résoudre que des problématiques de classification appartenant à deux catégories de classe (classe positive ou négative).

En réalité, nous rencontrons souvent des problèmes multi-classe surtout dans les applications liées à la surveillance d'état de roulements défectueux. Par conséquent, l'utilisation d'un SVM multi-classe est une condition préalable. Depuis plusieurs années, il y a eu naissance de deux stratégies permettant de surmonter ce défi. Ces deux méthodes sont détaillées ci-dessous :

- **Stratégie Un-Contre-Un (OVO)**

C'est une technique utilisée pour résoudre les problématiques de classification multi-classes par les algorithmes SVM. Elle est connue en anglais sous le nom « One-Versus-One method ». Cet algorithme construit  $k(k - 1)/2$  hyperplans où chaque classe est entraînée par un ensemble de données couvrant deux classes.

L'apprentissage à partir du jeu de données des  $i^{\text{ème}}$  et  $j^{\text{ème}}$  classes, peut être résolu en tant que problème de classification binaire.

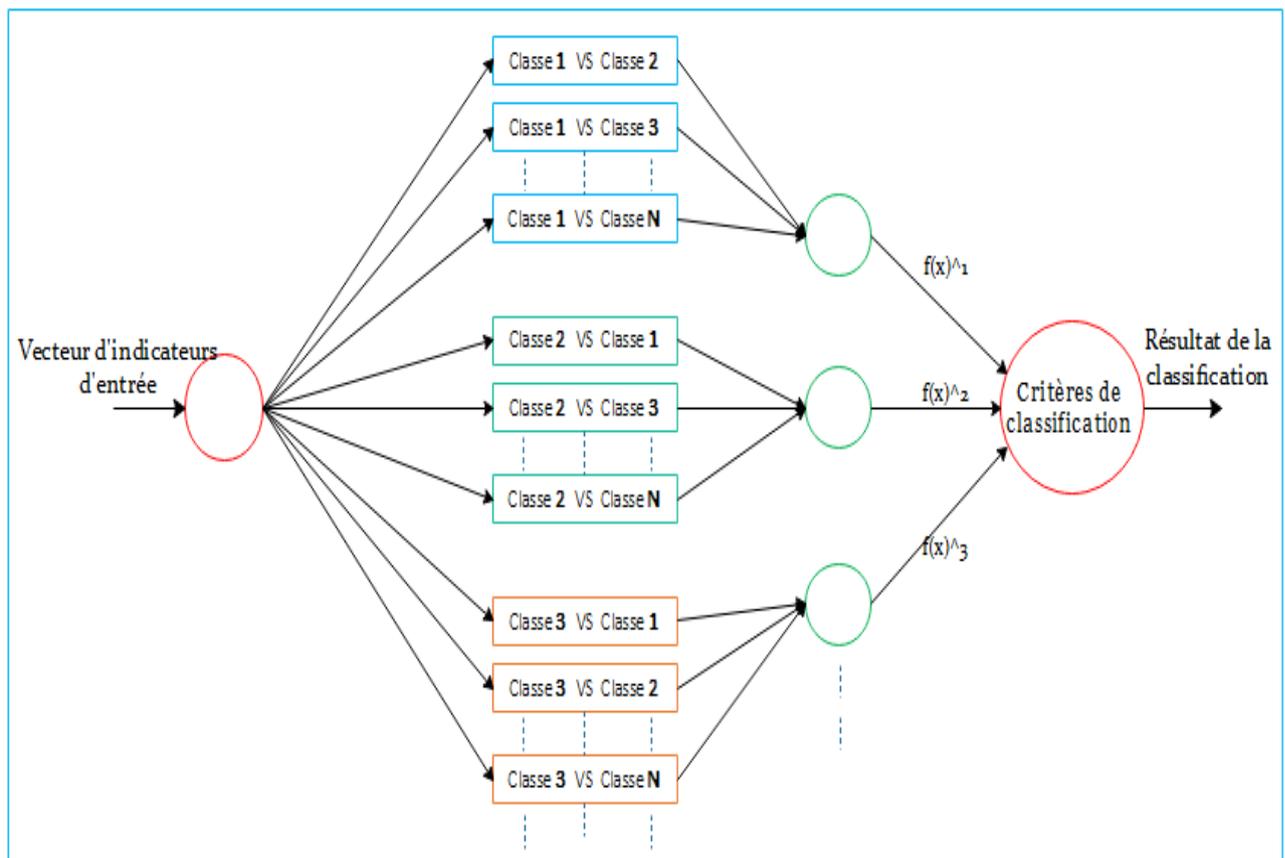
$$\text{Minimiser: } \frac{1}{2} \|\omega^{ij}\|^2 C \sum_t \xi_t^{ij} (\omega^{ij})^T \quad (\text{II.7})$$

$$\text{Sous les contraintes: } \begin{cases} (\omega^{ij})^T \phi(x_t) b^{ij} \geq 1 - \xi_t^{ij} & \text{si } y_t = i, \\ (\omega^{ij})^T \phi(x_t) b^{ij} \leq -1 \xi_t^{ij} & \text{si } y_t = j, \\ \xi_t^{ij} = 0, & j = 1, \dots, l \end{cases} \quad (\text{II.8})$$

Plusieurs méthodes sont exploitées pour tester les  $k(k - 1)/2$  classifieurs construits. Après le test, la décision du choix du modèle se fait à l'aide d'une stratégie, connue sous le nom Win-Max :

$$\text{sign}((\omega^{ij})^T \phi(x_t) b^{ij}), \text{ indique que } x \text{ est dans la } i^{\text{ème}} \text{ classe.}$$

Ensuite, le vote pour la  $i^{\text{ème}}$  classe est augmenté par un. Sinon, il sera augmenté pour la  $j^{\text{ème}}$  classe et  $x$  est prédit en fonction de la classe qui a le plus de votes. La figure II.2 montre le processus de classification MCSVM avec la technique OVO pour une problématique de  $N$  classes.



**Figure II.2** MCSVM avec la technique Un-Contre-Un (OVO).

- **Stratégie Un-Contre-Tous (OVA)**

Cette technique est appelée en anglais « One-Versus-All method » et elle consiste à la création d'un nombre  $k$  de modèles SVM qui est égal au nombre de classes rencontrées dans la problématique.

Le  $i^{\text{ème}}$  modèle SVM est construit en prenant une classe (labellisée positive) et en considérant tous les autres exemples comme une autre classe (labellisée négative). Puis, le processus est répété pour chaque classe.

Pour un ensemble de données d'apprentissage donné  $l : (x_1, y_1), \dots, (x_l, y_l)$ , où  $x_i \in \mathbb{R}^n$ ,  $i = 1, \dots, l$  et  $y_i \in 1, \dots, k$  est la classe de  $x_i$ , le  $i^{\text{ème}}$  modèle SVM peut résoudre le problème ci-dessous :

$$\text{Minimiser:} \quad \frac{1}{2} \|\omega^i\|^2 C \sum_{i=1}^l \xi_j^i (\omega^i)^T \quad (\text{II.9})$$

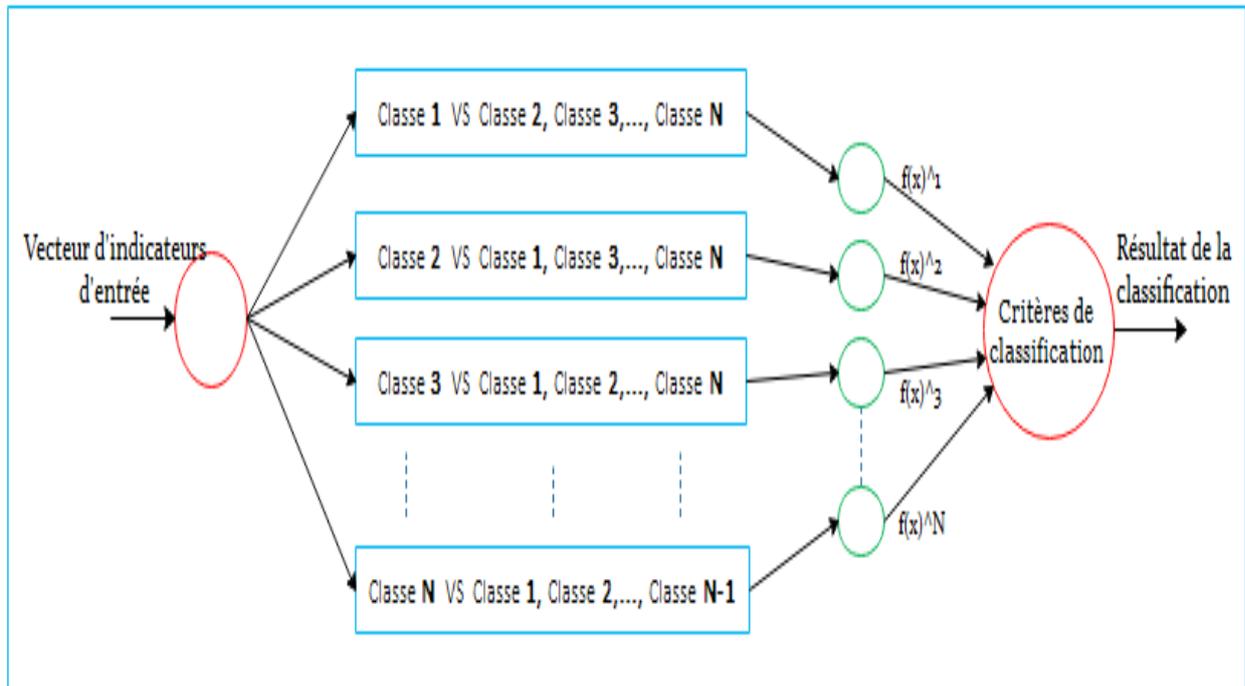
$$\text{Sous les contraintes:} \quad \begin{cases} (\omega^i)^T \phi(x_j) b^i \geq 1 - \xi_j^i & \text{si } y = i, \\ (\omega^i)^T \phi(x_j) b^i \leq -1 \xi_j^i & \text{si } y \neq j, \\ \xi_j^i = 0, & j = 1, \dots, l \end{cases} \quad (\text{II.10})$$

où  $C$  désigne le paramètre de pénalité.

Les données d'apprentissage du modèle  $x_i$ , sont mappées à un espace de dimension supérieure par la fonction  $\phi$ . La minimisation de l'équation II.9, maximise la marge  $2/\|\omega_i\|$  entre deux groupes de données lorsque l'ensemble de données n'est pas linéairement séparable et le paramètre de pénalité réduit l'erreurs d'apprentissage.

Une fois que le modèle MCSVM est conçu et prêt à être exploité, les différents résultats de test (égale aux nombres de classes), sont traités en appliquant une somme. Puis, le résultat final de la classification est déduit par le choix de la solution la plus probable. La figure II.3 montre la résolution d'une problématique de classification de  $N$  classes par MCSVM utilisant la technique OVA.

Le Multi-classe SVM est un algorithme d'apprentissage supervisé qui est largement utilisé dans la surveillance de l'état de santé des machines tournantes. Généralement, cette méthode prend comme entrée le vecteur de caractéristiques significatives pour classifier les différents défauts rencontrés dans une problématique spécifique. Elle a été utilisée pour la classification de différents défauts de roulements dans de nombreuses études [95, 130, 132, 133].



**Figure II.3** MCSVM avec la technique Un-Contre-Tous (OVA).

Morales et ses collègues [134], ont fait une fusion de données vibratoires et du courant pour diagnostiquer les différents types de défauts mécaniques d'un moteur à induction. Trois types de défauts sont pris en considération lors de ce travail ; tels que le défaut de roulement, rotor déséquilibré et désaligné. Puis, un ensemble de caractéristiques statistiques est extrait pour construire un vecteur d'indicateurs qui a été alimenté par la suite à un classifieur MCSVM. Enfin, les auteurs ont conclu que la performance de la méthode proposée est améliorée considérablement grâce à la fusion des données provenant de différentes sources d'information.

Trois ans après, Silva et Pederiva [137], ont proposé une approche de diagnostic basé sur l'analyse spectrale des signaux vibratoires en utilisant trois algorithmes de classification différents. La classification de défauts a été réalisée séparément par un réseau de neurones artificiels « ANN », l'algorithme « logique floue » et le « SVM ». Les résultats révélés ont prouvé l'efficacité du classifieur SVM doté d'une bonne capacité de généralisation par rapport aux autres techniques.

Dans un autre article, Tabrizi et al [135], ont utilisé la décomposition en paquet d'ondelettes (WPD) pour éliminer le bruit résiduel dans les signaux et l'algorithme de décomposition modale empirique d'ensemble (EEMD) pour l'extraction des caractéristiques de défauts.

Ces caractéristiques sont introduites ensuite dans un SVM afin de détecter les défauts de faibles dimensions au niveau des roulements dans différentes conditions de fonctionnement.

Une autre étude menée par Saidi et al [136], où ils ont proposé une méthode pour le diagnostic de roulement d'arbre d'une éolienne en utilisant le kurtosis spectral comme un indicateur de défaut et la régression à vecteurs de support pour la classification de défauts. Dans la même année, Hui et al dans la référence [138], ont proposé une méthode basée sur la paire d'algorithmes SVM et Sempster Shafer (DS) afin de diagnostiquer les défauts de roulements. Ils ont montré que la technique élaborée a réussi de classifier les données saines et défectueuses d'une manière plus précise par rapport aux SVM conventionnels. De plus, les résultats obtenus ont dévoilé l'efficacité de la théorie DS qui a boosté la performance du classifieur SVM et a augmenté le taux de classification de 76% à 94%.

Après une année, Gangsar et Tiwari [139], ont réalisé le diagnostic de défaut d'une machine à induction par la combinaison d'algorithmes : SVM et la transformée en paquet d'ondelettes. Ils ont utilisé cinq fonctions d'ondelettes différentes (telles que la fonction Haar, Daubechies, Symlet, Coiflet et Discrete Meyer) avec quatorze indicateurs statistiques temporels et fréquentiels pour analyser l'impact de différentes ondelettes sur le diagnostic de défauts affectant la machine. Les résultats ont démontré que toutes les ondelettes mères utilisées avec les descripteurs « la moyenne » et « l'écart type » pouvaient être utilisées pour le diagnostic de défauts des machines asynchrones. Cependant, l'utilisation de la fonction discrète Meyer avec les mêmes caractéristiques extraites a amélioré les performances du SVM et a montré la plus grande précision de prédiction.

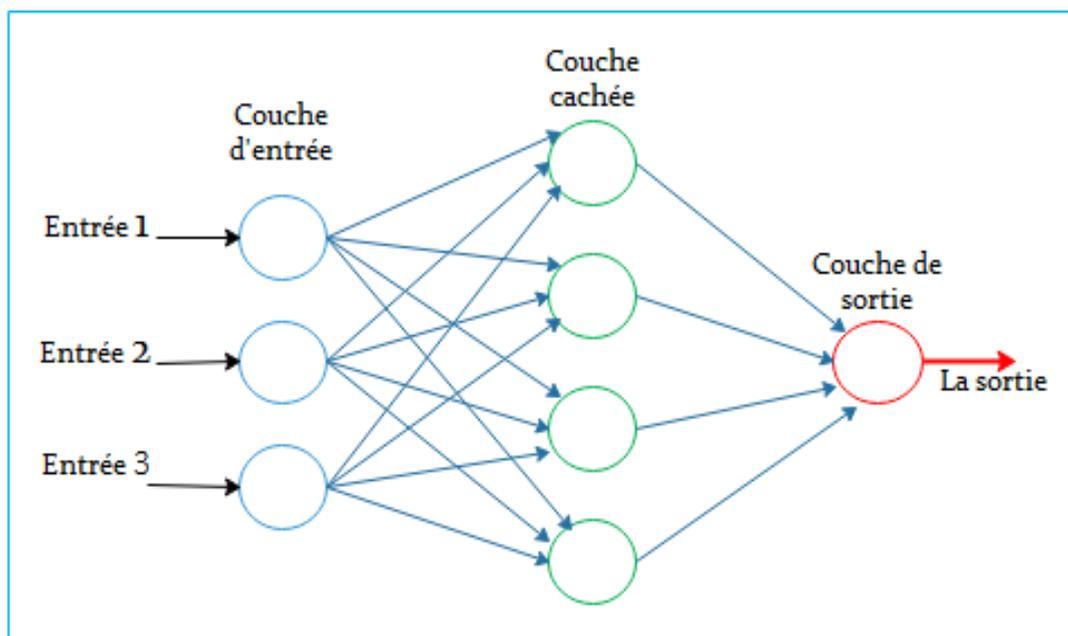
### **II.2.3.1.2 Réseau de Neurones Artificiels (ANN)**

Les ANN ont été développés selon un principe élémentaire de traitement de l'information semblable à celui du cerveau humain. Un réseau ANN se compose d'une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque couche contient un certain nombre de neurones qui sont considérés comme des unités de calcul dans le réseau (se référer à la figure II.5). Le neurone reçoit les entrées et multiplie chaque entrée par son poids. Puis, les résultats de multiplication sont combinés et transformés ensuite par une fonction d'activation afin de générer la sortie du neurone.

Soit un ANN ayant  $M$  neurones en entrée activés par un vecteur d'entrée  $x$  (de dimension  $M$ ), et par  $w_{i,j}^{0,1}$  le poids correspondant à la connexion entre le neurone  $i$  de la couche 0 et le neurone  $j$  de la couche  $l$  ; la sortie  $Y_j^1$  de chacun des neurones de la première couche cachée sera exprimée par l'équation II.11 :

$$Y_j^1 = f_j(\sum_{i=1}^M w_{i,j}^{0,1} x_i + b_j^1) \quad (\text{II.11})$$

où  $b_j^1$  est le biais et  $f_j$  représente la fonction d'activation qui pourra être une fonction sigmoïde, tangente hyperbolique ou une fonction linéaire par morceaux.



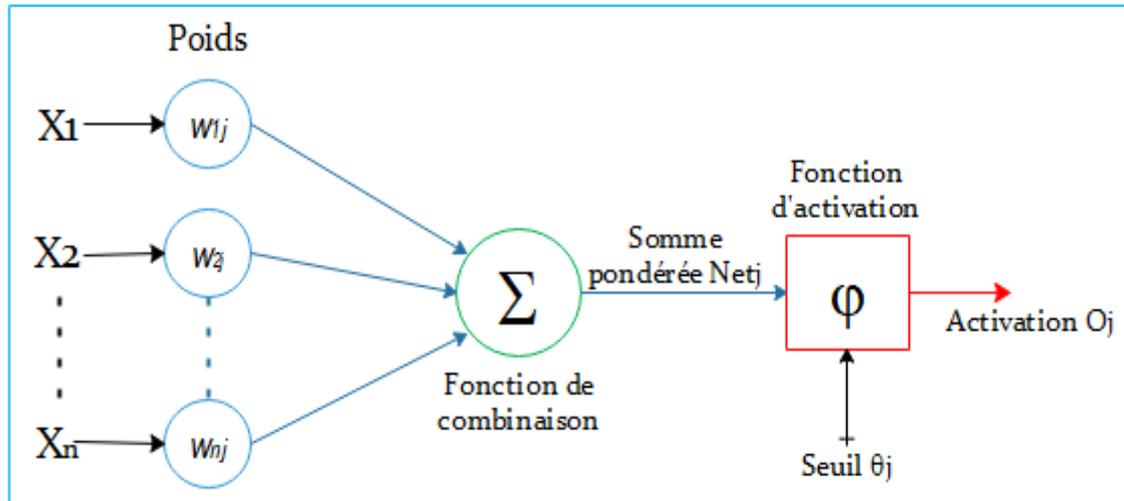
**Figure II.4** Exemple d'un réseau de neurones artificiels.

Le même processus exprimé par l'équation II.11 peut être répété pour les autres couches cachées ou celle de sortie, tel que chaque sortie d'une couche  $l$  sera l'entrée de la couche suivante  $l + 1$ .

La généralisation de l'équation II.11 à toutes les couches suivantes, sera définie comme suit :

$$Y_j^{l+1} = f_j(\sum_{i=1}^L w_{i,j}^{l,l+1} x_i^l + b_j^{l+1}) \quad (\text{II.12})$$

où  $L$  est le nombre de neurones de la couche  $l$ .



**Figure II.5** Modèle d'un neurone artificiel.

Il existe différents types de réseaux de neurones artificielles, par exemples : les perceptrons multicouches (MLP), les réseaux à fonctions de base radiale (RBF), les réseaux de neurones probabilistes (PNN), les réseaux de neurones récurrents (RNN), etc.

Parmi les critères qui nous permettent de distinguer entre ces réseaux, on cite l'architecture du réseau (par exemple le type et le nombre de couches), son niveau de complexité (comme la présence ou non d'une boucle de rétroaction), etc.

L'intégration de ces réseaux dans les applications de diagnostic de défauts a connu un grand succès [54]. Bin et ses collègues [140] ont extrait les indicateurs de défauts par la décomposition modale empirique (EMD) et la transformée en paquet d'ondelettes. Puis, ils ont utilisé un réseau de neurones à rétropropagation pour identifier les fissures précoces au niveau des rotors.

Dans une autre étude, Zhang et al [141] ont proposé une méthode basée sur la décomposition en paquet d'ondelettes (WPD), FFT et l'ANN pour le diagnostic de défauts et la prédiction de dégradation des composantes des machines dans un système de fabrication. Les signaux vibratoires décomposés par la WPD, sont transformés dans le domaine fréquentiel par la FFT. Ensuite, des descripteurs fréquentiels sont extraits et sont pris comme une entrée d'un modèle ANN dans la phase d'apprentissage. Enfin, Les auteurs ont prouvé l'efficacité de la technique proposée par rapport aux méthodes traditionnelles où ils ont réussi à identifier les défauts et même prédire la durée de vie utile restante de différents organes du système surveillé.

Quelques années plus tard, J. Ben Ali et ses collègues dans [142] ont proposé une méthode basée sur la combinaison d'EMD et ANN pour la détection de défauts de roulements. L'EMD est appliquée pour extraire les IMFs des signaux vibratoires non-stationnaires. Le processus de décomposition est suivi par une analyse mathématique afin de sélectionner les IMFs les plus pertinentes qui les ont utilisés ensuite pour extraire les caractéristiques de défauts. Puis, L'ensemble d'indicateurs choisi est utilisé pour entraîner un réseau ANN pour classifier les défauts de différents types et sévérités. Les résultats expérimentaux ont révélé l'efficacité de la théorie proposée pour l'évaluation automatique de la dégradation au niveau des roulements sans la nécessité d'une intervention humaine.

Un autre travail mené par Huang et al dans la référence [143], où ils ont établi un système de diagnostic de défauts basé sur la combinaison de la théorie d'extension et de réseau neuronal (NN) afin de détecter dix types de défauts les plus probables d'altérer le fonctionnement des moteurs à induction. A partir des signaux vibratoires mesurés, ils ont calculé les fréquences caractéristiques de défauts pour les utiliser ensuite comme données d'apprentissage d'un modèle ENN. Les résultats obtenus prouvent le bon potentiel de la méthode proposée pour l'identification et la localisation des défauts. Cette méthode est rapide, moins coûteuse et nécessite moins de données pour l'apprentissage.

### **II.2.3.1.3 Autres méthodes d'apprentissage conventionnel**

À l'exception des algorithmes ANN et SVM, d'autres méthodes ont été largement appliquées au diagnostic de défauts des machines tournantes, telles que l'arbre de décision (DT) [144], le classifieur bayésien naïf (NB) [84], les k plus proches voisins (KNN) [148], l'inférence neuro-floue adaptatif (ANFIS) [150], etc.

Abid et al [145] ont suggéré une nouvelle méthode basée sur l'optimisation stationnaire de la transformée en paquet d'ondelettes pour traiter les signaux vibratoires. Ils ont adopté l'arbre de décision pour la classification de défauts de roulement d'une machine asynchrone. Les résultats obtenus ont prouvé l'efficacité de l'approche proposée pour la détection des défauts de roulements à différents niveaux de gravité.

Kumar et ses collègues [146] ont fait le diagnostic des défauts de roulements sous différentes conditions de fonctionnement de la machine. La méthode proposée est basée sur l'extraction de descripteurs statistiques à partir des signaux vibratoires, suivie par une sélection des caractéristiques significatives qui a été effectuée à l'aide d'arbre de décision formulé par

l'algorithme J48. L'ensemble de paramètres jugés pertinents est introduit à deux classifieurs bayésiens (Naïve Bayes et Bayes-net) à des fins de classification.

Bradli et al [147] ont utilisé le classifieur KNN pour le diagnostic de roulements opérationnels sous différentes conditions de fonctionnement. L'intégration de l'outil KNN avec l'algorithme d'évolution différentielle binaire (BDE), a amélioré la tâche de surveillance et a prouvé l'efficacité de la stratégie proposée en maintenant de bonnes performances sous des conditions diversifiées.

Dans une autre étude menée par Rajabi et ses collègues dont la référence [149] dans laquelle ils ont proposé une nouvelle méthode dédiée au diagnostic des défauts de roulements en combinant la morphologie mathématique (MM) et le classifieur M-ANFIS à sorties multiples. Tout d'abord, la MM est utilisée pour filtrer les signaux vibratoires où les éléments de structure (SE) sont sélectionnés en fonction de la valeur de Kurtosis afin de rendre l'opérateur morphologique plus efficace. Puis, un ensemble d'indicateurs est extrait à partir des signaux filtrés pour former un vecteur de caractéristiques qui est ensuite pris comme une entrée à un modèle M-ANFIS. Enfin, Les résultats expérimentaux ont révélé l'efficacité de la stratégie proposée dans la détection des défauts de roulements sous différentes conditions opérationnelles liées à la charge et la vitesse.

### **II.2.3.2 Apprentissage profond (DL)**

Comme vu dans la littérature précédente, les méthodes conventionnelles d'apprentissage machine ont montré une efficacité significative dans le diagnostic de défauts mais ils ont l'inconvénient de limiter la capacité d'apprentissage des classifieurs parce qu'elles n'ont pas l'aptitude de traiter les données naturelles (données capteurs) sous leur forme brute. Ce qui montre que ces méthodes ont la difficulté d'apprendre ou de traiter des relations non-linéaires compliquées liées à la présence d'un défaut. Par conséquent, la capacité des classifieurs à effectuer la discrimination entre les classes est réduite, ce qui implique une forte susceptibilité d'erreur dans la phase de classification. Cela dépend généralement de la phase d'extraction et de sélection des caractéristiques pertinentes nécessitant la connaissance des techniques de traitement du signal, une expertise considérable et des connaissances approfondies afin de transformer les données brutes en une représentation interne appropriée à partir duquel le classifieur pourra effectivement détecter et classer les défauts.

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 fiables de surveillance et de diagnostic permettant de 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.2.3.2.1 Réseaux de neurones à convolution (CNN)**

Les CNN ont d'abord été proposés par LeCun [159] pour le traitement d'image et ils sont considérés comme un modèle de réseau de neurones profonds avec une structure acyclique (*feed-forward structure*) 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. Cette qualité d'analyse se résume en trois propriétés clés : une connectivité clairsemée (champs réceptifs locaux), un mécanisme de partage de poids et un sous-échantillonnage de la dimension de données dans le domaine spatial, ce qui réduit considérablement la quantité de paramètres d'entraînement et évite les risques de sur-apprentissage de l'algorithme.

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 :

$$x_j^l = f \left( b_j^l + \sum_{i \in M_j} x_i^{l-1} * k_{ij}^l \right) \quad (\text{II.13})$$

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 la vitesse 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
<b>Relu</b>	$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$
<b>Sigmoid</b>	$f(x) = \frac{1}{1 + e^{-x}}$
<b>Tanh</b>	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$

- *La Couche de sous-échantillonnage (SL)* connue aussi sous le nom « couche de *pooling* en anglais » et elle 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 :

$$x_j^l = f(\beta_j^l \mathbf{down}(x_j^{l-1} + b_j^l)) \quad (\text{II.14})$$

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 telle 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  $\beta$  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)* : 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 :

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, \quad \text{For } j = 1, \dots, K \quad (\text{II.15})$$

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

$$O(X) = f(W.X + b) \quad (\text{II.16})$$

où  $f(\cdot)$  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, respectivement.

Le but de FL est de collecter toutes les caractéristiques des sous-cartes d'indicateurs générées par la couche précédente pour la classification. La sortie finale est un vecteur unidimensionnel où chaque valeur de ce vecteur 1D est une valeur quantitative de la  $n$  classification.

Les réseaux CNN ont eu également 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 [160]. Ces dernières années, cet algorithme est considéré comme un outil de tendance, exploité et intégré 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.

Janssens et al [161] ont appliqué un réseau CNN pour le diagnostic de défauts des roulements où les résultats obtenus montrent que la technique proposée surpasse les performances de l'approche conventionnelle qui nécessite une extraction et une sélection manuelle d'indicateurs.

Ding et He [162] ont pris l'image d'énergie de paquet d'ondelettes (WPE) comme une entrée d'un réseau de neurones de convolution (ConvNet) pour le diagnostic de défauts de roulements. Une autre étude menée par Eren dans la référence [163] dans laquelle, il a pris les signaux vibratoires à leur état brut comme une entrée d'un réseau de neurones à convolution monodimensionnel (1DCNN) 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 1DCNN. 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 traitement du signal. Les performances obtenues démontrent que la complexité de calcul est réduite sans compromettre le taux de classification de défauts.

Zhang dans [164] et Li dans [165], ont amélioré la structure CNN avec des architectures profondes dotés d'une capacité surmontant l'impact de la variation de charge pour le diagnostic des défauts de roulement. Une structure CNN très profonde de 13 couches a été proposée dans [164] capable de garder un potentiel de classification élevé lors d'application de charges variables et dans des environnements bruyants. Li a proposé une nouvelle méthode de diagnostic de défauts basée sur le jumelage de l'algorithme CNN avec la théorie de Dempster-Shafer (DS). Celle-ci est implémentée par une matrice de distance. Les évaluations expérimentales révèlent que l'approche IDS-CNN proposée offre d'excellentes performances dans différentes conditions de charge et atteint le plus grand taux de classification par rapport aux autres méthodes ML et DNN [165].

Dans le but de réduire le coût de calcul dans la phase d'apprentissage des CNN en utilisant une petite quantité de données d'entraînement, un CNN adaptatif à chevauchement (AOCNN) est proposé dans la référence [166]. L'AOCNN traite directement les signaux vibratoires bruts monodimensionnels où le problème de la variante de décalage est traité par la couche de convolution adaptative et la couche de regroupement de la moyenne quadratique (RMS). Le problème marginal dans le réseau est allégé en utilisant la couche de chevauchement.

Les résultats expérimentaux révèlent que l'AOCNN avec un filtre « *Sparse* » peut identifier dix états de santé de roulements avec une précision de 99,19% lorsque seulement 5% d'échantillons est utilisé comme données d'apprentissage, ce qui est une amélioration significative étant donné que la plupart des méthodes DL exigent un minimum de 25 % de données allouées à 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%.

Récemment, Zhang et ses collègues [167] ont proposé une méthode de diagnostic intelligent 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 de 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.2.3.2.2 Autres méthodes d'apprentissage profond**

Actuellement et à l'exception des réseaux CNN, il existe divers algorithmes d'apprentissage profond tels que les réseaux de neurones profonds (DNN), les réseaux de croyances profondes (DBN), les auto-encodeurs (AE) et les réseaux de neurones récurrents à mémoire court-terme et long terme (LSTM), etc. Ces derniers ont été implémentés avec succès dans les systèmes de maintenance prédictive [155-158].

Li et ses collègues dans la référence [154] ont proposé un réseau de neurones profond (DNN) avec plusieurs couches cachées pour le diagnostic de défauts d'un système de fabrication des semi-conducteurs. Les résultats dévoilent de bonnes performances de la méthode proposée montrant la supériorité des DNN par rapport aux autres méthodes conventionnelles, telles que le perceptron multicouche (MLP), le SVM et la régression logique (LR).

Pan et ses collègues [168] ont combiné le CNN et LSTM unidimensionnels dans une seule structure où la sortie du CNN est considérée comme l'entrée du LSTM afin de diagnostiquer les différents défauts de roulements. Les résultats expérimentaux montrent que le taux de classification moyen de la méthode proposée atteint plus de 99%, ce qui surpasse les autres algorithmes de diagnostic.

Gan et Wang dans [153] ont appliqué un réseau DBN à deux couches pour le diagnostic de défauts de roulements. Ensuite, ils ont comparé la méthode proposée avec un réseau de neurones à rétropropagation (PBNN) et les SVM. Les résultats de la comparaison démontrent que le DBN a les meilleures performances par rapport aux techniques conventionnelles. Les méthodes d'apprentissage profond prennent généralement beaucoup de temps dans l'étape de formation, ce qui augmente significativement le coût du calcul et réduit la rapidité du diagnostic. Afin de surmonter cet inconvénient, Mao et al dans la référence [169] ont proposé une méthode de diagnostic exploitant le potentiel d'auto-encodeur à extraire les caractéristiques pertinentes et éventuellement la vitesse élevée d'entraînement des machines d'apprentissage extrêmes (ELM) pour l'identification de défauts de roulements. L'analyse comparative des résultats obtenus par rapport certaines approches de pointe, montre que la méthode AE-ELM est non seulement efficace mais elle a également une vitesse de diagnostic élevée.

### II.3 Conclusion

Ce chapitre résume les différentes étapes conçues pour la détection et le diagnostic intelligent de défauts des machines tournantes. La tâche de diagnostic utilisant les données capteur, est généralement basée sur trois démarches fondamentales : l'extraction d'indicateurs pertinents contenant les signatures de défauts, la sélection d'indicateurs dans le but d'avoir des caractéristiques avec une représentation plus significative dans une dimension réduite et finalement l'étape de classification de défaut qui permet de prendre une décision concernant l'état de santé de la machine à l'aide des moyens fournis par l'intelligence artificielle.

Dans chaque étape, les principales méthodes mises en œuvre dans la tâche de surveillance sont expliquées et accompagnées avec une synthèse bibliographique afin de référer les lecteurs à l'énorme progrès visualisé dans le domaine de la maintenance préventive.

Les principales conclusions qu'on peut tirer de ce chapitre sont :

- La performance du diagnostic basé sur les méthodes conventionnelles dépend de la qualité d'indicateurs extraits manuellement qui nécessitent des connaissances approfondies du domaine.
- Les méthodes ML classiques ne peuvent pas traiter des données capteur à leur état brut et elles peuvent avoir de bonnes performances lorsqu'elles fonctionnent avec une

petite quantité de données. De plus, Ces modèles ML ne maintiennent pas un bon niveau de transférabilité. C'est-à-dire, Ils ne peuvent pas être transférés ou généralisés à d'autres contextes, ce qui est possible avec l'approche DL.

- Le principal avantage de diagnostic à l'aide des méthodes d'apprentissage profond est que les caractéristiques pertinentes ne sont pas extraites manuellement ou par des experts du domaine mais elles sont apprises à partir des données brutes grâce à une procédure généralisée d'auto-apprentissage.
- En parallèle à l'extraction automatique d'indicateurs, l'approche DL réduit significativement la dimensionnalité d'une grande quantité de données d'entrée (*big data*) à travers l'architecture de ses réseaux où le nombre de neurones dans ses couches (ou dimension des filtres dans les CL et SL dans les réseaux CNN) est inférieure aux dimensions de données d'entrée.
- Les méthodes DL sont supérieures par rapport aux méthodes ML conventionnelles en termes de performance et d'efficacité du diagnostic de défauts, notamment les CNN dans le diagnostic de défauts de roulement.

# Chapitre III : Application au diagnostic des défauts de roulements

### III.1 Introduction

Comme nous avons vu précédemment, il existe plusieurs approches pour la surveillance de l'état de fonctionnement des machines tournantes. Approches plus ou moins complexes nécessitant la présence d'un expert et d'avoir des connaissances approfondies concernant la dynamique et la cinématique de la machine à surveiller, ce qui est difficilement réalisable surtout dans le cas des systèmes complexes. Avec le développement accru connu dans les firmes industrielles, le besoin d'avoir un système de surveillance plus ou moins automatique capable de détecter les défauts à un stade précoce est considéré comme une priorité absolue afin d'améliorer la tâche de maintenance préventive.

L'intégration des méthodes de l'intelligence artificielle dans les systèmes de diagnostic a offert une solution prometteuse à travers laquelle la tâche de diagnostic est convertie en tâche de classification.

La littérature nous a confirmé la supériorité de l'approche DL par rapport aux méthodes ML conventionnelles dans le diagnostic de défauts des machines tournantes, notamment les défauts de roulements.

Les roulements sont des organes cruciaux dans les machines tournantes. Divers articles ont signalé que cet organe est le plus susceptible d'avoir des défauts et qu'il peut même être la cause de l'apparition des défaillances au niveau des autres composantes de la machine.

En effet, Nandi [180] a rapporté que 40 à 50% de toutes les pannes affectant les moteurs électriques sont causées par les défauts de roulement ; Bonnett a dévoilé que 69% de défaillances affectant les moteurs asynchrones à grande puissance sont des défauts de roulements [106]. De plus, Immovili dans la référence [181] a estimé que la probabilité de défaillance de cet organe dans les machines tournantes varie de 40 à 90%. Ceci signifie que la surveillance de l'état de fonctionnement des roulements est une tâche primordiale afin d'assurer la fiabilité, maintenir la productivité et augmenter la durée de vie de ces machines.

Partant de ce fait, nous proposons dans les sections ultérieures quelques méthodes de diagnostic de défauts des roulements basées sur l'analyse des signaux vibratoires collectés à partir du banc d'essai de CWRU.

Ce chapitre est scindé en deux parties :

La première partie verra l'application des techniques conventionnelles de diagnostic des défauts de roulements à base du traitement EEMD. Cette méthode de prétraitement de signaux à base d'EEMD est proposée par Amarouayache dans la référence [170]. Elle est jumelée

avec quelques méthodes d'apprentissage classique d'IA notamment les SVM, K-NN et Naive Bayes. Amarouayache a utilisé ces méthodes comme des outils de prédiction et de décision afin d'identifier et de localiser les différents défauts de roulements. Les systèmes de diagnostic proposés seront évalués sous plusieurs conditions de fonctionnement et plus particulièrement sous des charges et vitesses variables.

La deuxième partie sera consacrée à l'application d'une technique d'apprentissage profond (DL) à la même base de données prise dans la première partie ; tel que, Le système de diagnostic créé à ce niveau est indépendant des outils de traitement de signal. On utilisera les signaux vibratoires collectés à leur état brut sans extraire les indicateurs de défauts manuellement. L'utilisation des CNN a l'avantage d'extraction automatique des différentes signatures de défauts contenues dans les signaux vibratoires, ce qui rend la méthode proposée plus puissante et ne nécessite pas l'intervention d'un expert du domaine [171].

### **III.2 Banc d'essai de « CWRU »**

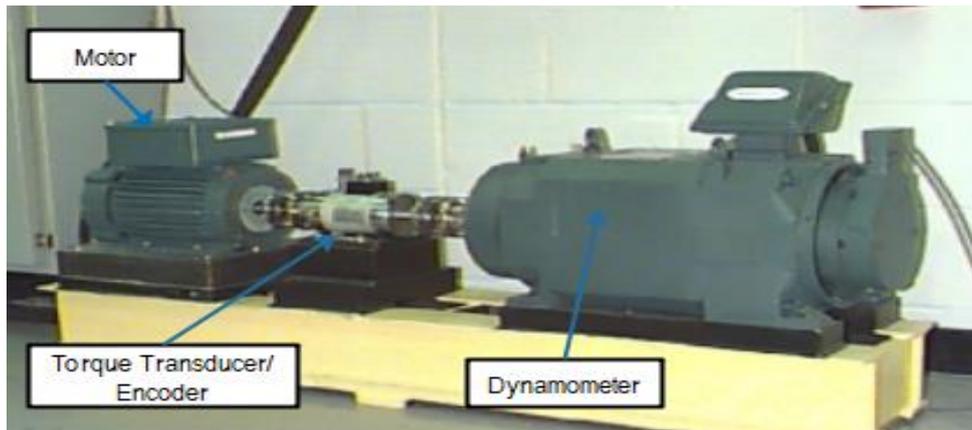
La base de données de l'Université de Case Western Reserve englobe les mesures de vibrations recueillies lors des essais de roulements à billes normaux ou défectueux sur un banc d'essai composé d'un moteur, un accouplement et une génératrice. Ce banc est représenté dans la Figure III.1 [172]. Les défauts sont sous forme de points de diamètres différents et ils ont été créés par une machine d'électroérosion sur les différents éléments de roulements.

Dans ce travail, les signaux vibratoires considérés sont ceux échantillonnés à 12 000 Hz avec plusieurs défauts de roulements : ORF (défaut de bague extérieure), IRF (défaut de la bague intérieure) et BAF (défaut de la bille). Selon l'application de la charge, nous avons quatre vitesses de rotation du moteur : 1797, 1772, 1750 et 1730 tr/min correspondant respectivement aux charges 0, 1, 2 et 3hp.

Dans cette partie nous avons sélectionné seulement 3 types de défaut des roulements avec la plus petite taille qui est égale à 0.007 *inch* (équivalent à 0.1778 millimètre).

Le tableau III.1 décrit les différents signaux sélectionnés de cette base de données où chaque signal est affiché avec un indice pour faciliter par la suite l'interprétation des résultats.

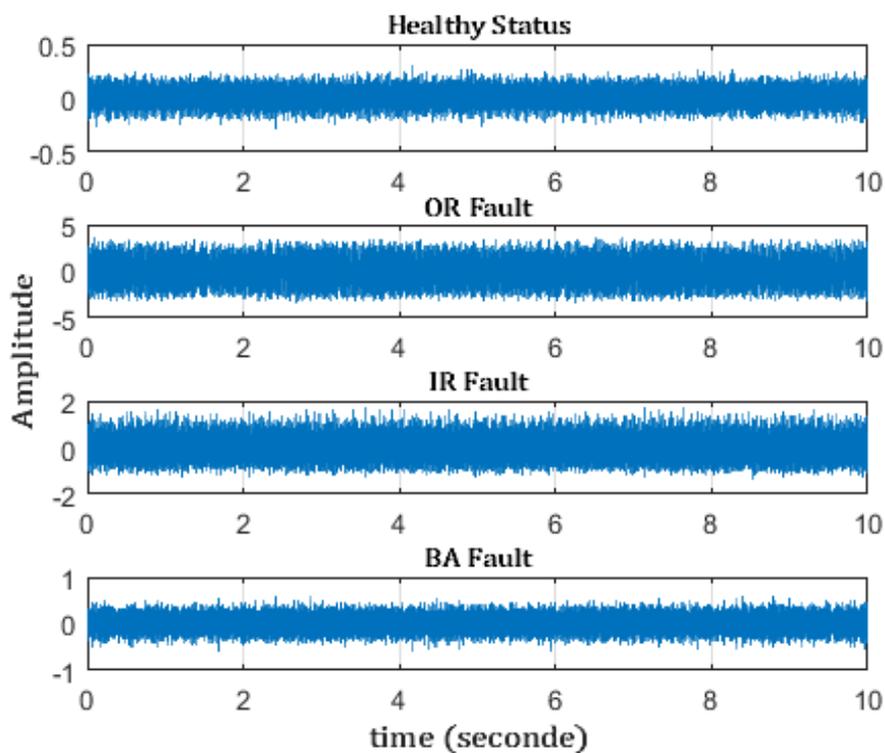
La figure III.2 montre les signaux vibratoires des 4 états fonctionnels des roulements sous la charge 0 hp.



**Figure III.1** Banc d'essai de l'Université CWR.

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

Etat de roulement	Charge (hp)	Indice
Sain	0,1,2 et 3	0
ORF	0,1,2 et 3	1
IRF	0,1,2 et 3	2
BAF	0,1,2 et 3	3



**Figure III.2** Signaux de vibration sous charge de 0 hp.

### III.3 Partie 01 : Diagnostic des défauts à base du traitement EEMD à l'aide des méthodes conventionnelles d'apprentissage automatique

#### III.3.1 Traitement de données

Afin d'avoir suffisamment d'échantillons que nous aurons besoin dans la phase d'apprentissage avec une des techniques de l'IA mentionnées dans le chapitre II, les signaux de vibration sont divisés en segments de même longueur par une segmentation non imbriquée, où chaque segment aura une taille de 576 points. A la fin du processus de segmentation, chaque défaut aura 500 segments. Pour trois types de défaut des roulements (ORF, IRF, BAF), y compris l'état normal (Sain), nous obtenons au total 2000 segments de vibration pour chaque condition de charge. Le tableau III.2 montre l'arrangement des ensembles de données construits.

**Tableau III.2** Arrangement de données vibratoires après la segmentation.

Nom du groupe	Nombre de segments	Condition de charge
A	2000	0 <i>hp</i>
B	2000	1 <i>hp</i>
C	2000	2 <i>hp</i>
D	2000	3 <i>hp</i>

#### III.3.2 Analyse par décomposition modale empirique d'ensemble « EEMD »

Dans le but d'avoir un diagnostic efficace de défauts au niveau des roulements, les chercheurs ont étudié intensivement différentes techniques de traitement du signal pour extraire avec précision les caractéristiques de ces défauts à partir des signaux vibratoires.

Parmi ces outils, on peut citer la décomposition modale empirique (EMD) qui est une méthode adaptative pouvant décomposer automatiquement un signal vibratoire sans l'intervention d'un expert du domaine et sans la nécessité d'une grande connaissance préalable sur les signaux.

L'EMD décompose les signaux vibratoires de hautes aux basses fréquences en une série de fonctions en mode intrinsèque (IMF) [51]. Ces composantes sont considérées comme une représentation transitoire des signaux qu'on peut les utiliser pour mettre en évidence les caractéristiques locales de ces signaux dans le cas d'une apparition d'un défaut.

L'EMD d'Ensemble est ensuite proposée afin de surmonter le problème de mélange de modes (mode-mixing en anglais) de l'EMD de base [52].

Dans le présent travail, l'EEMD est utilisée pour améliorer la détection de défauts en tant que procédé amélioré qui minimise l'effet du bruit dans les signaux traités. Cette méthode non seulement maîtrise le mixage de modes, mais aussi élimine le bruit résiduel persistant dans les IMF et diminue considérablement le temps de calcul de l'algorithme.

Dans la suite de cette étude, nous allons proposer une démarche simple pour améliorer la détection précoce de défauts des roulements en se basant sur l'application de l'EEMD. Pour cela, une procédure de sélection d'IMF est proposée afin de construire de nouveau les signaux vibratoires avec moins de bruit.

### **III.3.3 La méthodologie de diagnostic proposée**

La méthode proposée utilise l'EEMD avec une sélection à priori des IMFs susceptibles de contenir l'information utile pour nous renseigner sur l'état de dégradation des roulements.

Cette procédure peut être structurée par les étapes suivantes :

- (i) Décomposer le signal vibratoire enregistré par la technique EEMD ;
- (ii) A l'aide d'une procédure de sélection, choisir les IMFs contenant l'information utile sur le défaut et éliminer les autres ;
- (iii) Reconstruire le signal vibratoire à base des IMF choisies ;
- (iv) Extraire les indicateurs statistiques temporels à partir des nouveaux signaux reconstruits ;
- (v) Identifier et localiser les défauts de roulements à l'aide des méthodes conventionnelles d'apprentissage statistique.

Les IMFs générées par l'EEMD ont des sensibilités différentes par rapport aux défauts.

Certaines IMFs sont appropriées et étroitement liées aux défauts, tandis que les autres ne sont pas adéquates. La principale question de cette méthode est la sélection des IMF intéressantes.

Dans ce qui suit, nous étudierons la question en détail, et nous exposerons les motivations de l'utilisation d'une méthode adaptée afin de répondre à cette question et dans le but d'éliminer le maximum du bruit contenu dans les signaux vibratoires.

### **III.3.4 Sélection d'IMFs**

Lorsqu'un défaut apparaît au niveau des roulements, une série d'impulsions cycliques est générée dans les mesures vibratoires, dû à l'impact de glissement de la surface des éléments

roulants avec la surface présentant un défaut. De plus, Cet impact excite les résonances de la structure causant une augmentation d'énergie du signal vibratoire autour de ces résonances.

Toutefois, avec les glissements usuels de ces éléments, des phénomènes aléatoires peuvent être introduits au signal vibratoire, ce qui affectera la périodicité des impulsions par la création des impulsions aléatoires.

Nous avons élaboré une méthode de sélection 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 [73, 75]. 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, sont expliquées dans la référence [173].

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 25% d'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 0.25, correspond à la sélection des trois ou quatre premières IMFs, qui ont la plus grande énergie.

En effet, Les IMFs choisies sont présumées être les composantes les plus importantes 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 :

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

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.

### III.3.5 Application de la méthode proposée sur la base de données de CWRU

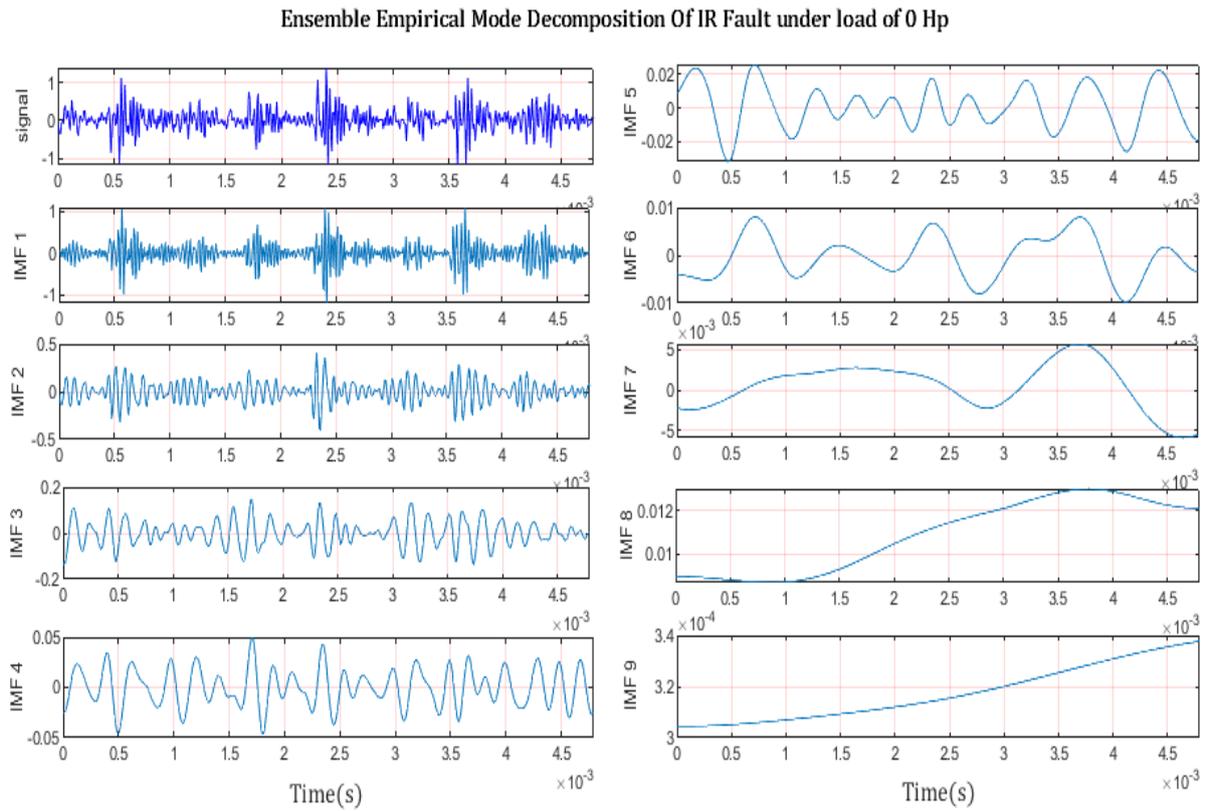
Dans cette section, nous examinons la méthode proposée sur la base de données de CWRU (Case Western Reserve University) [172]. Le traitement du signal basé sur l'EEMD suivi par la procédure de sélection d'IMFs mentionnées ci-dessus, est appliquée à tous les signaux vibratoires segmentés et arrangés dans le tableau III.2.

Grâce au processus de l'EEMD, chaque échantillon peut être décomposé en une combinaison de plus de dix fonctions en mode intrinsèque (IMFs), ainsi qu'un résidu. La figure III.3 montre un exemple d'application d'EEMD à un signal de vibration soumis à un défaut de cage interne (IRF). Après le processus de décomposition, des nouveaux signaux de vibration sont reconstruits à l'aide de la méthode décrite ci-dessus basée sur la sélection des IMFs les plus pertinentes. L'histogramme de la figure III.4 reporte les valeurs de coefficient de corrélation calculées pour toutes les IMFs obtenues par rapport à leur signal original (sous IRF) ; les signaux reconstruits des 4 états opérationnels de roulements sous la condition de charge 1hp, sont tracés dans la figure III.5.

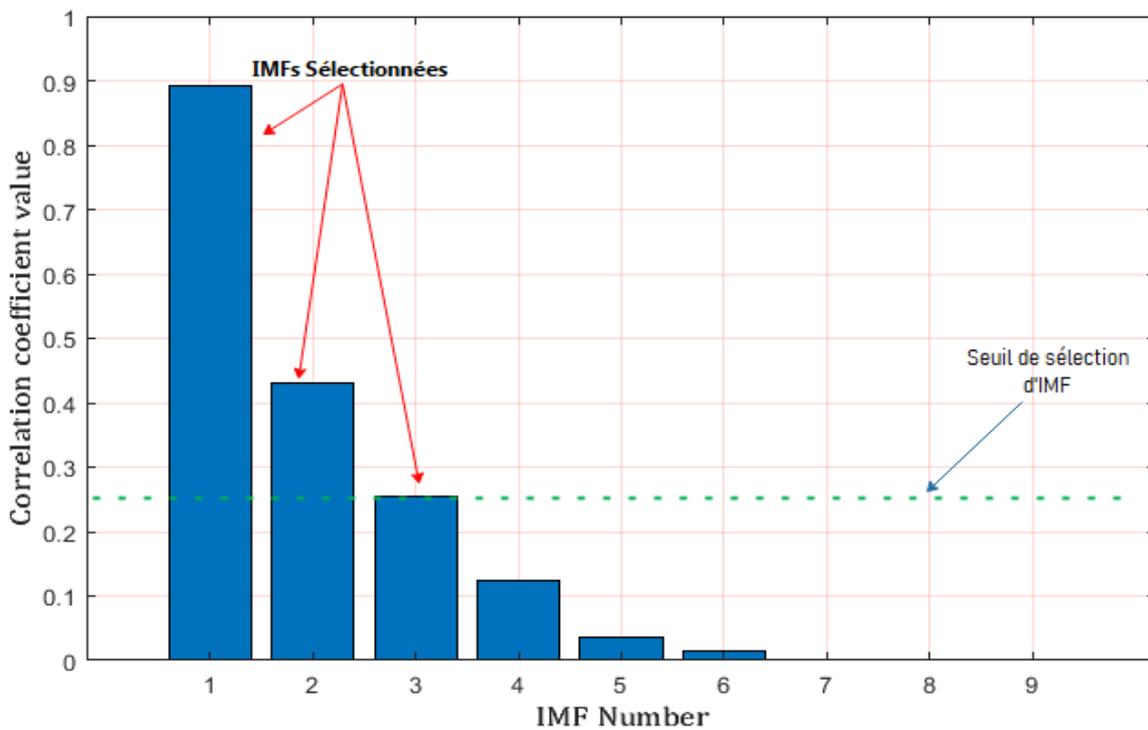
En analysant la figure III.3, on peut constater que l'EEMD a extrait l'ensemble des composantes (IMFs) du signal vibratoire IRF dans un ordre décroissant (d'une oscillation rapide vers une lente oscillation). C'est-à-dire, de la haute fréquence à la basse fréquence, ce qui signifie que chaque IMF a une bande de fréquence unique. De plus, l'énergie de ces IMFs diminue rapidement (parce que l'énergie reflète l'amplitude des vibrations).

Le processus de reconstruction de signaux a conservé les impulsions périodiques ou même aléatoires dans les mesures de vibration pour chaque état opérationnel des roulements en offrant une similarité importante par rapport aux signaux originaux.

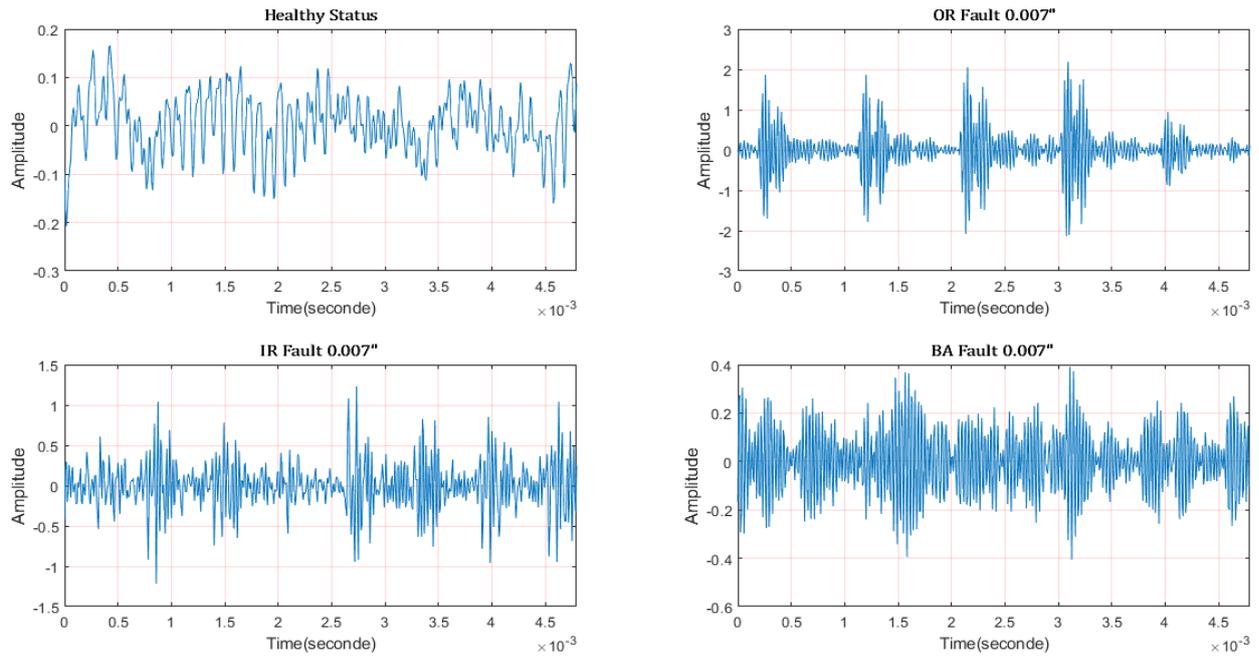
Les signaux reconstruits seront utilisés ci-après pour extraire les informations sous forme d'indicateurs statistiques dans le but de chercher les signatures de défauts afin de les identifier par une des méthodes d'IA qu'on va aborder dans les sections suivantes.



**Figure III.3** 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).



**Figure III.4** Procédure de sélection d'IMF après la décomposition du signal IRF par l'EEMD.



**Figure III.5** Nouveaux signaux vibratoires reconstruits sous la condition de charge 1 hp.

### III.3.5.1 Extraction d'indicateurs statistiques et classification de défauts :

Dans la phase d'application, plusieurs descripteurs temporels sont extraits à partir des signaux vibratoires reconstruits, tels que l'Entropie, Kurtosis, Skewness, etc.

Ces paramètres statistiques choisis sont utilisés pour construire des vecteurs de caractéristiques qui sont ensuite alimentés à plusieurs algorithmes de classification.

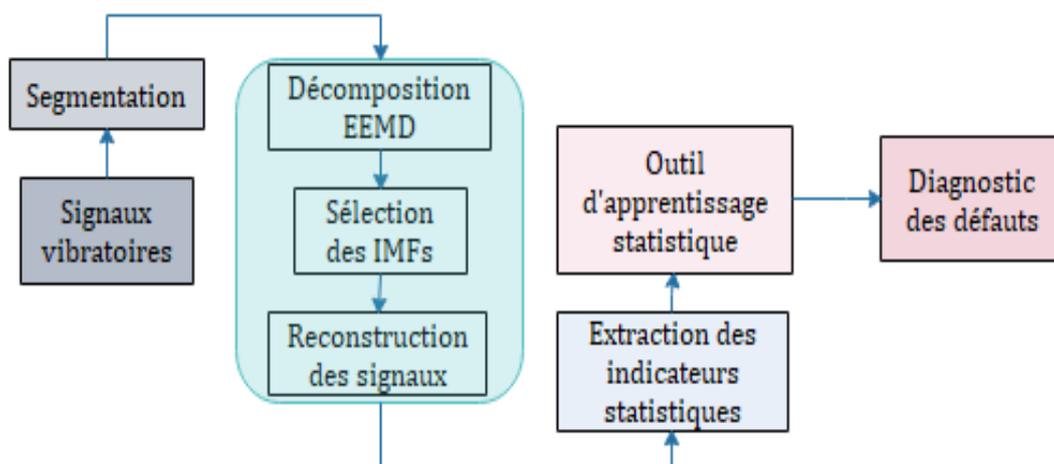
Les outils d'apprentissage statistique qu'on a utilisé dans cette partie, sont MCSVM, KNN et Naive Bayes.

L'utilisation de plusieurs classifieurs, nous permet de chercher le meilleur algorithme d'apprentissage afin de rendre la méthode de diagnostic proposée plus performante.

Le tableau III.3 contient les formules mathématiques de l'ensemble d'indicateurs extraits dans le domaine temporel à partir des signaux reconstruits et la figure III.6 expose l'organigramme générale de l'approche utilisée.

**Tableau III.3** Indicateurs temporels extraits à partir des signaux reconstruits.

Indicateur statistique	Formule mathématique
Moyenne	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ (III.3)
Valeur maximale	$F_{pv} = \max ( x_i )$ (III.4)
Valeur minimale	$F_{mv} = \max ( x_i )$ (III.5)
RMS	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$ (III.6)
Variance	$V = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$ (III.7)
Ecart-type	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$ (III.8)
Skewness	$S = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^3}{\sigma^3}$ (III.9)
Kurtosis	$K = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{\sigma^4}$ (III.10)
Entropy	$Entropy = -K \sum_{i=1}^N p_i \log p_i$ (III.11)

**Figure III.6** Organigramme de l'approche utilisée.

### III.3.5.2 Evaluation de performance sous la même condition de charge et de vitesse :

On sélectionne aléatoirement 60% d'indicateurs statistiques extraits à partir des signaux vibratoires reconstruits de chaque ensemble de données pour entraîner trois types de classifieur « MCSVM », « KNN » et « Naive Bayes », tandis que le reste des indicateurs (40%) est laissé comme des données de test.

Le processus d'apprentissage/test se fait pour chaque condition de fonctionnement séparément et le tableau III.4 résume l'ensemble des résultats obtenus.

**Tableau III.4** Résultats de classification de différents classifieurs sous la même condition de charge et de vitesse.

Expérience	Ensemble d'apprentissage	Ensemble de test	Charge/Vitesse (hp)/(tr/min)	MC-SVM (%)		K-NN (%)	Naive Bayes (%)
				OAA	OAD		
1	A	A	0/1797	100	100	100	100
2	B	B	1/1772	100	100	100	100
3	C	C	2/1750	100	100	100	100
4	D	D	3/1730	100	100	100	100

A partir de ces résultats, on peut voir clairement que les trois classifieurs utilisés, tels que le MC-SVM avec ses deux techniques One-Against-One (OAD) et One-Against-All (OAA), K-NN et Naive Bayes sont arrivés à identifier et localiser tous les types de défaut de roulements avec un taux de classification maximale, qui est égal à 100%.

De ce fait, on pourra dire que les techniques proposées ont une excellente aptitude à faire la discrimination entre les classes dans le cas des roulements opérationnels sous les mêmes conditions de charge et de vitesse.

### III.3.5.3 Evaluation de performance sous conditions de charge et de vitesse variables

Nous pouvons voir que les méthodes proposées à base du traitement EEMD, lorsqu'ils sont entraînés et testés avec des indicateurs statistiques provenant des mêmes conditions de charge et de vitesse, les classifieurs MC-SVM, K-NN et Naive Bayes peuvent atteindre 100% comme taux de classification. Cependant, dans l'application réelle ou dans l'industrie, les machines et ainsi leurs roulements doivent fonctionner dans différents types de conditions. Lorsque la condition de travail change, le signal de vibration mesuré change également. Cela rend le diagnostic de défauts plus difficile et le classifieur doit être généralement réentraîné avant d'être appliqué dans une condition de travail différente.

Dans cette section, nous menons des expériences pour évaluer les performances des méthodes de diagnostic proposées dans différentes conditions de charge et de vitesse.

Comme mentionné dans la section III.2.1, nous avons construit quatre ensembles de données vibratoires correspondant à quatre conditions opérationnelles du banc d'essai : 0 hp (jeu de données A), 1 hp (jeu de données B), 2 hp (jeu de données C) et 3 hp (jeu de données D).

Dans l'expérience 1, on utilise 60% d'indicateurs statistiques extraits à partir des signaux vibratoires reconstruits appartenant à l'ensemble de données « A » pour entraîner les trois classifieurs : MC-SVM (avec ses deux techniques OAO et OAA), K-NN et Naive Bayes.

Ensuite, 40% des indicateurs extraits de chaque ensemble de données B, C et D sont utilisés dans la phase de test.

Les expériences 2, 3 et 4 sont menées de la même manière que dans l'expérience 1 sauf que les jeux de données sont alternés.

**Tableau III.5** Résultats de classification de différents classifieurs sous des conditions variables de charge et de vitesse.

Expérience	Ensemble d'apprentissage	Ensembles de test	MC-SVM (%)		K-NN (%)	Naive Bayes (%)
			OAA	OAO		
1	A	B, C et D	100	99.79	99.89	100
2	B	A, C et D	100	100	100	100
3	C	A, B et D	99.89	99.89	99.79	100
4	D	A, B et C	100	100	99.79	99.79

Dans les quatre expériences étudiées, le taux de classification le plus faible est égale à 99.79% avec un taux d'erreur équivalant à 0.21% suivant l'expérience 1 (le cas du MC-SVM utilisant la technique OAO), l'expérience 3 (le cas du K-NN) et l'expérience 4 (pour les deux cas utilisant K-NN et Naive Bayes). Par contre, le classifieur qui a donné les meilleurs résultats est le MC-SVM utilisant la technique OAA avec une moyenne de 99.97% pour le total des expériences effectuées.

Après cette comparaison et en visualisant les résultats obtenus, on peut dire que tous les classifieurs qui sont jumelés avec le traitement EEMD proposé en [170], ont donné d'excellentes performances et ils sont arrivés à classifier les défauts de roulements sous des conditions de charge et de vitesse variables avec une précision optimale.

## III.4 Partie 02 : Diagnostic des défauts à base de l'apprentissage profond

### III.4.1 Traitement de données

On prend les mêmes données vibratoires du CWRU arrangées dans le tableau III.2, dans lequel la longueur des segments a été choisi exprès auparavant comme 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 576 points, ce qui correspond à une image vibratoire de taille 24 x 24 soit un total de 576 pixels.

Le processus de conversion du signal de vibration « 1D » à une image en niveaux de gris « 2D », est expliqué ci-dessous :

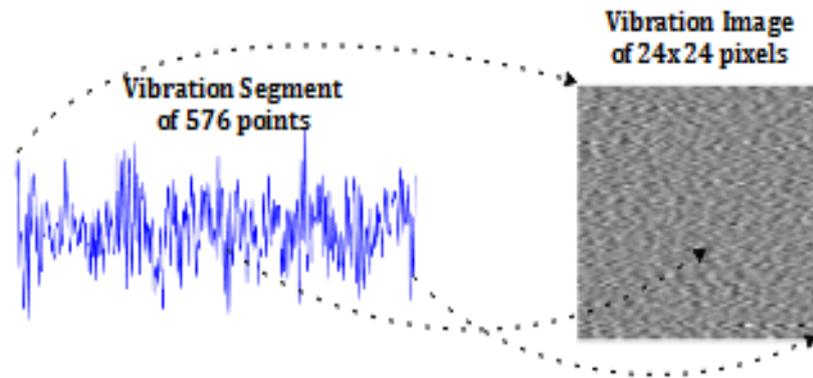
L'amplitude de chaque échantillon du signal de vibration est normalisée dans l'intervalle [0, 1]. Cette valeur définit l'intensité lumineuse d'un pixel et elle peut se varier du noir (0) jusqu'au blanc (1) en passant par les nuances qui sont contenues dans cet intervalle. Pour cela, l'amplitude normalisé 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 dans 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.

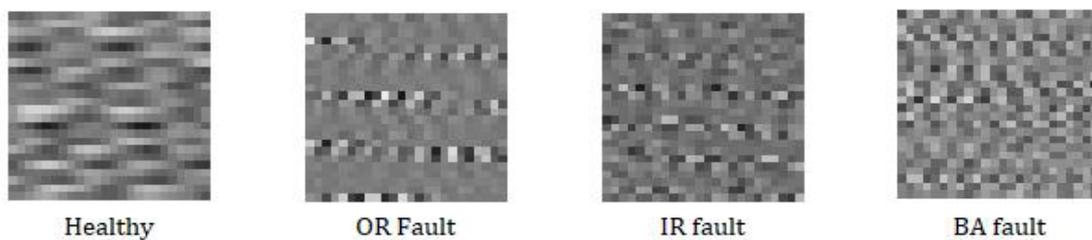
Le nombre de pixels dans l'image de vibration faut qu'il soit égal au nombre de points dans le signal vibratoire. Dans notre cas, tous les segments de longueur '576 points' sont convertis en images vibratoires de taille '24x24 pixels'.



**Figure III.7** Processus de conversion du signal  $1D$  en image vibratoire  $2D$ .

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 un total de 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  $0\text{ hp}$ .



**Figure III.8** Images vibratoires correspondantes à la charge  $0\text{ hp}$ .

**Tableau III.6** Disposition des images vibratoires construites.

Nom d'ensemble	Nombre d'images	Condition de charge ( $hp$ )
<i>A</i>	<i>2000</i>	<i>0 hp</i>
<i>B</i>	<i>2000</i>	<i>1 hp</i>
<i>C</i>	<i>2000</i>	<i>2 hp</i>
<i>D</i>	<i>2000</i>	<i>3 hp</i>

### III.4.2 Méthodologie de diagnostic proposée

Dans cette partie, nous utilisons une méthode différente à celles appliquées dans la partie précédente, et elle a été proposée par Amarouayache, I.I.E dans la référence [171].

La technique de diagnostic proposée se base principalement sur le traitement d'images vibratoires construites précédemment à l'aide des réseaux de neurones de convolution, où les signaux collectés ne sont pas analysés par des outils de traitement de signal avant leurs conversions en images (sans l'application d'EEMD ou autres méthodes). L'organigramme du système de diagnostic réalisé est exposé dans la figure III.9.

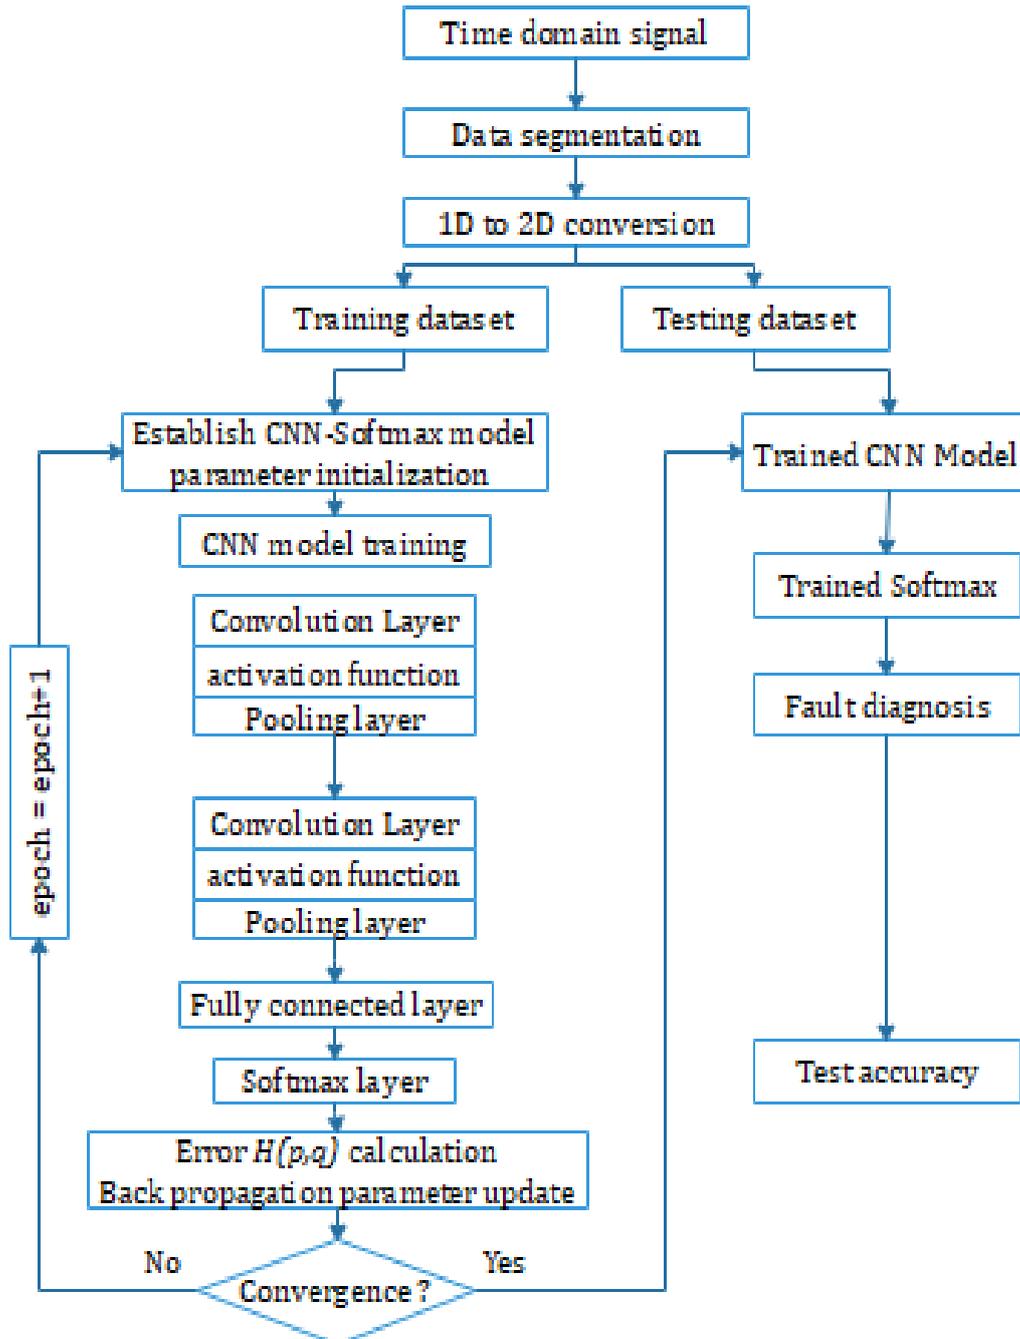
#### III.4.2.1 L'architecture proposée du modèle CNN

La couche d'entrée du modèle CNN doit avoir la même taille que les images vibratoires transformées « 24x24 » et en raison de la petite taille des images en niveaux de gris, nous construisons un réseau CNN avec une structure basique, qui ne contient que deux couches de convolution successives de taille de noyau 5x5 pour la première CL et 3x3 pour la deuxième CL. Chaque couche CL est connectée à une couche de regroupement de type max-pooling (SL) de taille 2x2.

La taille de noyau et le nombre de filtre pour chaque couche dans notre réseau CNN, sont définis expérimentalement et après plusieurs essais, les hyperparamètres finaux sélectionnés du modèle CNN adopté, sont décrits dans le tableau III.7.

**Tableau III.7** Structure de notre modèle CNN.

Type de couche	Taille de noyau	Nombre de filtres	Taille de sortie
CL1	5x5	30	20x20
SL1	2x2	/	10x10
CL2	3x3	60	8x8
SL2	2x2	/	4x4



**Figure III.9** Organigramme de la méthode proposée pour le diagnostic de défauts.

#### III.4.2.2 Evaluation de performance sous la même condition de charge et de vitesse:

Dans la 1<sup>ère</sup> expérience, on sélectionne aléatoirement 60% des images vibratoires appartenant à l'ensemble « A » du tableau III.6 pour entraîner notre modèle CNN, tandis que le reste des images du même ensemble de données (40%), est laissé comme des échantillons de test.

Par la suite, nous sommes conduits à effectuer 3 autres expériences de la même manière que l'expérience précédente, où les images vibratoires d'apprentissage/test sont alternées séparément des jeux de données B, C et D.

Les taux de classification de la méthode proposée sont enregistrés dans le tableau III.8 et les résultats de classification détaillés sont clarifiés dans la matrice de confusion présentée dans la figure III.10.

Comme mentionné dans le tableau III.8, la technique de diagnostic de défaut proposée atteint une précision de classification élevée équivalente à 100% dans les quatre expériences effectuées.

**Tableau III.8** Résultats de classification par notre méthode de diagnostic de défauts.

Expérience	Nom d'ensemble Training (60%) / Testing (40%)	Taux de classification
1	A	100%
2	B	100%
3	C	100%
4	D	100%

1	200 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	200 25.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	200 25.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	200 25.0%	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.10** Matrice de confusion détaillant les résultats du diagnostic dans la même condition de charge et de vitesse (la même matrice de confusion pour les 4 expériences).

À partir de la matrice de confusion exposée dans la figure III.10, il est clair que la méthode proposée identifie avec succès tous les types de défaut des roulements opérationnels dans la même condition de charge et de vitesse, où les résultats de diagnostic atteignent une précision maximale avec un taux d'erreur nul.

Dans les parcs industriels réels, les roulements en tant que composant fondamental des machines tournantes, doivent continuer à fonctionner dans des conditions diverses. Cette diversité de conditions de travail comprend soit des changements de charge et de vitesse, soit l'influence du bruit.

Les changements de charge et de vitesse sont causés par les interventions humaine pour accomplir les différentes tâches industrielles, cependant, le bruit est causé par différentes interférences harmoniques liées à l'environnement de la machine. Pour ce fait, nous devons examiner notre système de diagnostic dans des conditions de travail variables, y compris les conditions de charge, vitesse et de bruit.

#### **III.4.2.3 Evaluation de performance sous conditions de charge et de vitesse variables**

Pour évaluer l'efficacité de notre méthode de diagnostic dans des conditions de charge et de vitesse variables et sans réentraîner notre système de diagnostic, nous effectuons 4 expériences, où on réutilise les mêmes modèles CNN entraînés dans la partie ci-dessus.

Chaque modèle CNN sélectionné est formé auparavant par 1200 images vibratoires à partir d'un seul ensemble de données du tableau III.6 et il sera ensuite testé par 2400 images provenant de trois autres ensembles de données. Les performances obtenues sont enregistrées dans le tableau III.9.

Dans la première expérience, nous utilisons le modèle CNN entraîné précédemment par 1200 images vibratoires provenant de l'ensemble de données « A » afin de tester sa performance d'identification de défauts par un ensemble différent de données, qui contient au total 2400 images vibratoires provenant des ensembles de données B, C et D (800 images chacun).

Chacune des expériences 2, 3 et 4 sont effectuées de la même manière que la première expérience, sauf que le modèle CNN entraîné et les ensembles de données de test sont alternés.

**Tableau III.9** Taux de classification sous des conditions de charge et de vitesse variables.

Expérience	Données d'entraînement	Données de test	Taux de classification
1	A	B, C and D	100%
2	B	A, C and D	100%
3	C	A, B and D	100%
4	D	A, B and C	99.92%

Comme le montre le tableau III.9, la performance la plus faible est notée dans l'expérience quatre dans laquelle l'efficacité d'identification de défauts atteint un taux de classification élevé qui est égal à 99,92% avec un taux d'erreur trop petit (error rate= 0.08%).

En revanche, dans les expériences 1, 2 et 3, les performances de diagnostic atteignent 100% comme taux de classification.

par conséquent, ces expériences prouvent la haute efficacité de la méthode proposée pour le diagnostic des défauts de roulements, où il est précisé que sans réentraîner le modèle CNN adopté, notre méthode continue d'atteindre une performance élevée sous des conditions opérationnelles de charge et de vitesse variables.

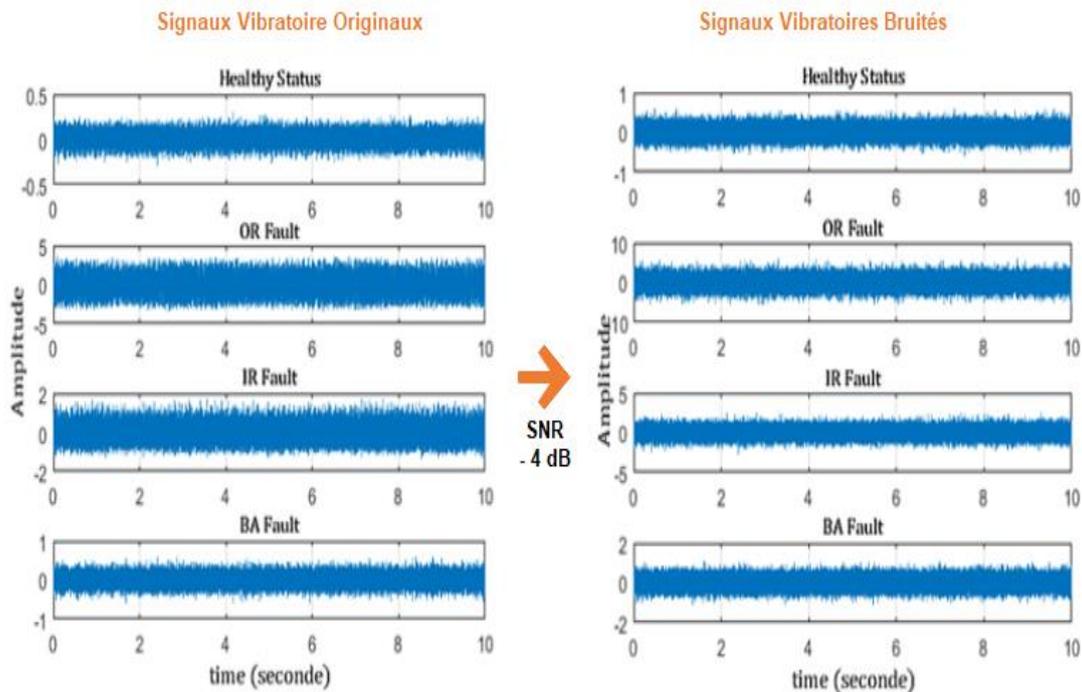
#### III.4.2.4 Evaluation de performance sous conditions de bruit :

Afin d'évaluer le système de diagnostic proposé dans différentes conditions de bruit, nous ajoutons des variables de bruit blanc gaussien additif (AGWN) aux signaux de vibration d'origine pour former des signaux vibratoires bruités. L'expression mathématique III.13 définit la relation du rapport « signal / bruit » (SNR : signal-to-noise ratio).

La méthode proposée est examinée sous des valeurs SNR faibles et élevées qui varient de -4 à 10 dB (décibel).

$$SNR = 10\log_{10}\left(\frac{P_{signal}}{P_{noise}}\right) \quad (III.13)$$

Où  $P_{signal}$  dénote la puissance du signal et  $P_{noise}$  signifie la puissance du bruit dans ce signal. La figure III.11 montre les signaux vibratoires sous la charge 0 hp à l'état original et les mêmes signaux sous un bruit blanc gaussien ajouté d'une valeur SNR équivalente à -4 décibel.



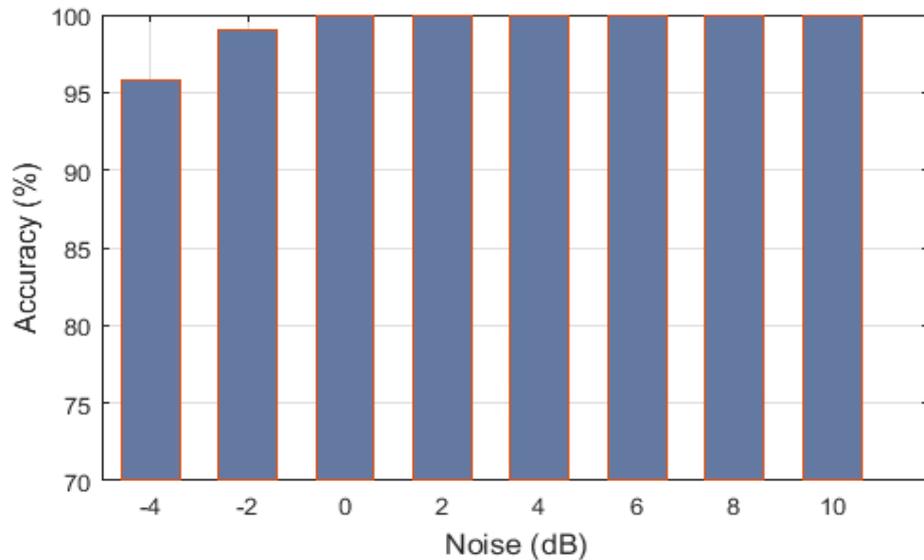
**Figure III.11** Signaux vibratoires bruités sous une valeur de SNR = -4 Db.

Les mêmes processus précédents sont réalisés sur les signaux bruités obtenus, y compris la division en segments, qui sont ensuite convertis en images en niveaux de gris. Puis, les images de vibrations bruitées sont considérées comme une entrée au modèle CNN adopté.

Les précisions de diagnostic de défauts de la méthode proposée sous des valeurs variables de SNR, sont présentées dans la figure III.12.

A partir de la figure III.12, nous pouvons évidemment voir que le modèle CNN proposé continue d'atteindre 100% comme taux de classification sous des valeurs élevées de SNR, variante de 0 à 10 Db. Cependant, sous de faibles valeurs de SNR, les performances se dégradent et la précision de classification atteint respectivement 99% selon SNR= -2 et 95,97% selon SNR = -4 dB.

Pour ce fait, nous avons essayé d'améliorer les performances de notre système de diagnostic sous de faibles valeurs SNR en ajoutant un supplément de filtres dans la première et la deuxième couche de convolution. Le tableau III.10 résume les expériences réalisées et les résultats obtenus.



**Figure III.12** Histogramme des performances de la technique proposée dans différentes conditions de bruit.

**Tableau III.10** Résultats de classification par rapport au nombre de filtres dans les deux couches de convolution.

Expérience	Nombre de filtres		Taux de classification	
	CL1	CL2	SNR= -2 dB	SNR= -4 dB
1	30	60	99 %	95.75 %
2	35	70	100 %	97.60 %
3	40	80	100 %	98.12 %

Nous pouvons voir à travers cette expérience que notre modèle CNN fonctionne mieux quand le nombre de filtres augmente dans les couches de convolution « CL1 et CL2 ».

Les performances de classification atteignent 100% pour SNR = -2db et atteignent 98,12% pour SNR = -4db.

Dans les cas de test à faible SNR, l'augmentation du nombre de filtres de convolution a rendu notre réseau plus efficace de manière qu'il a appris plus de caractéristiques potentielles à travers l'amélioration de sa capacité d'extraction d'informations contenant les signatures de défauts. Par contre, cette amélioration a été accompagnée par une augmentation considérable du coût de calcul de l'algorithme. La figure III.13 expose la matrice de confusion liée à la troisième expérience du tableau III.10 (SNR= -4dB).

Les résultats obtenus décrits par la matrice de confusion présentée dans la figure III.13, montrent que notre système de diagnostic a mal classé seulement 15 échantillons de 600 images vibratoires bruitées (étiquette 2, 3 et 4) avec un taux d'erreur équivalant approximativement à 1,9%.

La méthode CNN-Softmax a réussi de détecter l'état sain (étiquette 1) avec un taux de classification équivalant à 100%, ce qui prouve la forte capacité de notre méthode à différencier un roulement sain des roulements défectueux dans des environnements opérationnels bruyants.

Les résultats satisfaisants obtenus démontrent la robustesse et l'efficacité élevées de la méthode de diagnostic de défauts proposée qui fonctionne toujours bien sous les conditions de bruit.

1	200 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	195 24.4%	3 0.4%	0 0.0%	98.5% 1.5%
3	0 0.0%	2 0.3%	192 24.0%	2 0.3%	98.0% 2.0%
4	0 0.0%	3 0.4%	5 0.6%	198 24.8%	96.1% 3.9%
	100% 0.0%	97.5% 2.5%	96.0% 4.0%	99.0% 1.0%	98.1% 1.9%
	1	2	3	4	
	Target Class				

**Figure III.13** Matrice de confusion obtenue à la 3ème expérience (*le cas SNR= - 4db*).

### 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 d'IMFs afin de reconstruire de nouveau les signaux vibratoires. 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 systèmes du diagnostic établis à base des techniques conventionnelles, sont examinés sous différentes conditions opérationnelles, particulièrement liées aux variations de la charge et de vitesse.

Les résultats obtenus montrent l'efficacité des méthodes appliquées au diagnostic de défauts des roulements, où les trois techniques proposées : EEMD-SVM, EEMD-KNN et EEMD-NB, ont réussi à identifier et localiser les défauts de roulements étudiés sous différentes conditions du travail avec une performance élevée.

Ces bonnes performances prouvent aussi l'efficacité du traitement de signal effectué basé sur l'EEMD, ce qui a rendu les signaux vibratoires reconstruits plus clairs, moins bruités, et sans perdre les informations contenant les différentes signatures de défauts.

Nous avons exposé dans la deuxième partie, une technique d'apprentissage profond, basée sur le traitement d'images par les réseaux de neurone de convolution. La méthode proposée consiste à faire la conversion des signaux vibratoires bruts à des images en niveaux de gris, qui sont ensuite introduites comme une entrée à un modèle CNN conçu. Cette technique exploite le potentiel des CNN dans l'extraction automatique d'indicateurs significatifs à partir des images vibratoires sans la nécessité d'un traitement quelconque.

Le système de diagnostic adopté a d'excellentes performances, qui atteignent un taux de classification de 100%. De plus, lorsque les conditions opérationnelles liées à la charge et la vitesse, sont changées et sans réentraîner notre modèle CNN, le système de diagnostic proposé fonctionne toujours bien en maintenant une haute performance d'identification de défauts (excellent potentiel de transférabilité et de généralisation).

En outre, la méthode proposée est fiable, robuste et elle a la capacité de tenir son bon fonctionnement dans des environnements bruyants et sans aucun processus de débruitage ou de traitement.

Les techniques expérimentées dans ce chapitre, ayant prouvé leurs efficacités et elles vont être réappliquées dans le chapitre suivant, où nous allons examiner une nouvelle méthode basée sur le traitement EEMD et les réseaux de neurones de convolution. Ce nouveau système de diagnostic va être évalué sur le banc d'essai du CRTI pour détecter les défauts de roulements.

D'ailleurs, la technique proposée sera évaluée aussi sur la base de données de CWRU, mais cette fois ci avec un large nombre de défauts de différents diamètres et sévérités.

# Chapitre IV : Application de la méthode EEMD\_CNN pour le diagnostic des défauts de roulements

## IV.1 Introduction

Ce chapitre présente un certain nombre d'expériences qui ont été menées pour valider la performance et l'efficacité de la nouvelle méthode EEMD-CNN pour le diagnostic des défauts de roulements.

Cette évaluation est réalisée en étudiant l'application de la méthode proposée sous deux bases de données vibratoires collectées à partir des bancs d'essai d'URMA/CRTI et de CWRU.

Dans une première phase, des processus de sélection et de reconstruction sont effectués pour reconstruire à nouveau les signaux vibratoires avec moins de bruit grâce à l'application du traitement EEMD aux signaux de vibration bruts (comme expliqué dans le chapitre III).

Puis, une seconde phase repose sur la conversion des nouveaux signaux 1D afin de générer des représentations 2D en niveaux de gris qui sont prises par la suite comme une entrée d'un réseau de neurones de convolution (CNN).

En outre, notre système de diagnostic a été comparé avec une méthode conventionnelle EEMD-MCSVM utilisant des caractéristiques extraites manuellement et a été évalué aussi sous différentes conditions de fonctionnement liées à la charge et à la vitesse.

Enfin, la comparaison entre la méthode développée et les méthodes existantes dans la littérature, a démontré l'efficacité de l'EEMD-CNN qui fait la discrimination entre les classes automatiquement dont elle peut identifier et localiser avec succès les défauts de roulements avec une très grande précision pour une faible quantité de données d'entraînement.

## IV.2 Banc d'essai URMA/CRTI

Afin de vérifier la validité des méthodes proposées, des expériences ont été réalisées sur le banc d'essai fourni par l'Unité de Recherche en Matériaux Avancés (URMA / CRTI).

Les figures IV.1 et IV.2 montrent la plateforme de test utilisée dans ce travail.

La description de ce banc d'essai et l'étape d'acquisition des données de vibration sont présentées ci-dessous :

Ce banc d'essai se compose d'un moteur à induction triphasé doté d'une puissance de 0,37 kW, d'un variateur de vitesse et des roulements sous différents états de santé.

Le roulement testé est soutenu à l'arbre du moteur côté entraînement dont on a utilisé un variateur de vitesse de type « Lenze ESV371N01SXB » pour contrôler la vitesse du moteur à courant alternatif. Les signaux de vibration sont collectés sous les fréquences de rotation

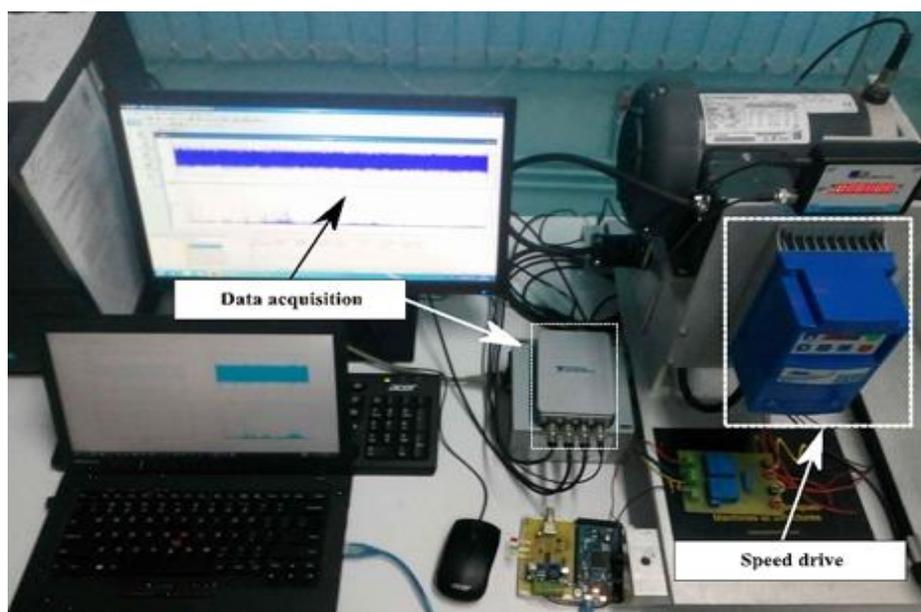
suivantes : 30, 35, 40 et 45 Hz à l'aide de trois accéléromètres industriels ICP (CTC AC 140-2D) avec une sensibilité appliquée égale à 100 mV/g.

Les signaux de vibration qui reflètent l'état réel des roulements sont analysés et stockés à l'aide du logiciel VibraQuest (VQ-DT8) avec une fréquence d'échantillonnage de 25,6 kHz et un temps d'acquisition de 10 secondes pour chaque condition de fonctionnement.

Les spécifications techniques des roulements de type « 3/4 in. ER-12K », sont répertoriées dans le tableau IV.1.



**Figure IV.1** Banc d'essai du CRMA/CRTI.



**Figure IV.2** Étape d'acquisition de données.

**Tableau IV.1** Les spécifications techniques des roulements utilisés.

Bearing Model	Inner race Diameter(mm)	Outer race Diameter(mm)	Roller Diameter(mm)	Contact Angle(degree)
<i>ER12K-0114</i>	<i>29.31</i>	<i>47.00</i>	<i>7.93</i>	<i>0°</i>

Dans notre travail, nous sélectionnons un ensemble de quatre états de santé de roulement qui comprend un état normal (Sain : sans la présence d'un défaut), un défaut de la cage interne (IRF), un défaut de la cage externe (ORF) et un défaut de la bille (BAF).

Les différents défauts sont labellisés afin de nous faciliter l'interprétation des résultats dans les parties ultérieures de cette étude comme le montre le tableau [IV.2](#).

Electrical Discharge Machining (EDM) a introduit les défauts et la figure [IV.3](#) montre les types de roulements défectueux utilisés lors des expérimentations.

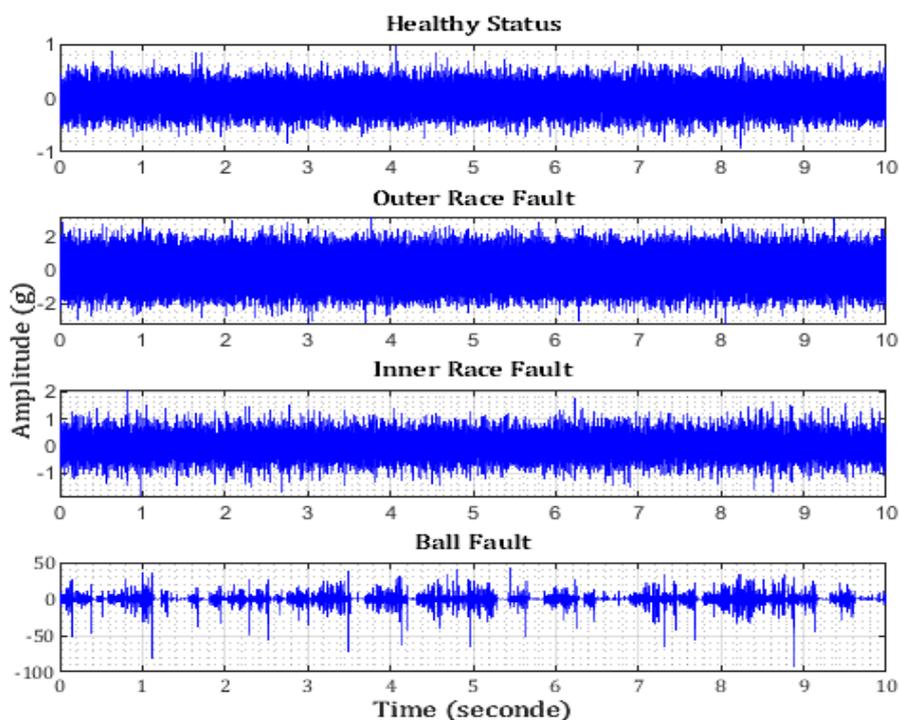
La figure [IV.4](#) montre les signaux vibratoires collectés dans la même condition de vitesse (fréquence de rotation équivalente à 35Hz) où on peut remarquer une augmentation des amplitudes de vibration au niveau des signaux acquis en présence de défauts, et ce de manière plus considérable dans le cas de défaut de la bille (BAF).

**Tableau IV.2** Labellisation des différents états de roulements.

Condition	Indice (etiquette)
Healthy	1
OR Fault	2
IR Fault	3
BA Fault	4



**Figure IV.3** Roulements défectueux utilisés dans notre travail : (a)- Défaut de la cage interne « IRF », (b)- Défaut de la bille « BAF », (c)- Défaut de la cage externe « ORF ».



**Figure IV.4** Signaux vibratoires sous la même condition de vitesse (*fréquence de rotation équivalente à de 35 Hz*).

### IV.3 Diagnostic des défauts de roulements par la méthode proposée

#### IV.3.1 Traitement de données :

Comme mentionné auparavant, les signaux vibratoires sont enregistrés dans une durée de 10 secondes et avec une fréquence d'échantillonnage équivalente à 25.6 kHz. Cela signifie que chaque signal avait au total 256000 points.

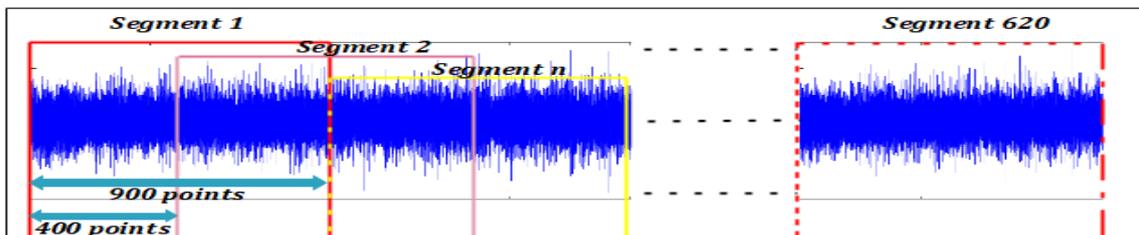
Les classifieurs doivent avoir suffisamment d'échantillons pour que la phase d'apprentissage et de test soit correcte. Afin de satisfaire cette condition, les données de vibration sont divisées en segments imbriqués de la même longueur avec un pas de 400 points, comme clarifié dans la figure IV.5.

620 échantillons contenant 900 points chacun, sont sélectionnés pour chaque état de santé. Pour chaque état de santé 620 échantillons sont générés d'où on aura pour les quatre états de roulements 2480 segments pour chaque vitesse du moteur.

Nous avons construit quatre jeux de données A, B, C et D suivant l'ordre respectif des fréquences de rotations du moteur 30, 35, 40 et 45 Hz, comme illustré dans le tableau IV.3.

**Tableau IV.3** Distribution des ensembles de données.

Nom d'ensemble des données	Types de défauts	Nombre des segments	Fréquence de rotation (Hz)
A	Sain, ORF, IRF, BAF	2480	30
B	Sain, ORF, IRF, BAF	2480	35
C	Sain, ORF, IRF, BAF	2480	40
D	Sain, ORF, IRF, BAF	2480	45

**Figure IV.5** Segmentation imbriquée des signaux de vibration.

La longueur de segment n'était pas choisie au hasard. Cette dernière repose 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 ( $30^2 = 900 \text{ points}$ ). De plus, Le choix d'une segmentation imbriquée a comme objectif de ne pas perdre l'information qui se focalise entre les segments.

#### IV.3.2 La reconstruction des signaux vibratoires à base de d'EEMD

La technique EEMD est appliquée aux signaux de vibration qui peuvent être décomposés en plus de 10 IMFs. La figure IV.6 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 : IMF d'une oscillation rapide (haute fréquence) à une oscillation lente (basse fréquence). ainsi, les amplitudes de vibration des fonctions oscillantes sont aussi générées dans un ordre décroissant, ce qui traduit la diminution rapide de l'énergie.

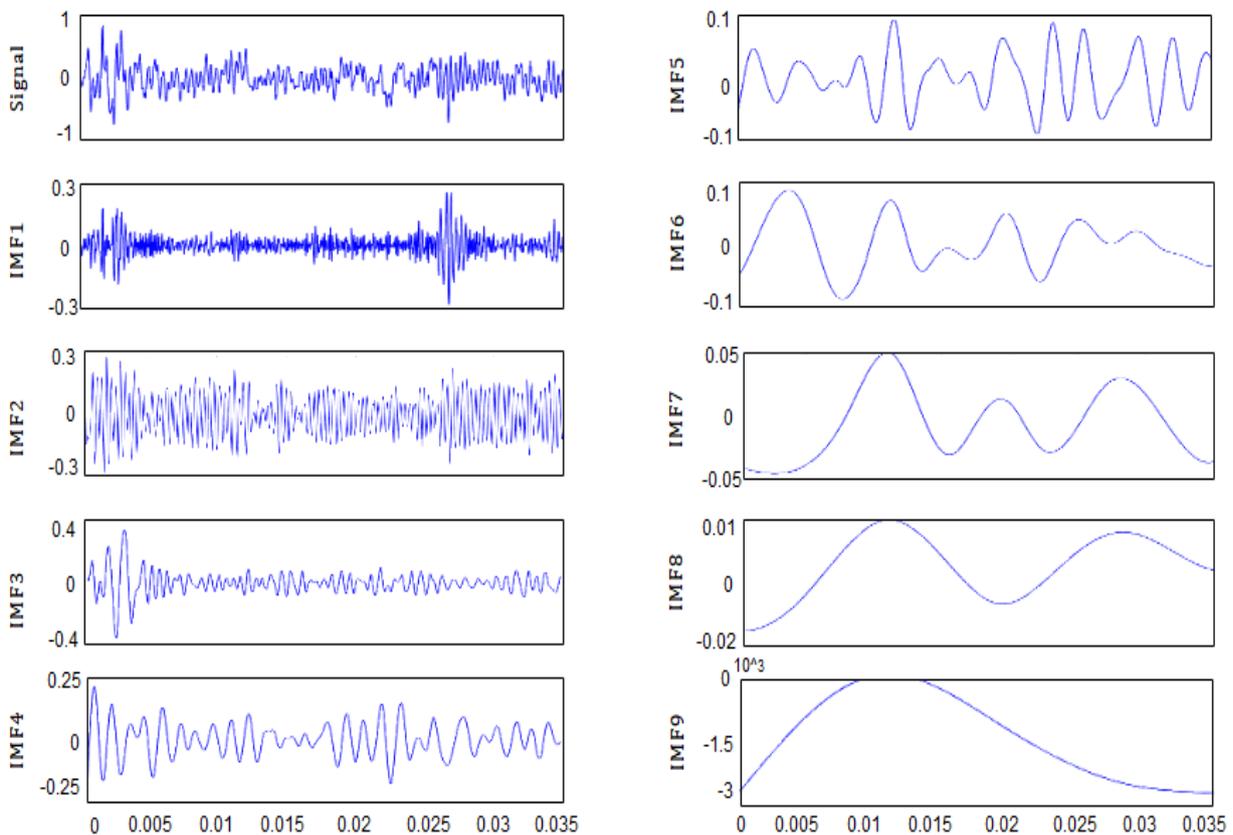
Après le processus d'extraction d'IMFs, nous avons sélectionné les fonctions intrinsèques qui contiennent les signatures de défaut par le calcul du coefficient de corrélation entre chaque

signal et son  $n$  IMF avec une procédure similaire à celle appliquée dans la section III.3.4 du chapitre III [170].

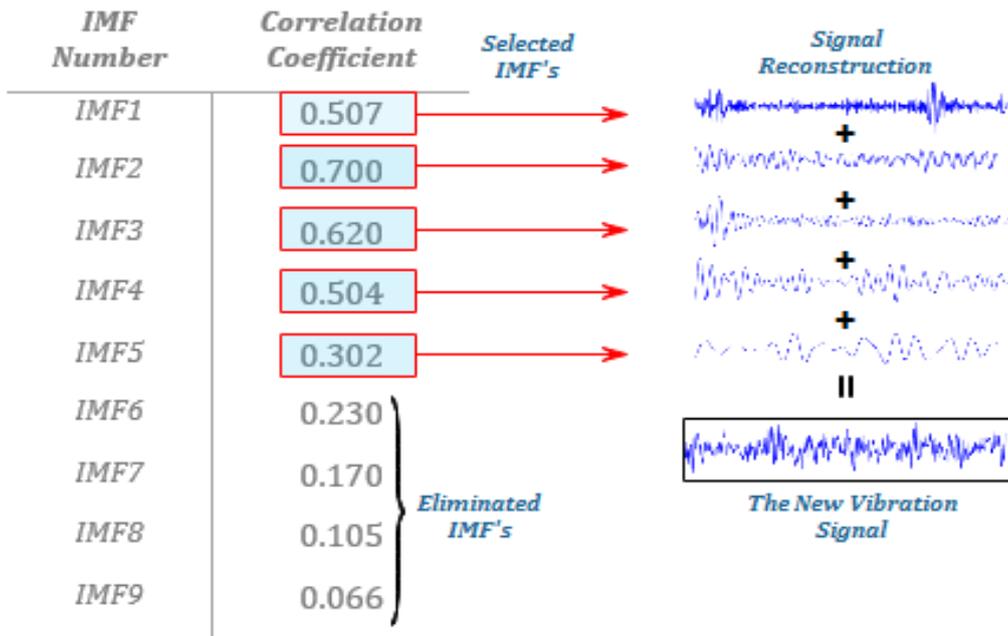
Les IMFs choisies sont utilisées par la suite pour reconstruire le nouveau signal de vibration avec une simple opération d'addition. Le critère de sélection est basé sur la valeur du coefficient de corrélation entre chaque segment et son  $n$  IMF correspondante et qui doit être supérieure ou égale à 0,25.

Le principal avantage de la solution proposée est d'éliminer l'impact du bruit sur les signaux de vibration d'origine de manière que toutes les informations représentatives décrivant l'état de santé réel du roulement soient conservées. La figure IV.7 montre un exemple de débruitage d'un signal de vibration par la procédure proposée.

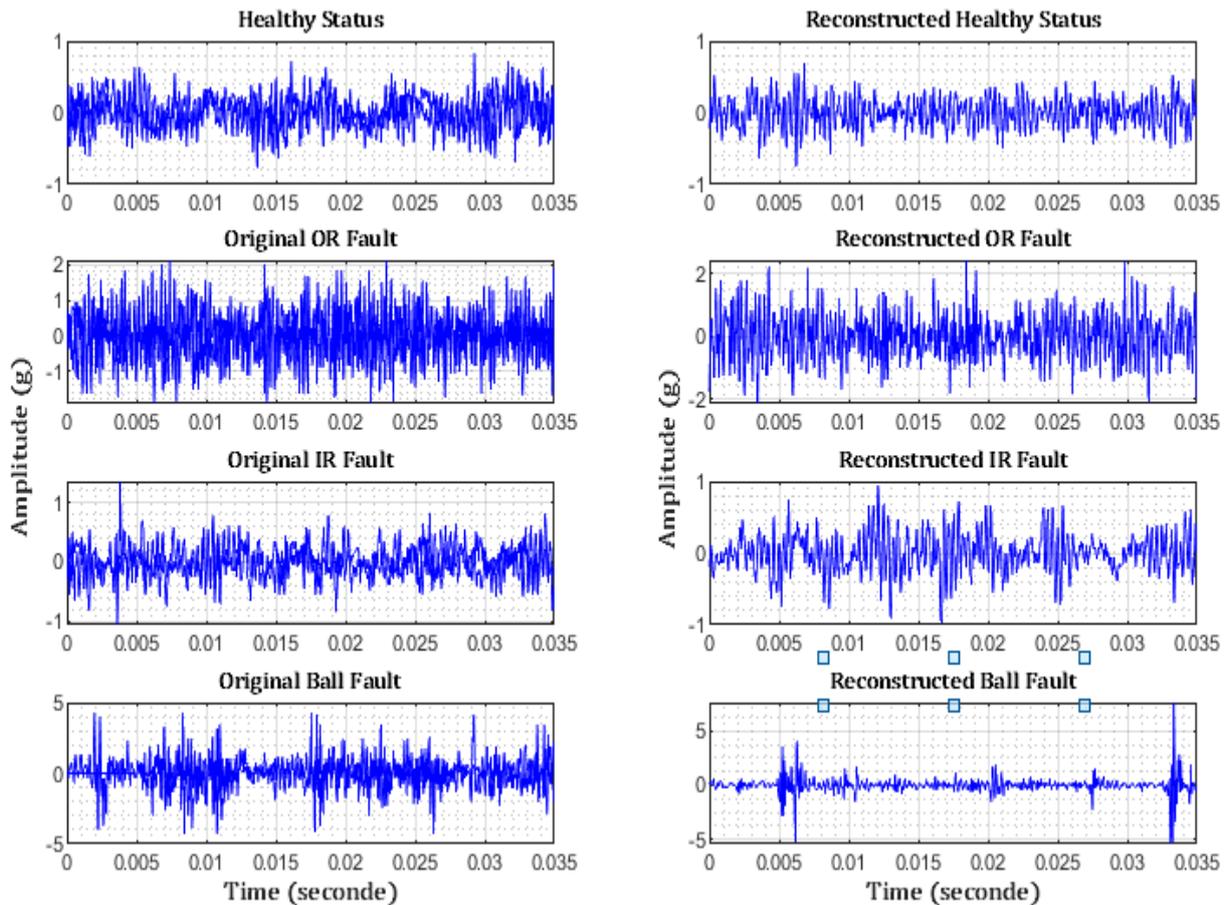
La figure IV.8 expose les signaux d'origine accompagnés avec les signaux reconstruits, en définissant quatre états de santé de roulements sous la même vitesse (fréquence de rotation équivalente à 30 Hz), où on peut visualiser une similarité importante entre les signaux bruts et les signaux reconstruits de manière que toutes les impulsions et les amplitudes de vibration sont conservés.



**Figure IV.6** Signal de vibration et ses 9 premiers IMFs sous défaut de cage interne à une vitesse de 30Hz.



**Figure IV.7** Exemple décrivant la procédure de sélection d'IMFs et de reconstruction des signaux vibratoires après le traitement EEMD.



**Figure IV.8** Signaux de vibration originaux contre les signaux reconstruits sous une fréquence de rotation équivalente à 30Hz.

### IV.3.3 Extraction des caractéristiques et classification des défauts

À ce niveau, nous pouvons diviser notre étude ultérieure en deux stratégies. La première méthode de diagnostic est basée sur l'apprentissage statistique conventionnel qui utilise MC-SVM pour la reconnaissance des défauts. En revanche, la seconde méthode utilise un algorithme d'apprentissage profond exploitant la fonction Softmax pour l'identification des défauts. La figure IV.9 présente l'organigramme du système de diagnostic proposé.

#### IV.3.3.1 La première méthode : EEMD-MCSVM

La première méthode consiste à extraire douze paramètres statistiques dans le domaine temporel et fréquentiel à partir des signaux reconstruits. Dans cette étape, le spectre de fréquence est dérivé par l'application de la transformée de Fourier aux signaux reconstruits. Les indicateurs extraits avec leurs formules mathématiques sont affichés et arrangés dans le tableau IV.4.

Les douze indicateurs extraits manuellement sont ensuite utilisés pour la classification des défauts avec le classifieur multi-classes SVM (MCSVM). À ce niveau, les techniques un-contre-un (OAO) et un-contre-tous (OAA) sont utilisées dans le stade de classification des défauts.

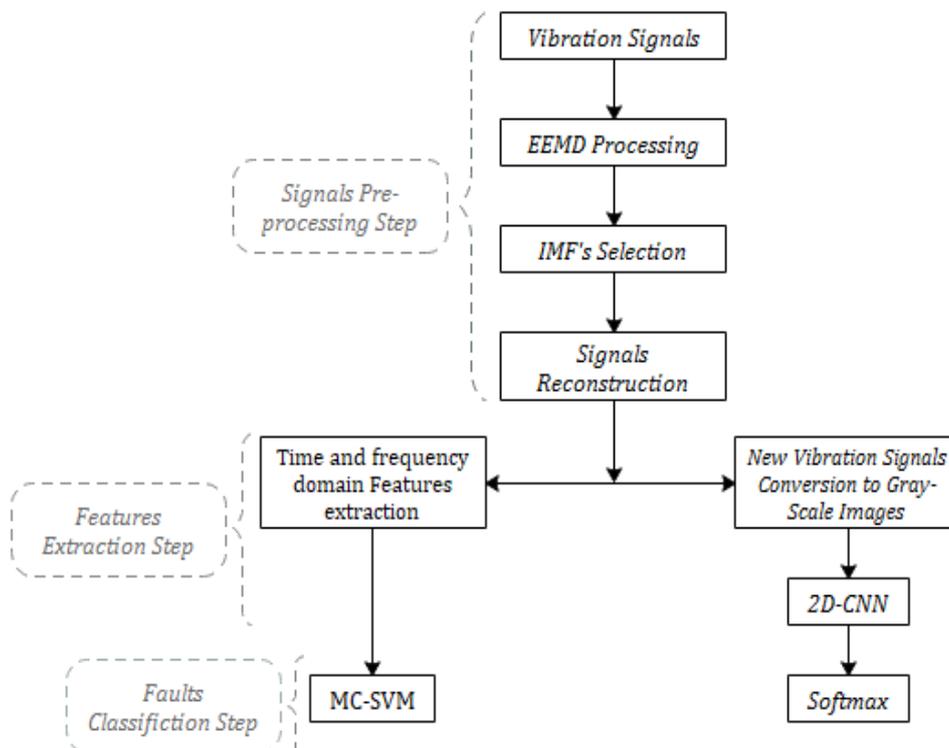


Figure IV.9 Organigramme des méthodes de diagnostic proposées.

**Tableau IV.4** Caractéristiques statistiques extraites dans le domaine temporel et fréquentiel.

Domain	Feature formulas
Time domain	Mean value: $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ Root mean square: $RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
	Skewness: $S = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^3}{\sigma^3}$ Standard deviation: $\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
	Kurtosis: $K = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{\sigma^4}$ Peak-to-peak value : $F_{ppv} = \max(x_i) - \min(x_i)$
	Peak value: $F_{pv} = \max( x_i )$ Crest factor: $F_{cf} = \frac{F_{pv}}{RMS}$
Frequency domain	Mean frequency : $F_{md} = \frac{1}{N} \sum_{i=1}^N x_i$ Variance : $V_i = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$
	Energy: $E_i = \sum_{i=1}^N  x_i ^2$ Shannon entropy: $F_{se} = -K \sum_{i=1}^N p_i \log p_i$

Dans les quatre expériences de classification qui correspondent à quatre conditions de fonctionnement différentes, un total de douze caractéristiques statistiques, comprend huit indicateurs temporels et quatre fréquentiels, sont extraits de chaque signal reconstruit à base du traitement EEMD.

Les paramètres statistiques choisis sont utilisés pour construire un vecteur de caractéristiques qui est ensuite utilisé comme une entrée d'un MCSVM dans l'étape de classification.

Environ 80% des échantillons de l'ensemble de données A (fréquence de rotation= 30 Hz), sont sélectionnés aléatoirement comme données d'apprentissage, tandis que 20% des échantillons sont laissés comme données de test.

Le tableau IV.5 montre les résultats de la classification en utilisant MCSVM avec les techniques OAO et OAA.

**Tableau IV.5** Résultats de la classification utilisant l'EEMD-MCSVM.

MC-SVM technique	Test samples	Correct Number	Accuracy
OAO	480	460	95.83%
OAA	480	464	96.66%

Le tableau **IV.5** montre que les performances du MCSVM avec les techniques OAA sont nettement supérieures à celles des techniques OAO.

Le meilleur taux de classification atteint 96,66% avec 16 échantillons mal classés, tandis que la précision la plus faible atteint 95,83% avec 20 échantillons mal classés dans le cas du classifieur MCSVM utilisant la technique OAO.

On a essayé d'extraire manuellement les caractéristiques les plus utilisées dans le domaine de diagnostic qui sont censées être révélatrices dès l'apparition d'un défaut.

Après la tentative d'extraction de l'informations la plus complète possible en couvrant le domaine temporel et fréquentiel, on doit chercher ou essayer de nouveaux indicateurs statistiques qui peuvent avoir des sensibilités différentes par rapport à la présence des défauts dont la probabilité d'améliorer les performances de la méthode EEMD-MCSVM n'est pas garantie; tels que l'ajout ou l'élimination de certains indicateurs peuvent nuire la classification, ce qui signifie que la dégradation des performances de diagnostic reste susceptible ou probable.

Le classifieur MCSVM a cherché le meilleur hyperplan séparateur à travers lequel il peut faire la séparation entre les classes (les états de roulements) à partir des distributions spatiales des descripteurs extraits.

A ce niveau, la présence d'un ou de plusieurs éléments perturbateurs ou inutiles, peuvent réduire l'aptitude du classifieur à discriminer entre les classes et rendent la tâche de diagnostic plus difficile.

Les scores obtenus ne donnent pas des résultats satisfaisants qui sont incompatibles avec les objectifs de cette étude visant à construire un système de diagnostic puissant et auto-adaptatif avec la capacité d'atteindre un taux de classification supérieure.

Par conséquent, nous sommes amenés et contraints à développer une autre méthode utilisant une des algorithmes d'apprentissage profond, où les différents détails des expériences ultérieurement effectuées, sont décrits dans les sections suivantes.

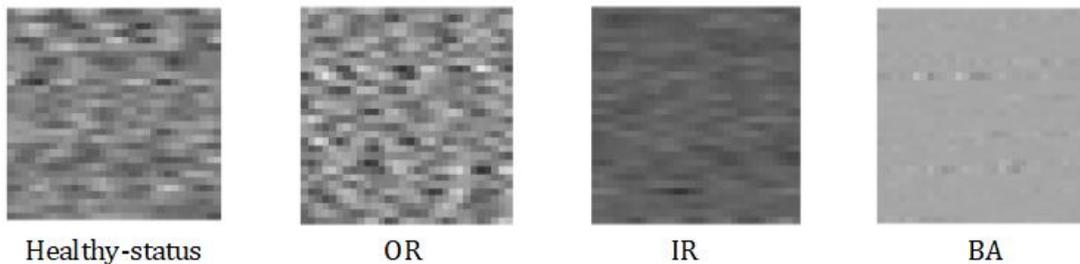
#### **IV.3.3.2 La deuxième méthode : EEMD-2DCNN**

La couche d'entrée du CNN conçue, reçoit un format de données bidimensionnel. Pour transformer les signaux reconstruits listés dans le tableau **IV.3** et qui sont dans un format 1D en images vibratoires 2D, le même processus de conversion, expliqué dans la section **III.4.1** du chapitre **III**, est effectué.

Étant donné que la longueur de chaque échantillon vibratoire est de 900 points, la taille de l'image de vibration en niveaux de gris est sélectionnée à  $M = 30$ ,  $N = 30$  ( $M \times N = 30 \times 30 = 900$  pixels). La figure IV.10 montre les images vibratoires générées sous une fréquence de rotation de 30 Hz. De cette façon, nous avons obtenu un ensemble d'images vibratoires contenant 2480 images en niveaux de gris avec une taille  $30 \times 30$  pixels dans chaque condition de fonctionnement. Le tableau IV.6 décrit la disposition des ensembles de données des images vibratoires construites.

**Tableau IV.6** Distribution des ensembles d'images vibratoires.

Ensemble de données	Nombre d'images	Fréquence de rotation (Hz)
A	2480	30
B	2480	35
C	2480	40
D	2480	45



**Figure IV.10** Images vibratoires construites relatives à l'ensemble de données A (fréquence de rotation équivalente à 30 Hz).

Dans le processus de construction du modèle 2D-CNN, la sélection des hyperparamètres 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 hyperparamètres 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.

Afin d'étudier l'influence des fonctions d'activation sur les performances du modèle CNN, une architecture CNN est développée après plusieurs essais répétés et qu'on va la considérer comme un modèle de référence à travers lequel on poursuivra notre évaluation.

L'apprentissage se fait par l'algorithme de rétro-propagation et pour mieux entraîner notre modèle CNN, nous avons utilisé un optimiseur de type « Adam » avec un coefficient d'apprentissage adaptatif (variant de 0.01 à 0.001) et en utilisant ainsi la « cross-entropy » comme une fonction de perte.

Le modèle CNN de référence se compose de deux couches de convolution (CL), deux couches de pooling (SL), deux couches entièrement connectées (FL) et doté à la sortie d'un classifieur Softmax.

Dans l'étape de sélection de la taille de 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 30 filtres avec une taille de noyau de 7x7, et elle est suivie par une couche de sous-échantillonnage de type Max-Pooling de taille 2x2.

La prochaine CL se compose de 60 filtres avec une taille de noyau de 4x4, et est suivi d'une SL de type Max-Pooling de taille 2x2.

Dans la première FL, le nombre de neurones est fixé à 128, tandis que le nombre de neurones dans la seconde FL est 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 IV.7 présente une description détaillée concernant les hyperparamètres du modèle de référence adopté.

Comme mentionné dans le deuxième chapitre, les fonctions *Sigmoid*, *Relu* et *Tanh* sont les fonctions d'activation couramment utilisées dans les réseaux CNN. Dans le cadre de notre étude, le processus de sélection de la fonction d'activation adéquate est basé sur les résultats expérimentaux liés aux cas pratiques.

Les images vibratoires construites appartenant à l'ensemble de données « A » du tableau IV.6 sont utilisées pour entraîner le CNN de référence sous les configurations définies par le tableau IV.7.

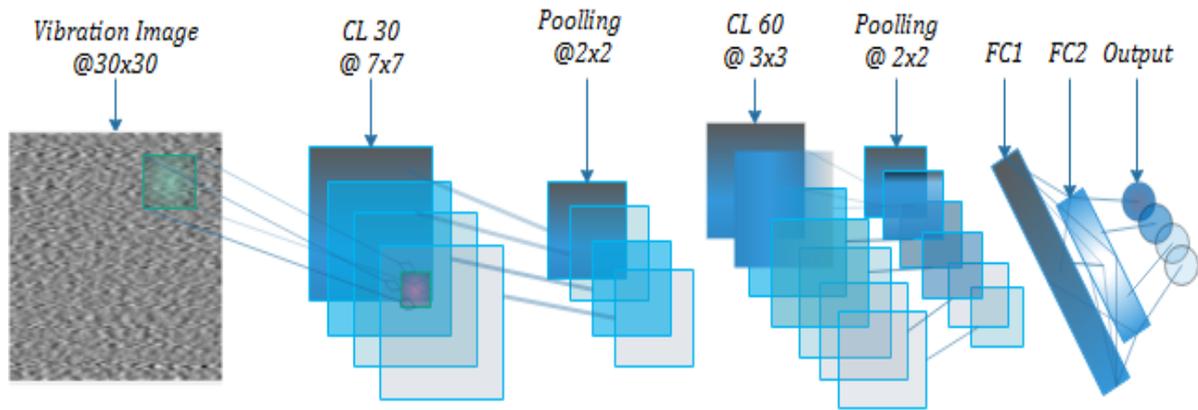
**Tableau IV.7** Description des hyper-paramètres du modèle CNN de référence.

Layer Number	Type	Layer specification	Size Out
Layer 01	'Input'	Input Size=30x30	30x30
Layer 02	'CL'	Filter Num = 30, Stride=1, Pad=0 kernel size = 7x7 <b>Activation function</b>	24x24
Layer 03	'SL'	Size 2x2	12x12
Layer 04	'CL'	Filter Num = 60, Stride=1, Pad=0 Kernel Size =4x4 <b>Activation function</b>	10x10
Layer 05	'SL'	Size 2x2	5x5
Layer 06	'Fc'	128 hidden layer neuron nodes Dropout=0.8 <b>Activation function</b>	1x128
Layer 07	'Fc'	4 hidden layer neuron nodes	1x4
Layer 08	'Softmax'	\	1x4
Layer 09	'OutPut'	LossFunc=@CrossEnt	1x4

Premièrement, le modèle CNN initial est entraîné par 2000 images vibratoires et testé ensuite par 480 images vibratoires. Après chaque opération apprentissage/test, le type de fonction d'activation sera modifié dans la couche entièrement connectée, et dans les deux couches de convolution qui utilisent la même fonction d'activation. Ensuite, on continue à effectuer cette opération jusqu'à ce que toutes les probabilités disponibles soient réalisées.

Enfin, les taux de classification obtenus à partir des différentes fonctions d'activation utilisées, seront comparés en couvrant neuf expériences. Les résultats expérimentaux sont notés dans le tableau **IV.8**.

Ce test vise à étudier l'apport des différentes fonctions d'activation dans notre modèle CNN et d'évaluer leurs contributions afin de sélectionner les fonctions adéquates à travers lesquelles les performances du réseau seront boostées.



**Figure IV.11** Architecture du réseau CNN proposé.

**Tableau IV.8** Résultats de classification du modèle CNN sous différentes fonctions d'activation utilisées.

Experiment	CL 1	CL 2	FL	Accuracy
1	Sigmoid	Sigmoid	Sigmoid	99.20 %
2	Relu	Relu	Relu	99.00 %
3	Tanh	Tanh	Tanh	99.16 %
4	Sigmoid	Sigmoid	Relu	99.00 %
5	Sigmoid	Sigmoid	Tanh	99.40 %
6	Relu	Relu	Sigmoid	98.25 %
<b>7</b>	<b>Relu</b>	<b>Relu</b>	<b>Tanh</b>	<b>99.60 %</b>
8	Tanh	Tanh	Sigmoid	99.40 %
9	Tanh	Tanh	Relu	98.75 %

A partir des résultats obtenus dans les neuf expériences effectuées, nous pouvons voir que la configuration selon l'expérience 7, permet à identifier correctement 99,60% des images vibratoires de test. Par contre, le résultat le plus faible a été trouvé dans l'expérience 6, où le taux de classification est estimé à 98,23%. Par conséquent, nous adoptons dans les expériences à venir la configuration CNN selon l'expérience 7 qui utilise la fonction d'activation de type « Relu » dans les couches de convolution et exploite la fonction d'activation de type « Tanh » dans la couche entièrement connectée. Ces fonctions sélectionnées ont permis un traitement convenable de l'information de manière que le réseau

CNN ne perd pas l'information utile par rapport aux autres expériences et extrait les indicateurs significatifs qui l'ont aidé à avoir la meilleure efficacité dans le processus du diagnostic. Ce qui explique que ces fonctions d'activation ont permis d'aboutir à des caractéristiques plus discriminantes ou optimales, ce qui a eu un impact positif sur la performance de la classification. De plus, L'utilisation de la fonction « Relu » dans les CL nous a permis aussi à avoir un apprentissage plus rapide par rapport aux fonctions « sigmoid » et « Tanh ».

#### IV.3.3.3 Évaluation de performance sous la même condition de vitesse

En conservant le même processus de partitionnement des ensembles de données apprentissage/test, les deux méthodes proposées : MCSVM et CNN-Softmax basées sur le traitement EEMD, sont appliquées pour évaluer l'efficacité de notre système de diagnostic sous différentes fréquences de rotation incluant les fréquences respectives 35, 40 et 45 Hz liées aux données correspondantes B, C et D. Les différents résultats de classification sont résumés dans le tableau IV.9.

**Tableau IV.9** Résultats obtenus dans la phase de test des classifieurs MCSVM et Softmax dans quatre conditions de fonctionnement.

Experiment	Rotation frequency	MCSVM		Softmax
		OAo technique	OAA technique	
1	30 Hz	95.83%	96.66%	99.60%
2	35 Hz	97.08%	97.50%	100%
3	40 Hz	96.25%	97.29%	99.80%
4	45 Hz	97.61%	98.12%	100%

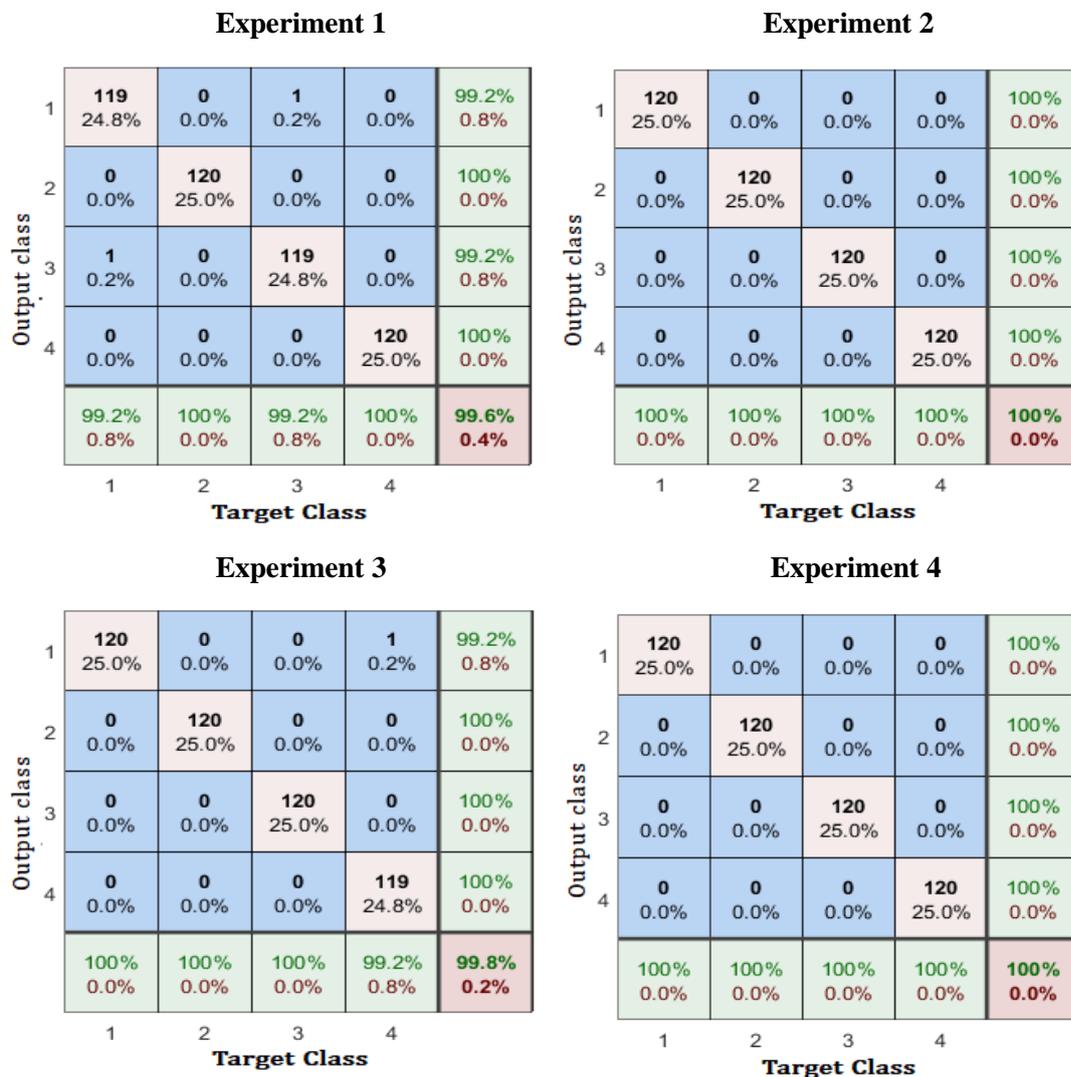
En comparant les résultats répertoriés dans le tableau IV.9, nous constatons que la technique OAA utilisée par MCSVM a de meilleures performances par rapport au MCSVM utilisant la technique OAo dans les quatre cas étudiés.

Le taux de classification le plus faible lié à la technique OAo, est observé dans l'expérience 1 (95.83%), tandis que la meilleure précision de la technique OAA est notée dans l'expérience 4 ; elle peut atteindre 98,12%. Par contre, le modèle CNN-Softmax dépasse les performances de MCSVM utilisant les techniques OAA dans tous les cas où le taux d'identification de

défauts le plus faible du modèle CNN-Softmax, est observé dans l'expérience 1, soit 1.48 points de plus que le taux de classification le plus élevé de la technique OAA.

En outre, le modèle CNN-Softmax a des performances supérieures, notamment dans les expériences 2 et 4 dans lesquelles le taux de classification atteint 100% avec un taux d'erreur nul.

Afin d'avoir une analyse quantitative détaillée liée aux résultats du diagnostic utilisant l'algorithme EEMD-CNN proposé, quatre matrices de confusion selon 4 expériences réalisées, sont introduites pour enregistrer les résultats d'identification de l'état des roulements et le nombre de mauvaises classifications de défauts. La figure IV.12 montre les matrices de confusion basées sur les résultats de test du modèle CNN-Softmax correspondant aux 4 expériences effectuées.



**Figure IV.12** Matrices de confusion détaillant les résultats de test obtenus par la méthode EEMD-CNN.

L'interprétation des résultats contenus dans les matrices de confusion exposées dans la figure IV.12, est la suivante :

Dans l'expérience 1, deux par 480 échantillons liée à l'ensemble de test sont mal classés par la technique CNN-Softmax. Les étiquettes correctes des échantillons mal classés sont à la fois les classes 1 et 3 correspondantes respectivement à l'état sain et au défaut de la cage interne (IRF).

Par contre, les catégories identifiées par notre CNN-Softmax, sont à la fois les classes 3 et 1 correspondantes respectivement aux défauts de la cage interne et à l'état sain. Parallèlement, le taux d'identification des autres états de roulements est équivalent à 100%.

Dans les deux expériences 2 et 4, notre modèle CNN-Softmax a réussi à faire la discrimination entre tous les classes notant que la précision du diagnostic est estimée à 100%.

Dans l'expérience 3, le modèle CNN-Softmax a mal classé qu'une seule image vibratoire parmi les 480 échantillons de test. L'étiquette réelle de l'échantillon mal classé est la classe 1 correspondante à l'état sain, tandis que la classe identifiée par notre méthode est la classe 4 correspondante au défaut de la bille (BAF). Au même temps, la précision de classification des autres classes est égale à 100%.

Les résultats expérimentaux montrent que la méthode EEMD-CNN proposée est plus performante que la méthode EEMD-MCSVM dont elle a réussi de maintenir un taux de classification élevé pour le diagnostic des défauts de roulements sous la même condition de vitesse.

Le principal avantage du CNN est son potentiel d'auto-apprentissage à partir des signaux reconstruits et sans aucune connaissance a priori. Cet outil apprend plusieurs niveaux de représentations de données qui correspondent à une hiérarchie d'indicateurs de défauts, allant à partir des données d'entrée (les images vibratoires de l'entrée) vers une représentation plus significative et de haut niveau.

Cela nous a confirmé la supériorité de l'approche DL par rapport aux méthodes ML classiques qu'elles dépendent explicitement de la qualité des descripteurs extraits manuellement. Par conséquent, nous conservons la meilleure méthode pour le reste des expériences.

#### IV.3.3.4 Évaluation de performance sous des conditions de vitesses variables

Un autre défi visant à explorer l'efficacité de la méthode proposée dans différentes conditions opérationnelles par rapport aux applications réelles des systèmes de surveillance où les machines ainsi que leurs roulements doivent fonctionner sous diverses conditions et situations.

Afin d'évaluer la méthode EEMD-CNN proposée sous des vitesses variables, nous avons entraîné notre modèle CNN par la totalité des deux ensembles de données B et D correspondants respectivement aux fréquences de rotation 35 Hz et 45 Hz. Ensuite, les ensembles de données A et C correspondants respectivement aux fréquences de rotation 30 Hz et 40 Hz, sont pris comme données de test. Les taux moyens d'apprentissage et de classification obtenus sont 100% et 98,24%, comme montré dans la figure IV.13.

Cette évaluation avait l'objectif de voir si notre système de diagnostic est capable d'identifier les différents états de roulements, en le testant par des données inconnues qu'on n'a pas utilisé lors de la phase d'apprentissage.

La performance de classification avait une légère dégradation avec un taux d'erreur équivalent à -1.76%, ce qui prouve que le CNN a d'excellente capacité d'extraction d'indicateurs pertinents liés à l'apparition de défauts à partir de l'ensemble de données d'entraînement et a pu généraliser les caractéristiques apprises sur de nouvelles données tirées des autres fréquences de rotation.

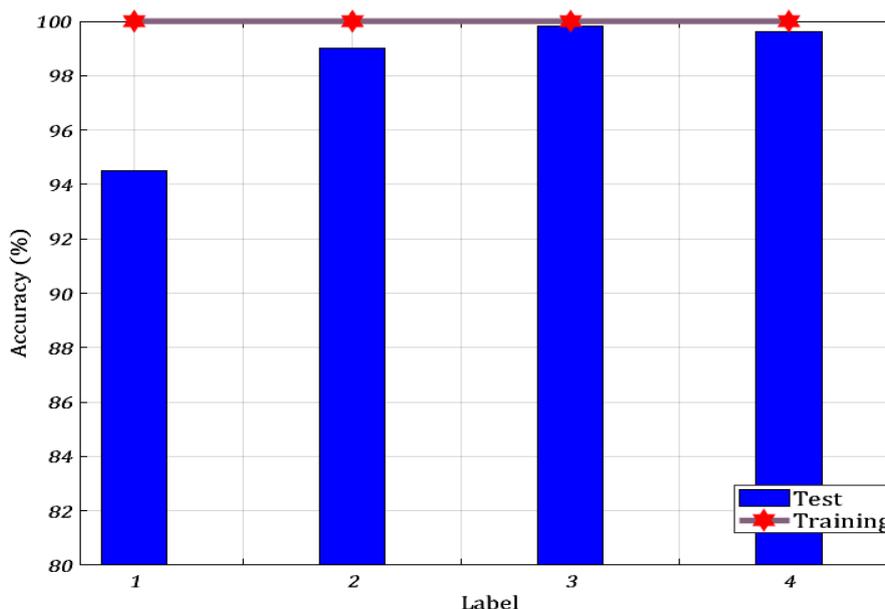


Figure IV.13 Performances d'apprentissage et de classification sous vitesses variables.

#### IV.3.3.5 Évaluation sous différentes quantités de données Apprentissage/Test

Dans cette section, nous évaluons notre méthode EEMD-CNN proposée sous différentes quantités de données Apprentissage/Test. Il a été indiqué dans les sections ci-dessus que 80% de chaque ensemble de données a été pris comme données d'apprentissage alors que le reste (20%) est utilisé comme donnée de test. Les meilleures performances sont obtenues dans les deux expériences 2 et 4 atteignant 100% comme taux de classification.

En prenant les mêmes données utilisées dans l'expérience 4 du tableau IV.9, le modèle CNN sera entraîné par 65% des images vibratoires tandis que le reste est laissé comme donnée de test (35% pour le test). Après chaque processus apprentissage/test, on réentraîne à nouveau notre modèle CNN par un pourcentage décroissant d'images dans la phase d'apprentissage et on le valide ensuite par un pourcentage croissant d'images vibratoires de test provenant du même ensemble de données. Le tableau IV.10 décrit les quatre expériences effectuées et résume les différents résultats obtenus à chaque expérience. La figure IV.14 Expose les matrices de confusion correspondantes aux deux dernières expériences 3 et 4, respectivement.

**Tableau IV.10** Résultats de classification de notre technique EEMD-CNN sous des quantités variables d'images vibratoires dans le processus apprentissage/test.

Experiment	Training data	Testing data	Accuracy
1	65%	35%	99.90%
2	50%	50%	99.70%
3	35%	65%	99.60%
4	20%	80%	99.40%

A partir du tableau IV.10 et la figure IV.14, nous pouvons voir que la méthode EEMD-CNN proposée maintient une performance significative sous différentes quantités de données utilisés dans le processus Apprentissage/Test. Pour une quantité décroissante de données d'apprentissage et une quantité croissante de données de test, les performances de notre méthode sont passées de 99,80% (expérience 1) à 99,40% par rapport à l'expérience 4 (une légère dégradation de - 0.40%) où seulement 20% des images vibratoires ont été utilisées comme données d'apprentissage.

Experiment 03					Experiment 04						
Output class	1	403 25.0%	0 0.0%	0 0.0%	5 0.3%	98.8% 1.2%	496 25.0%	0 0.0%	0 0.0%	8 0.4%	98.4% 1.6%
	2	0 0.0%	403 25.0%	0 0.0%	0 0.0%	100% 0.0%	0 0.0%	494 24.9%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	403 25.0%	1 0.1%	99.8% 0.2%	0 0.0%	0 0.0%	496 25.0%	2 0.1%	99.6% 0.4%
	4	0 0.0%	0 0.0%	0 0.0%	397 24.6%	100% 0.0%	0 0.0%	2 0.1%	0 0.0%	486 24.5%	99.6% 0.4%
		100% 0.0%	100% 0.0%	100% 0.0%	98.5% 1.5%	99.6% 0.4%	100% 0.0%	99.6% 0.4%	100% 0.0%	98.0% 2.0%	99.4% 0.6%
	Target Class				Target Class						

**Figure IV.14** Matrices de confusion relatives aux deux derniers cas étudiés.

A partir de la matrice de confusion représentée dans la figure IV.14 correspondantes à l'expérience 4, 12 images de vibration d'un total de 1984, sont mal classées par la méthode proposée dans laquelle le modèle CNN a été entraîné seulement par 496 images de vibration. En conséquent, la méthode EEMD-CNN fonctionne toujours bien sous de faible quantité de données d'apprentissage, ce qui confirme la haute performance de la méthode proposée.

#### IV.3.4 Validation de la méthode proposée sur la base de données de CWRU

Dans cette section, nous inspectons l'efficacité du système de diagnostic proposé sur un ensemble de données de défauts tiré d'une source de données ouverte fourni par l'université de Case Western Reserve (CWRU) [172]. Ce choix de motivation tient au fait que cette base de données est accessible à la communauté des chercheurs, ce qui permet une comparaison équitable entre les performances des méthodes de recherche proposées dans le domaine du diagnostic de défauts.

Le banc d'essai de CWRU a été décrit précédemment dans le chapitre III, dans lequel on a diagnostiqué 3 types de défaut caractérisés par un diamètre équivalent à 0.007 *inch*. Cette fois ci, on s'intéresse à étudier un large nombre de classes exprimant plusieurs types de défauts à différents diamètres et sévérités.

A l'exception de l'état sain de roulement, chaque défaut a trois diamètres différents à savoir 0,007, 0,014 et 0,021 pouces. Les signaux vibratoires sont collectés à différentes conditions de charge et de vitesse (0, 1, 2 et 3 Hp correspondantes aux vitesses 1797, 1772, 1750 et 1730 tr/min).

Douze classes sont sélectionnées à partir de cette base de données, où chaque classe définit un état de santé de roulement utilisé lors des expérimentations, comme décrit par le tableau **IV.11**.

Nous construisons trois jeux de données dont chacun comprend différentes classes définissant plusieurs états de santé des roulements. Les données vibratoires sont arrangées comme suit :

L'ensemble de données « A » comprend 4 classes couvrant les quatre premiers états de santé des roulements du tableau **IV.11** (c'est les mêmes classes étudiées auparavant dans le chapitre **III**). Les ensembles de données « B » et « C » couvrent respectivement les huit premiers et la totalité des états de santé de roulements listés dans le même tableau **IV.11** afin de former des ensembles de données de 8 et 12 classes. Chaque jeu de données A, B et C comprend différentes conditions de fonctionnement du moteur liées à la charge et à la vitesse.

Nous appliquons la même stratégie de diagnostic proposée auparavant aux données de roulement de CWRU à travers laquelle les signaux de vibration sont segmentés et décomposés en une série de fonctions oscillantes par l'EEMD. Puis, le même processus de sélection d'IMFs est réalisé afin de reconstruire les signaux vibratoires qui sont ensuite transformés en images en niveaux de gris. Les signaux vibratoires reconstruits sous la charge 2 hp sont montrés dans la figure **IV.15** et les ensembles d'images vibratoires transformées dans différentes conditions de charge, sont arrangées dans le Tableau **IV.12**.

**Tableau IV.11** Défauts de roulements étudiés.

Fault position (Load position)	Fault diameter ( <i>inch</i> )	Label
Healthy status	/	1
outer race (Centered at 6:00)	0.007	2
Inner race	0.007	3
Ball	0.007	4
outer race (Orthogonal at 3:00)	0.007	5
outer race (Opposite at 12:00)	0.007	6
outer race (Centered at 6:00)	0.014	7
Inner race	0.014	8
Ball	0.014	9
Outer race (Centered at 6:00)	0.021	10
Inner race	0.021	11
Ball	0.021	12

Après, nous adoptons la même architecture et configuration du modèle CNN utilisé dans les sections ci-dessus, sauf que le nombre de neurones dans la couche 7 du tableau IV.7 est ajusté pour être égal au nombre de classes dans chaque expérience.

Enfin, nous effectuons trois expériences dans lesquelles le CNN adopté est appliqué pour extraire automatiquement les caractéristiques significatives et classer les différents défauts de roulements par la fonction Softmax.

**Tableau IV.12** Arrangement des ensembles d'images vibratoires de CWRU après les processus de reconstruction de signaux et de conversion 1D à 2D.

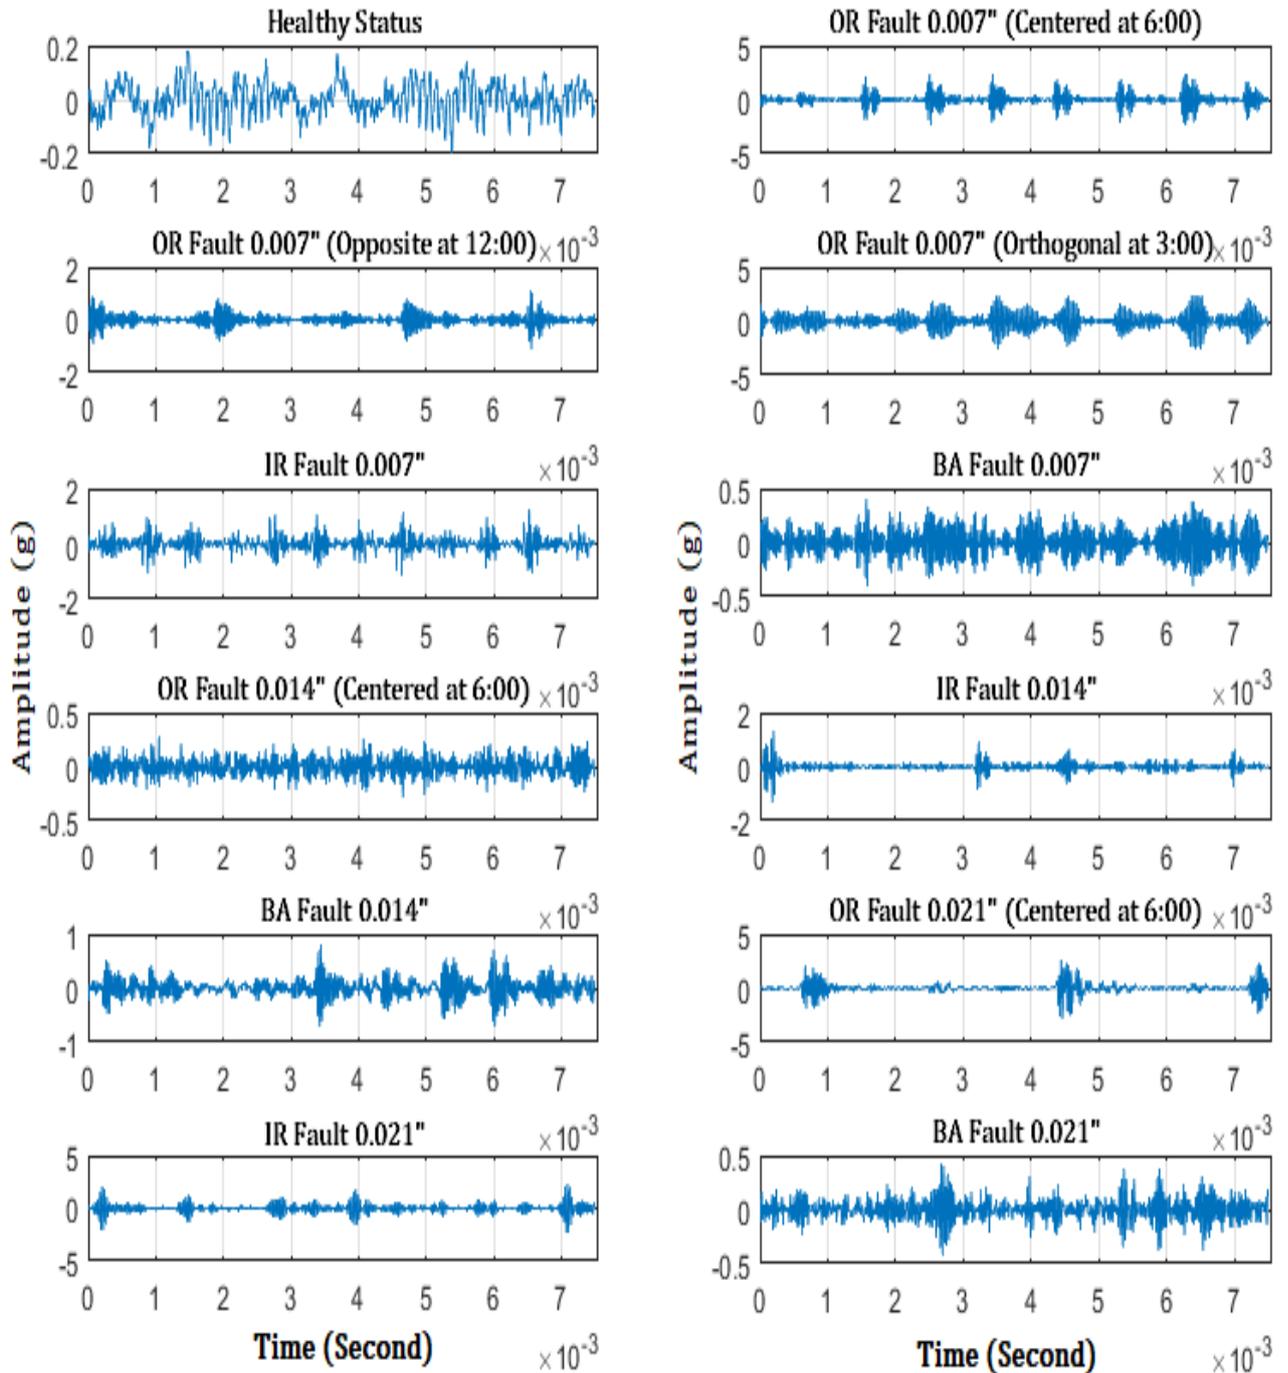
Dataset Name	Number of classes	Load ( <i>hp</i> )	Number of images
A	4	0, 1, 2, 3	3200
B	8		6400
C	12		9600

Dans chaque expérience, seulement 20% des images vibratoires sont sélectionnées aléatoirement pour entraîner notre modèle CNN, tandis que le reste (80%) sont laissés comme données de test.

Les différents résultats obtenus sont résumés dans le tableau IV.13 et la figure IV.16 montre la matrice de confusion générée dans la troisième expérience.

**Tableau IV.13** Résultats de classification obtenus par l'application de la méthode de diagnostic proposée EEMD-CNN.

Experiment	Dataset name	Training images	Testing Images	Accuracy (%)
1	A	640	2560	100 %
2	B	1280	5120	99.98 %
3	C	1920	7680	99.87 %



**Figure IV.15** Tous les signaux reconstruits sous une charge de 2 hp.

Output class	1	640 8.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	640 8.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	640 8.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	640 8.3%	0 0.0%	0 0.0%	3 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.5% 0.5%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	640 8.3%	0 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.7% 0.3%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	640 8.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	630 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	640 8.3%	0 0.0%	0 0.0%	0 0.0%	99.8% 0.2%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	640 8.3%	0 0.0%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	640 8.3%	0 0.0%	100% 0.0%
	11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	640 8.3%	100% 0.0%
	12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	640 8.3%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	98.4% 1.6%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.9% 0.1%
	1	2	3	4	5	6	7	8	9	10	11	12	
	<b>Target Class</b>												

**Figure IV.16** Matrice de confusion dans différentes conditions de charge pour 20% d'images vibratoires utilisées dans la phase d'apprentissage.

Les taux de classification pour les trois expériences réalisées, sont : 100%, 99,98% et 99,87% correspondants respectivement aux ensembles de données A, B et C.

Ces performances démontrent l'excellent potentiel de la méthode de diagnostic proposée dans l'identification de différents états de roulement sous différentes conditions de charge et de vitesse pour seulement 20% des échantillons utilisés en apprentissage.

La capacité de l'EEMD-CNN à détecter et localiser les défauts de roulement avec une performance élevée sous de petite quantité de données utilisées lors de la phase d'apprentissage, conduit à réduire le risque de sur-apprentissage et diminue considérablement le temps d'entraînement.

A partir de la figure IV.15, on peut noter que la méthode proposée peut identifier l'état de santé des roulements avec une efficacité significative, où seulement 10 par 9600 échantillons de test sont mal classés.

En outre, l'EEMD-CNN a réussi d'identifier l'état sain (étiquette 1) avec un taux d'erreur nul, ce qui prouve l'excellent potentiel de notre méthode à distinguer un roulement sain des roulements défectueux.

Les résultats du système de diagnostic EEMD-CNN proposé correspondant aux différentes classes étudiées sont comparés à des travaux utilisant la même base de données de référence « CWRU », comme le montre le tableau IV.14. Les résultats obtenus démontrent la supériorité de la méthode EEMD-CNN proposée, qui surpasse les autres méthodes de diagnostic existantes.

**Tableau IV.14** Résultats de comparaison des performances de classification des techniques de diagnostic existantes dans la littérature utilisant les données vibratoires de CWRU.

Method	Description	Number of classes	Training samples	Testing accuracy
1	<b>La méthode proposée (EEMD-CNN)</b>	<b>4, 8, 12</b>	<b>20 %</b>	<b>100%-99.98%-99.87%</b>
2	STFT-CNN [174]	4	70 %	99.50 %
3	MWT-CNN [174]	4	70 %	99.50 %
4	HHT-CNN [174]	4	70 %	97.60 %
5	LiftingNet [175]	4	50 %	99,63 %
6	One-Shot, Five-Shots [176]	10	96 %	99.79%-99.77%
7	AOCNN-SF-LOG [177]	10	20 %	99.64 %
8	DWAE-ELM [178]	12	66 %	95.20 %
9	DRNN [179]	12	60 %	96.53 %

## IV.4 Conclusion

Dans ce chapitre, nous avons proposé une nouvelle méthode basée sur le traitement EEMD exploitant à la fois les algorithmes MCSVM et CNN pour le diagnostic des défauts de roulements.

Ce système de diagnostic nécessite la capacité d'EEMD à décomposer les signaux vibratoires afin d'extraire avec précision les IMFs les plus pertinentes qui seront utilisées par la suite pour reconstruire les signaux de vibration avec moins de bruit.

Les résultats obtenus lors de cette étude confirment la supériorité de la méthode d'apprentissage profond (EEMD-CNN) par rapport à la méthode conventionnelle (EEMD-MCSVM) qui dépend explicitement sur la qualité des caractéristiques extraites manuellement. Cela prouve aussi l'excellent potentiel de CNN à extraire des caractéristiques plus discriminantes contenant les signatures de défauts à partir des données d'entrée sans l'intervention d'un expert du domaine.

La méthode EEMD-CNN proposée maintient toujours de haute performance de diagnostic sous des fréquences de rotation variables et peut atteindre 98.24% comme taux de classification, ce qui signifie aussi la bonne capacité de généralisation et de transférabilité de notre système à classifier des données inconnues qu'on n'a pas utilisé dans la phase d'apprentissage.

De plus, notre modèle EEMD-CNN reste efficace même avec une faible quantité de données d'entraînement, où le résultat de classification atteint 99,40% pour seulement 20% des données utilisées lors de l'apprentissage.

L'application de l'EEMD-CNN à la base de données de CWRU valide l'efficacité de notre méthode pour le diagnostic des défauts de roulements avec différents diamètres et sévérités et sous différentes conditions de fonctionnement liées à la charge et la vitesse.

L'excellent potentiel d'EEMD-CNN à diagnostiquer un large nombre de défauts avec une faible quantité de données de formation évite le risque de sur-apprentissage et réduit considérablement le coût de calcul.

Ce travail prouve aussi l'efficacité du traitement EEMD qui sert à éliminer le bruit et extraire les informations précieuses à partir des signaux vibratoires bruts, ce qui reflète l'état de santé réel des roulements qui sont déjà exposés au bruit.

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 et perspectives

Ce projet de recherche a porté sur la surveillance et le diagnostic des défauts de roulements en utilisant la technique de décomposition modale empirique.

Il s'agit de développer un système de diagnostic capable à détecter et à localiser les différents défauts de roulements dans un stade précoce. Ce système s'insère d'une façon globale dans le cadre d'un programme d'une stratégie de maintenance préventive conditionnelle.

Cette étude concerne l'extraction des paramètres pertinents à partir des signaux de nature vibratoire après un processus de débruitage, et le développement des méthodes de classification en vue d'établir un diagnostic efficace reflétant l'état de dégradation réel des roulements.

Dans ce travail, nous nous sommes concentrés sur le jumelage de l'EEMD avec les différents outils fournis par l'intelligence artificielle pour la classification des données vibratoires, où les techniques que nous avons mises en œuvre doivent répondre aux diverses contraintes imposées par les différents modes de fonctionnement de la machine.

Tout d'abord, nous avons présenté le domaine de la maintenance préventive des machines tournantes dans lequel nous avons vu un nombre important et non exhaustif des principales défaillances pouvant altérer le fonctionnement de ces machines. Une brève classification des approches de surveillance dédiées à la recherche d'une présence d'un défaut est dressée avec un intérêt donné à l'approche sans modèle, notamment le diagnostic à base des méthodes externes exploitant les données capteur provenant de différentes sources d'information. Une attention particulière est donnée à l'analyse vibratoire, où les principales méthodes dédiées à exploiter et à traiter l'information vibratoire, sont décrites et détaillées. Un état de l'art a été exposé dans le but de considérer l'immense progrès dans le domaine de détection et de diagnostic des défauts.

En second lieu, les différentes étapes conçues pour effectuer une démarche de diagnostic intelligent, ont été décrites et largement discutées. Cette démarche est réunie avec une synthèse bibliographique résumant les principales méthodes de l'IA mises récemment afin d'automatiser la tâche de diagnostic et ainsi renforcer l'efficacité des systèmes de

surveillance. La principale limitation des méthodes conventionnelles d'apprentissage statistique réside à la dépendance de la qualité des caractéristiques extraites manuellement nécessitant l'intervention d'un expert du domaine, par contre, l'avantage majeur des techniques d'apprentissage profond consiste en leur potentiel d'extraire les informations pertinentes à partir d'une grande quantité de données d'entrée grâce à une procédure généralisée d'auto-apprentissage.

Dans la phase d'application, plusieurs techniques ont été expérimentées pour le diagnostic de défauts des roulements, à savoir, l'approche conventionnelle à base du traitement EEMD et la méthode d'apprentissage profond basée sur le traitement d'images par CNN. L'objectif de l'élaboration de plusieurs systèmes de diagnostic est de chercher ou définir l'approche la plus performante aidant à identifier l'état réel des roulements avec une efficacité élevée.

Les premières expérimentations ont vu l'élaboration d'un algorithme à base d'EEMD afin de diminuer le taux de bruit contenu dans les signaux vibratoires acquis. Ces derniers sont reconstruits à nouveau à base des IMFs les plus pertinentes choisies par une procédure de sélection. Un ensemble d'indicateurs statistiques temporels a été extraits manuellement à partir des signaux reconstruits afin de construire un vecteur de caractéristiques qui a été pris ensuite comme une entrée à plusieurs classifieurs conventionnels en utilisant le MCSVM, le KNN et le Naive Bayes. Cette approche a été appliquée aux données vibratoires de CWRU, où les défauts qui ont le plus petit diamètre, ont été choisis lors des expériences (les défauts d'un diamètre de 0.007 inch). Le système de diagnostic proposé a été évalué pour diagnostiquer quatre états de santé de roulements opérationnels sous des conditions de charge et de vitesse variables.

Une deuxième méthode a été exposée en utilisant les réseaux de neurones de convolution. Cette technique est totalement différente aux méthodes conventionnelles ; elle ne nécessite aucune extraction manuelle d'indicateurs contenant les signatures de défauts. Ceci a l'avantage d'extraction automatique des indicateurs à partir des images vibratoires sans avoir des connaissances approfondies. La méthode proposée a été validée sous plusieurs contraintes opérationnelles (sous l'effet du bruit et de charges variables). Les méthodes développées ont montré des performances élevées dans la détection des défauts précoces affectant les roulements.

Le dernier chapitre a été consacré sur le développement d'une nouvelle méthode de surveillance basé sur le couple EEMD-CNN. Elle exploite l'aptitude d'EEMD à traiter les signaux vibratoires non stationnaire et le potentiel du CNN à extraire automatiquement les

caractéristiques révélatrices de l'état de dégradation des roulements. Cette combinaison efficace a été validée et testée sous des données vibratoires provenant de deux bancs d'essais (URMA/CRTI et CWRU). Le système de surveillance conçu a révélé d'excellents résultats en diagnostic de défauts des roulements sous une faible quantité de données utilisées lors de la phase d'apprentissage, ce qui a réduit considérablement le coût d'entraînement vis-à-vis au temps de calcul. Enfin, nous avons comparé les résultats obtenus avec ceux obtenus par les techniques de diagnostic existantes dans la littérature, ce qui nous a permis de montrer le bien-fondé de la méthode que nous avons développée.

A travers cette étude, nous avons surmonté les principales limitations et lacunes des approches de diagnostic de défauts existantes, où les contributions qu'on peut tirer, englobent les axes suivants :

- ✓ La proposition de deux algorithmes puissants (EEMD et CNN) qui ne nécessitent aucune intervention d'un expert ou d'une extraction manuelle d'indicateurs.
- ✓ Diagnostic précis et précoce de défauts sous des conditions de fonctionnement variables.
- ✓ La méthode proposée a une excellente capacité de généralisation et peut classer efficacement des données inconnues.
- ✓ Réduction du coût d'apprentissage à partir d'une grande quantité de données vibratoires.

## Perspectives

A la suite de ces travaux, nous pouvons tirer plusieurs perspectives envisageables pour des futurs travaux :

- ✓ Les futurs travaux pourraient également inclure l'application de la méthode proposée au diagnostic des défauts pour d'autres machines tournantes, comme les turbines et les réducteurs de vitesses.
- ✓ Application des méthodes proposées à des données provenant de nouvelles sources d'information, comme les données acoustiques et du courant, etc., et diagnostic de nouveaux types de défauts, notamment les défauts d'engrenage.
- ✓ Le développement de nouveaux systèmes de diagnostic plus sophistiqués en se basant sur les techniques de l'apprentissage profond comme l'apprentissage parallèle et l'apprentissage par transfert.

- ✓ Faire des expérimentations plus poussées liées aux applications industrielles dans le but de converger vers une maintenance prédictive plus efficace des machines tournantes.
- ✓ Cette recherche fournit une étude réussie du diagnostic automatique des défauts de roulements à l'aide du couple EEMD-CNN. Les méthodes proposées dans cette thèse et celles qui seront étudiées à l'avenir peuvent être intégrées dans une boîte à outils complète pour le diagnostic de défauts, ce qui porte un grand avantage aux praticiens et aux chercheurs impliqués dans le domaine de la surveillance de l'état des machines par l'analyse vibratoire.

# Annexe : Caractéristiques des roulements de CWRU

**Tableau A.1** Spécifications des défauts de roulements.

Roulement	Position de défaut	Diamètre (inches)	Profondeur (inches)	Marque
<b>Roulement coté entraînement</b>	Bague intérieur	.007	.011	SKF
		.014		
		.021		
		.028		
	Bague extérieur	.007	.011	SKF
		.014		
		.021		
		.040		
	Bille	.007	.011	SKF
		.014		
.021				
.028				
<b>Roulement coté ventilateur</b>	Bague intérieur	.007	.011	SKF
		.014		
		.021		
	Bague extérieur	.007		
		.014		
		.021		
	Bille	.007		
		.014		
		.021		

- ✓ **Le roulement coté entraînement** : roulement à Billes de cannelure profonde de type 6205-2RS JEM SKF.

Taille : inches.

**Tableau A.2** Caractéristiques du roulement coté entraînement

Diamètre intérieur	Diamètre extérieur	Epaisseur	Diamètre de bille	Diamètre primitif
0.9843	2.0472	0.5906	0.3126	1.537

**Fréquences caractéristiques des défauts (en Hz)****Tableau A.3** Fréquences caractéristiques des défauts (roulement coté entraînement)

Bague intérieur	Bague extérieur	Train de la cage	Élément roulant
5.4152	3.5848	0.39828	4.7135

- ✓ **Le roulement coté ventilateur** : roulement à Billes de cannelure profonde de type 6205-2RS JEM SKF.

Taille : inches.

**Tableau A.4** Caractéristiques du roulement coté ventilateur

Diamètre intérieur	Diamètre extérieur	Epaisseur	Diamètre de bille	Diamètre primitif
0.6693	1.5748	0.4724	0.2656	1.112

**Fréquences caractéristiques des défauts (en Hz)****Tableau A.5** Fréquences caractéristiques des défauts (roulement coté ventilateur)

Bague intérieur	Bague extérieur	Train de la cage	Élément roulant
4.9469	3.0530	0.3817	3.9874

# Bibliographie

- [1] L. Wang, J. Chu, & J. Wu. « Selection of optimum maintenance strategies based on a fuzzy analytic hierarchy process ». *International journal of production economics*, 107(1), pp. 151-163, 2007.
- [2] R. Ahmad, & S. Kamaruddin. « An overview of time-based and condition-based maintenance in industrial application ». *Computers & Industrial Engineering*, 63(1), pp. 135-149, 2012.
- [3] H. P. Bloch & F. K. Geitner. « Machinery failure analysis and troubleshooting: practical machinery management for process plants ». Gulf Professional Publishing Butterworth-Heinemann, 2012.
- [4] N. K. Verma, S. Khatravath & A. Salour. « Cost benefit analysis for condition-based maintenance ». In *Prognostics and Health Management (PHM), IEEE Conference*, pp. 1-6, 2013.
- [5] J. Van Dam & L. J. Bond. « Economics of online structural health monitoring of wind turbines: Cost benefit analysis ». In *AIP Conference Proceedings Vol. 1650, No. 1*, pp. 899-908, 2015.
- [6] J. Kim, Y. Ahn, & H. Yeo. « A comparative study of time-based maintenance and condition-based maintenance for optimal choice of maintenance policy ». *Structure and Infrastructure Engineering*, 12(12), pp.1525-1536, 2016.
- [7] A. K. Jardine, D. Lin, & D. Banjevic. « A review on machinery diagnostics and prognostics implementing condition-based maintenance ». *Mechanical systems and signal processing*, 20(7), pp. 1483-1510, 2006.
- [8] R. B. Randall & J. Antoni. « Rolling element bearing diagnostics—A tutorial ». *Mechanical systems and signal processing*, 25(2), pp. 485-520, 2011.
- [9] B. S. Yang, T. Han, & Z. J. Yin. « Fault diagnosis system of induction motors using feature extraction, feature selection and classification algorithm ». *JSME Int J Series C* 49(3):734–741, 2006.
- [10] R. B. Randall. « *Vibration-based Condition Monitoring Industrial, Aerospace and Automotive Applications* ». John Wiley & Sons, Ltd, Chichester, UK, 2011 édition, Janvier 2011. ISBN 9780470977668. URL <http://doi.wiley.com/10.1002/9780470977668>.
- [11] T. P. K. Nguyen. « Politiques de maintenance et d’investissement sous évolution technologique incertaine ». Thèse de Doctorat, Ecole Centrale de Nantes, 2012.
- [12] I. KHELFI. « Diagnostic des machines tournantes par les techniques de l’intelligence artificielle ». Thèse de Doctorat, Université Badji Mokhtar Annaba, 2014.
- [13] P. Lyonnet, « *La maintenance : Mathématique et Méthodes* ». Techniques et documentation, Lavoisier, Paris, 1992.
- [14] R. Dekker. « Applications of maintenance optimization models: a review and analysis », *Reliability Engineering and System Safety* 51, 229–240, 1996.
- [15] G. Zwingelstein. « *Diagnostic des défaillances : théorie et pratique pour les systèmes industriels. Traité des nouvelles technologies* ». Série Diagnostic et maintenance. Hermes Science Publications, 1995. ISBN 9782866014636.
- [16] M. Combacau. « *Commande et surveillance des systèmes à événements discrets complexes: applications aux ateliers flexibles* ». thèse de doctorat, L’université Paul Sabatier de Toulouse, 1991.

- [17] A. Willsky. « A survey of design methods for failure detection in dynamic systems », *Automatica*, vol. 12, no 6, p. 601–611, 1976.
- [18] M. R. Zemouri. « Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance ». thèse de doctorat, l'Université de Franche-Comté.
- [19] M. Basseville. « Detecting changes in signals and systems - a survey », *Automatica*, vol. 24, no 3, p. 309–326, 1998.
- [20] M. Combacau, P. Berrut, F. Charbonnaud & A. Khatab. « Reflexions sur la terminologie: Surveillance - supervision », Groupement pour la recherche en Productique, Systèmes de Production Sûrs de Fonctionnement, 2000.
- [21] H. L. Jones. « Failure detection in linear systems ». thèse de doctorat, Massachusetts Institute of Technology, 1973.
- [22] R. V. Beard. « Failure accommodation in linear systems through self-reorganization ». thèse de doctorat, Massachusetts Institute of Technology, 1971.
- [23] J. Gertler & D. Singer. « A new structural framework for parity equation-based failure detection and isolation », *Automatica*, vol. 26, no 2, p. 381–388, 1990.
- [24] L. Travé-Massuyès, P. Dague & F. Guerrin. « Le raisonnement qualitatif pour les sciences de l'ingénieur », Hermès, 1997.
- [25] J. Mosterman. « Diagnosis of physical systems with hybrid models using parameterized causality », *Hybrid Systems: Computation and Control*, 4th International Workshop, HSCC'01, Rome, Italia, p. 447–458, 2001.
- [26] M. Sampath, R. Sengupta, S. Lafortune, K. Sinnamohideen & D. Teneketzis. « Diagnosability of discrete event systems », *IEEE Transactions on Automatic Control*, vol. 40, no 9, p. 1555–1575, 1995.
- [27] P. Bhowal, D. Sarkar, S. Mukhopadhyay & A. Basu. « Fault diagnosis in discrete time hybrid systems - a case study », *Information Sciences*, vol. 177, no 5, p. 1290–1308, 2007.
- [28] A. K. Samantaray & B. O. Bouamama. « Model-based Process Supervision », chap. Diagnostic and Bicausal Bond Graphs for FDI, 2008.
- [29] J. Brunet, M. Labarrère, D. Jaume, A. Rault & M. Vergé. « Détection et diagnostic de pannes : Approche par modélisation », Hermès, Paris, 1990.
- [30] B. Dubuisson, « Diagnostic, intelligence artificielle et reconnaissance des formes » Hermès, Paris, 2001.
- [31] Marton, Lorinc & Linden, Franciscus. « Temperature dependent friction estimation: Application to lubricant health monitoring ». *Mechatronics*. 22. 1078–1084, 2012. 10.1016/j.mechatronics.2012.09.003.
- [32] L. Ciabattoni, F. Ferracuti, A. Freddi, and A. Monteriu, « Statistical spectral analysis for fault diagnosis of rotating machines ». *IEEE Transactions on Industrial Electronics*, vol. 65, no. 5, pp. 4301–4310, 2018.
- [33] X. Liang, M. J. Zuo, & Z. Feng. « Dynamic modeling of gearbox faults: a review ». *Mechanical Systems and Signal Processing*, vol. 98, pp. 852–876, 2018.
- [34] P. D. Samuel & D. J. Pines. « A review of vibration-based techniques for helicopter transmission diagnostics ». *Journal of Sound and Vibration*, vol. 282, no. 1-2, pp. 475–508, 2005.

- [35] K. Liang, N. Qin, D. Huang, Y. Fu, & L. Hu. « Convolutional recurrent neural network for fault diagnosis of high-speed train bogie ». *Complexity*, vol. 2018, Article ID 4501952, 13 pages, 2018.
- [36] Z. Feng & M. J. Zuo. « Vibration signal models for fault diagnosis of planetary gearboxes ». *Journal of Sound and Vibration*, vol. 331, no. 22, pp. 4919–4939, 2012.
- [37] X. Wang, S. Si, Y. Wei & Y. Li. « The optimized multi-scale permutation entropy and its application in compound fault diagnosis of rotating machinery ». *Entropy*, vol. 21, no. 2, p. 170, 2019.
- [38] A. Glowacz & Z. Glowacz. « Diagnostics of stator faults of the single-phase induction motor using thermal images, MoASoS and selected classifiers ». *Measurement*, vol. 93, pp. 86–93, 2016.
- [39] O. Janssens, R. Schulz, V. Slavkovikj & al. « Thermal image based fault diagnosis for rotating machinery ». *Infrared Physics & Technology*, vol. 73, pp. 78–87, 2015.
- [40] A. M. D. Younus & B.S. Yang. « Intelligent fault diagnosis of rotating machinery using infrared thermal image ». *Expert Systems with Applications*, vol. 39, no. 2, pp. 2082–2091, 2012.
- [41] E. Resendiz-Ochoa, R. A. Osornio-Rios, J. P. Benitez-Rangel, L. A. Morales-Hernandez & R. D. J. Romero-Troncoso. « Segmentation in thermography images for bearing defect analysis in induction motors ». In: *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, vol. 6, 2017.
- [42] M. Vollmer & K. P. Möllmann. « Infrared Thermal Imaging: Fundamentals ». *Research and Applications*. Wiley, 2010.
- [43] B. Kim, D. Gu, J. Kim, Y. Kim & B. Choi. « Rolling element bearing fault detection using acoustic emission signal analyzed by envelope analysis with discrete wavelet transform ». In: D. Kiritsis, C. Emmanouilidis, A. Koronios, J. Mathew (eds) *Engineering Asset Lifecycle Management*. Springer, London, 2010. [https://doi.org/10.1007/978-0-85729-320-6\\_69](https://doi.org/10.1007/978-0-85729-320-6_69).
- [44] Mohammed, Thabit & Mohammed, Aref & Al-Ani, Muzhir & Al-Shayea, Qeethara & Alnaimi, Firas. « Fault Diagnosis of Rotating Machine Based on Audio Signal Recognition System: An Efficient Approach ». *International Journal of Simulation: Systems, Science & Technology*, 2020. 21. 8.1-8.8. 10.5013/IJSSST.a.21.01.08.
- [45] J. Liang & Z. Yang. « A novel wavelet transform–empirical mode decomposition based sample entropy and SVD approach for acoustic signal fault diagnosis ». in *International Conference in Swarm Intelligence*. Springer, pp. 232–241, 2015.
- [46] Y. He & X. Zhang. « Approximate entropy analysis of the acoustic emission from defects in rolling element bearings ». *Journal of Vibration and Acoustics*, vol. 134, no. 6, p. 061012, 2012.
- [47] P. J. Dempsey & A. A. Afjeh. « Integrating Oil Debris and Vibration Gear Damage Detection Technologies Using Fuzzy Logic ». *International 58th Annual Forum and Technology Display, Quebec (Canada) June 11–13, 2002*.
- [48] D. P. Anderson. « Condition monitoring by wear metal analysis using ICP spectrometry. In: *Condition Monitoring* ». *Proceedings of the International Conference on Condition Monitoring*. Swansea: Pineridge Press, pp. 222–33, 1987.
- [49] Yang, Yizhou, & Jiang, Dongxiang. « Casing Vibration Fault Diagnosis Based on Variational Mode Decomposition, Local Linear Embedding, and Support Vector Machine ». *Shock and Vibration*, 2017. 1-14. 10.1155/2017/5963239.

- [50] Y. Xin, S. Li, Z. Zhang, Z. An, & J. Wang. « Adaptive Reinforced Empirical Morlet Wavelet Transform and Its Application in Fault Diagnosis of Rotating Machinery ». In *IEEE Access*, vol. 7, pp. 65150-65162, 2019, doi: 10.1109/ACCESS.2019.2917042.
- [51] N. E. Huang, Z. Shen, S.R. Long & al. « The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis ». *Proceedings of the Royal Society of London A: Mathematical, Physical & Engineering Sciences*, 454, 903–995, 1998.
- [52] N. E. Huang & Z. Wu. « Ensemble empirical mode decomposition: A noise-assisted data analysis method ». *Advances in Adaptive Data Analysis*, vol. 01, No. 01, pp. 1-41, January 2009.
- [53] Y. Lei, Z. He & Y. Zi. « Application of the EEMD method to rotor fault diagnosis of rotating machinery ». *Mechanical Systems and Signal Processing*, vol. 23, no 4, p. 1327-1338, 2009.
- [54] Y. Lei, Z. He & Y. Zi. « EEMD method and WNN for fault diagnosis of locomotive roller bearings ». *Expert Systems with Applications*, vol. 38, no 6, p. 7334-7341, 2011.
- [55] J. Gilles. « Empirical Wavelet Transform ». in *IEEE Transactions on Signal Processing*, vol. 61, no. 16, pp. 3999-4010, Aug.15, 2013, doi: 10.1109/TSP.2013.2265222.
- [56] K. Dragomiretskiy & D. Zosso. « Variational Mode Decomposition ». in *IEEE Transactions on Signal Processing*, vol. 62, no. 3, pp. 531-544, Feb.1, 2014, doi: 10.1109/TSP.2013.2288675.
- [57] J. Morlet, G. Arens, E. Fourgeau, & D. Giard. « Wave propagation and sampling theory- part 1: complex signal and scattering in multilayered media ». *Geophysics*, 47(2), 203-221, 1982.
- [58] J. Morlet, G. Arens, E. Fourgeau, & D. Giard. « Wave propagation and sampling theory- part 2: sampling theory and complex waves ». *Geophysics*, 47(2), 222-236, 1982.
- [59] A. Grossmann & J. Morlet. « Decomposition of Hardy functions into square integrable wavelets of constant shape ». *SIAM J. math. Anal.* 15 (4), 723-736, 1984.
- [60] D. Gabor. « Theory of communication. Part 1: The analysis of information... Engineers-Part III ». *Radio and Communication . . .* , 1946. URL: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=5298517](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5298517).
- [61] Song, Wenlei, Xiang, Jiawei, & Zhong, Yongteng. « A Simulation Model Based Fault Diagnosis Method for Bearings ». *Journal of Intelligent & Fuzzy Systems*, vol. 34, no. 6, pp. 3857-3867, 2018. Doi: 10.3233/JIFS-169557.
- [62] K. A. Loparo, A. H. Falah, & M. L. Adams. « Model-based fault detection and diagnosis in rotating machinery ». *Proceedings of the Tenth International Congress on Sound and Vibration*, Stockholm, Sweden, pp. 1299-1306, 2003.
- [63] C. Zhang, Y. Liu, F. Wan, B. Chen, J. Liu & B. Hu. « Multi-faults diagnosis of rolling bearings via adaptive customization of flexible analytical wavelet bases ». *Chinese Journal of Aeronautics*. Vol 33, Issue 2, Pages 407-417. , February 2020. <https://doi.org/10.1016/j.cja.2019.03.014>.
- [64] I. Howard, S. Jia & J. Wang. « The dynamic modeling of a spur gear in mesh including friction and a crack ». *Mechanical Systems and Signal Processing*, Vol. 15, pp. 831-838, 2001.
- [65] J. Park, J. M. Ha, H. Oh, B. D. Youn, J. Choi & N. H. Kim. « Model-Based Fault Diagnosis of a Planetary Gear: A Novel Approach Using Transmission Error ». in *IEEE Transactions on Reliability*, vol. 65, no. 4, pp. 1830-1841, Dec. 2016, doi: 10.1109/TR.2016.2590997.

- [66] X. Liang, M. J. Zuo & W. Chen. « Dynamics-Based Vibration Signal Modeling for Tooth Fault Diagnosis of Planetary Gearboxes, Fault Diagnosis and Detection ». Mustafa Demetgul and Muhammet Ünal, IntechOpen, May 2017. Doi: 10.5772/67529.
- [67] C. H. Oppenheimer & K. A. Loparo. « Physically based diagnosis and prognosis of cracked rotor shafts ». *Component and Systems Diagnostics, Prognostics, and Health Management II*, Vol. 4733, Bellingham, pp. 122-132, 2002.
- [68] A. K. Jalan & A. R. Mohanty. « Model Based Fault Diagnosis in Rotating Machinery ». 2011.
- [69] J. Dybala & R. Zimroz. « Rolling bearing diagnosing method based on empirical mode decomposition of machine vibration signal ». *Appl. Acoust*, 77, 195–203, 2014.
- [70] J. Dybala & A. Galezia. « A novel method of gearbox health vibration monitoring using empirical mode decomposition ». In *Advances in Condition Monitoring of Machinery in Non-Stationary Operations*; Springer: Berlin, Heidelberg, Germany, Volume 333, pp. 225–234, 2014.
- [71] H. Chen, P. Chen, W. Chen & C. Wu. « Wind turbine gearbox fault diagnosis based on improved EEMD and Hilbert square demodulation ». *Appl. Sci.*, 7, 128, 2017.
- [72] M. Zvokelj, S. Zupan & I. Prebil. « EEMD-based multiscale ICA method for slewing bearing fault detection and diagnosis ». *J. Sound Vib.* 370, 394–423, 2016.
- [73] Y. Amirat, V. Choqueuse, and M. Benbouzid, “EEMD-based wind turbine bearing failure detection using the generator stator current homopolar component”, *Mechanical Systems and Signal Processing*, (mssp Elsevier), vol. 41, n° 1-2, pp. 667-678, 2013, doi : 10.1016/j.ymsp.2013.06.012.
- [74] A. Tabrizi, L. Garibaldi, A. Fasana & S. Marchesiello. « Performance improvement of ensemble empirical mode decomposition for roller bearings damage detection ». *Shock Vib.*, 964805, 2015.
- [75] Y. Amirat, M. Benbouzid, T. Wang, K. Bacha and G. Feld, “EEMD-based Notch Filter for Induction Machine Bearing Faults Detection,” *Applied Acoustic Journal*, vol. 8, n° 5, pp. 1503-1508, 2018, doi : 10.1016/j.apacoust.2017.12.030.
- [76] G. K. Singh & S.A. Ahmed. « Vibration signal analysis using wavelet transform for isolation and identification of electrical faults in induction machine ». *Electr. Power Syst. Res.* 68 (2), 119–136, 2004.
- [77] R. X. Gao & R. Yan. « Non-stationary signal processing for bearing health monitoring ». *Int. J. Manuf. Res.* 1 (1), 18–40, 2006.
- [78] A. M. Younus & B. S. Yang. « Wavelet co-efficient of thermal image analysis for machine fault diagnosis ». In *Prognostics and Health Management Conference, PHM'10*. (pp. 1-6), January 2010. IEEE.
- [79] R. B. Randall. « Vibration-based condition monitoring: industrial, aerospace and automotive applications ». Willey-Blackwell, Hoboken, New Jersey, USA, 2011.
- [80] Y. T. Wu, H. C. Hong, & Y. L. Chung. « A looseness identification approach for rotating machinery based on post-processing of ensemble empirical mode decomposition and autoregressive modeling ». *J. Vib. Control.* 18, 1–12, 2012.
- [81] J. Zhou, Y. Qin, L. Kou, M. Yuwono, & S. Su. « Fault detection of rolling bearing based on FFT and classification ». *J Advan Mech Des Syst Manuf* 9(5), 2015.
- [82] J. Wu, T. Tang, M. Chen, & T. Hu. « Self-adaptive spectrum analysis based bearing fault diagnosis ». *Sensors* 18(10), 2018.

- [83] B. S. Yang, T. Han, & Z. J. Yin. « Fault diagnosis system of induction motors using feature extraction, feature selection and classification algorithm ». *JSME Int J Series C* 49(3):734–741, 2006.
- [84] B. R. Nayana, & P. Geethanjali. « Effective time domain features for identification of bearing fault using LDA and NB classifiers ». *Int J Mech Product Eng Res Dev* 8:1135–1150, 2018.
- [85] T. P. K. Nguyen, A. Khlaief, K. Medjaher, A. Picot, P. Maussion P & al. « Analysis and comparison of multiple features for fault detection and prognostic in ball bearings ». In: Fourth European conference of the prognostics and health management society, Utrecht, Netherlands, pp.1–9, Jul 2018.
- [86] Z. H. Luo & Q. J. Xiao. « Time-frequency features of signal analysis and its application in mechanical fault diagnosis ». *AdvanMater Res* 834-836:1065–1068, 2013.  
<https://doi.org/10.4028/www.scientific.net/amr.834-836.1065>.
- [87] C. S. Syan, & G. Ramsoobag. « Empirical mode decomposition for fault diagnosis of multi-component systems ». *Annual Reliability and Maintainability Symposium (RAMS)*, 2018.  
<https://doi.org/10.1109/ram.2018.8463000>.
- [88] M. Bahri, & J. J. Sharples. « Sensitivity of the empirical mode decomposition to interpolation methodology and data non-stationarity ». *Environ Model Assess*, 24(4):437–456, 2019.
- [89] E. Karatoprak, & S. Seker. « An improved empirical mode decomposition method using variable window median filter for early fault detection in electric motors ». *Math Probl Eng* 1–9, 2019.  
<https://doi.org/10.1155/2019/8015295>
- [90] K. C. D. Kompella, V. G. R. Mannam, & S. R. Rayapudi. « DWT based bearing fault detection in induction motor using noise cancellation ». *J Electric Syst Inform Technol* 3(3):411–427, 2016.
- [91] M. R. Mehrjou, N. Mariun, M. Karami & al. « Wavelet-based analysis of MCSA for fault detection in electrical machin ». *Wavelet Transform and Some of Its Real-World Applications*, pp 79–110, 2015. <https://doi.org/10.5772/61532>.
- [92] L. H. Wang, X. P. Zhao, J. X. Wu, Y. Y. Xie, & Y. H. Zhang. « Motor fault diagnosis based on short-time Fourier transform and convolutional neural network ». *Mech Eng* 30(6):1357–1368, 2017.
- [93] H. Liu, L. Li, & J. Ma. « Rolling bearing fault diagnosis based on STFT-deep learning and sound signals ». *Shock Vib* 1–12, 2016. <https://doi.org/10.1155/2016/6127479>
- [94] A. G. Espinosa, J. A. Rosero, J. Cusido, L. Romeral, & J. A. Ortega. « Fault detection by means of Hilbert–Huang transform of the Stator current in a PMSM with demagnetization ». *IEEE Transact Energy Convers* 25(2):312–318, 2010.
- [95] A. Kabla, & K. Mokran. « Bearing fault diagnosis using Hilbert-Huang transform (HHT) and support vector machine (SVM) ». *Mechanics and Industry* 17(3); 308, 2015.  
<https://doi.org/10.1051/meca/2015067>
- [96] Chiementin, Xavier, Kilundu, Bovic & J. Dron & Dehombreux, Pierre & Debray, Karl. « Effect of cascade methods on vibration defects detection ». *Journal of Vibration and Control*. 17. 567-577, 2011. [10.1177/1077546310362447](https://doi.org/10.1177/1077546310362447).
- [97] E. Faris, G. Matthew, M. David, & A. Abdulmajid. « Application of Acoustic Emission in Diagnostic of Bearing Faults within a Helicopter Gearbox ». *Procedia CIRP*. Volume 38, Pages 30-36, 2015. <https://doi.org/10.1016/j.procir.2015.08.042>.

- [98] R. I. Saad Al-Dossary, Raja Hamzah & al. « Observations of Changes in Acoustic Emission Waveform for Varying Seeded Defect Sizes in a Rolling Element Bearing ». *Applied Acoustics*. Vol. 70-58, p. 81, 2009.
- [99] B. Eftekharijad, M. Carrasco, B. Charnley, & D. Mba. « The application of spectral kurtosis on acoustic emission and vibrations from a defective bearing ». *Mechanical Systems and Signal Processing*, vol. 25, no. 1, pp. 266-284, 2011.
- [100] C. Ruiz-Cárcel, E. Hernani-Ros, Y. Cao & D. Mba. « Use of Spectral Kurtosis for Improving Signal to Noise Ratio of Acoustic Emission Signal from Defective Bearings ». *Journal of Failure Analysis and Prevention*. 14(3): 363-371, 2014.
- [101] G. Lim, D. Bae & J. Kim. « Fault diagnosis of rotating machine by thermography method on support vector machine ». *J Mech Sci Technol* 28, 2947–2952, 2014. <https://doi.org/10.1007/s12206-014-0701-6>.
- [102] M. Moret & P. Guay. « Roulements - les différents types et montages ». *Techniques de l'ingénieur*, 33(0), 2013.
- [103] A. A. Elfeky, M. I. Masoud & I. F. El-Arabawy. « Fault Signature Production for Rolling Element Bearings in Induction Motor ». *Compatibility in Power Electronics*. IEEE, 2007.
- [104] Projet MQTM, « Fiabilité- qualité : La maintenance systématique ».
- [105] S. Elfezazi & al. « Vers un outil, basé sur l'analyse fonctionnelle, pour la mise en œuvre des indicateurs de mesure de performance de la fonction maintenance ». *Revue française de gestion industrielle*. Vol.22, N°3/2003.
- [106] A. H. Bonnett & C. Yung. « Increased efficiency versus increased reliability ». *IEEE Industry Applications Magazine*, 14: 29-36, xi, 14, 15, 2008.
- [107] J. McCarthy, "4.2 Asset price inflation," *Boom & Bust: A Look at Economic Bubbles*, p. 207, 2015.
- [108] Y. Yuan, H. Xu, & B. Wang. An improved NSGA-III procedure for evolutionary many-objective optimization. Presented at the Proceedings of the 2014 conference on Genetic and evolutionary computation, Vancouver, BC, Canada, 2014.
- [109] J. Chang, T. Li, & P. Li. "The selection of time domain characteristic parameters of rotating machinery fault diagnosis". *International Conference on Logistics Systems and Intelligent Management (ICLSIM)*, 2010.
- [110] Y. Lei, D. Kong, J. Lin & M. Zuo, "Fault detection of planetary gearboxes using new diagnostic parameters," *Measurement Science and Technology*, vol. 23, pp. 055605, 2012.
- [111] E. J. Cross, G. Manson, K. Worden, & S. G. Pierce. "Features for damage detection with insensitivity to environmental and operational variations". *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Science*, 468(2148):4098-4122, 2012.
- [112] S. Dong, T. Luo, L. Zhong, L. Chen & X. Xu. "Fault diagnosis of bearing based on the kernel principal component analysis and optimized k-nearest neighbour model". *Journal of Low Frequency Noise, Vibration and Active Control*. 36(4):354-365, 2017. doi:10.1177/1461348417744302.
- [113] Z. Chen & Y. Yuan. "Bearing fault diagnosis based on EMD-KPCA and ELM". *Vibroengineering PROCEDIA*, Vol. 4, p. 200-205, 2014.

- [114] Y. Li, X. Qin and J. Guo, "Fault Diagnosis in Industrial Process Based on Locality Preserving Projections," 2010 International Conference on Intelligent System Design and Engineering Application, Changsha, pp. 734-737, 2010. doi: 10.1109/ISDEA.2010.309.
- [115] K. M. Bhavaraju, P. K. Kankar, Satish, C. Sharma & S. P. Harsha. A comparative study on bearings faults classification by artificial neural networks and self-organizing maps using wavelets. *International Journal of Engineering Science and Technology*, 2010.
- [116] F. Wang, J. Sun, D. Yan, S. Zhang, L. Cui & Y. Xu. "A Feature Extraction Method for Fault Classification of Rolling Bearing based on PCA". 11th International Conference on Damage Assessment of Structures (DAMAS 2015), Volume 628, 24–26, Ghent, Belgium, August 2015.
- [117] B. P. Kamiel & I. Howard. "Ball bearing fault diagnosis using wavelet transform and principal component analysis". *AIP Conference Proceedings* 2187, 050031, 2019. <https://doi.org/10.1063/1.5138361>
- [118] J. Huang, S. Bi, H. Pan & X. Yang. "Application of independent component analysis to fault diagnosis of gearbox". 28. 126-130, 2008.
- [119] A. K. A., M. N. Belur & D. Chakraborty, "Comparison of various linear discriminant analysis techniques for fault diagnosis of Re-usable Launch Vehicle," 2011 50th IEEE Conference on Decision and Control and European Control Conference, Orlando, FL, pp. 3050-3055, 2011. doi: 10.1109/CDC.2011.6161032.
- [120] M. Ahmed, M. Baqqar, F. Gu & A. D. Ball, "Fault detection and diagnosis using Principal Component Analysis of vibration data from a reciprocating compressor," *Proceedings of 2012 UKACC International Conference on Control*, Cardiff, pp. 461-466, 2012. doi: 10.1109/CONTROL.2012.6334674.
- [121] F. Miao & R. Z. Zhao. "Application of Independent Component Analysis in Machine Fault Diagnosis". *Advanced Materials Research*, 905, 524–527, 2014. <https://doi.org/10.4028/www.scientific.net/amr.905.524>
- [122] J. Tian, M. Pecht & C. Li. "Diagnosis of rolling element bearing fault in bearing-gearbox union system using wavelet packet correlation analysis". Dayton, OH, pp.24-26, 2012.
- [123] J. Zheng, J. Cheng, Y. Yang & S. Luo. "A rolling bearing fault diagnosis method based on multi-scale fuzzy entropy and variable predictive model-based class discrimination". *Mechanism and Machine Theory*, 78, pp.187-200, 2014.
- [124] V. Vakharia, V. K. Gupta & P. K. Kankar. "Bearing Fault Diagnosis Using Feature Ranking Methods and Fault Identification Algorithms". *Procedia Engineering*, 144, pp.343-350, 2016.
- [125] T. Hastie, R. Tibshirani & J. Friedman. "The Elements of Statistical Learning: Data Mining, Inference, and Prediction". Springer, 2009.
- [126] T. W. Rauber, F. Boldt & F. M. Varejão. "Heterogeneous feature models and feature selection applied to bearing fault diagnosis". *IEEE Transactions on Industrial Electronics*, 62(1), pp.637-646, 2015.
- [127] Z. Liao & P. Chen. "A Vibration Signal Filtering Method Based on KL Divergence Genetic Algorithm – with Application to Low Speed Bearing Fault Diagnosis," 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP), Shanghai, China, pp. 1-5, 2018. doi: 10.1109/ICDSP.2018.8631550.

- [128] Z. Wang, T. Sun and X. Tian. "Fault Diagnosis of Rolling Bearing Based on SDAE and PSO-DBN," 2019 Chinese Control And Decision Conference (CCDC), Nanchang, China, pp. 624-629, 2019. doi: 10.1109/CCDC.2019.8833353.
- [129] M. Seera, C. P. Lim, & C. K. Loo. "Motor fault detection and diagnosis using a hybrid FMM-CART model with online learning". *Journal of intelligent manufacturing*, 27(6), pp.1273-1285, 2016.
- [130] C. Rajeswari, B. Sathiyabhama, S. Devendiran & K. Manivannan. « Bearing fault diagnosis using multi-class support vector machine with efficient feature selection methods". *International Journal of Mechanical and Mechatronics Engineering*, 15(1), pp.1-12, 2015.
- [131] C. Kim, H. Lee, W. B. Lee. "Process fault diagnosis via the integrated use of graphical lasso and Markov random fields learning & inference". *Computers & Chemical Engineering*, vol. 125, Pages 460-475, 2019. <https://doi.org/10.1016/j.compchemeng.2019.03.018>.
- [132] H. Keskes, A. Braham, & Z. Lachiri. "Broken rotor bar diagnosis in induction machines through stationary wavelet packet transform and multiclass wavelet SVM". *Electr. Power Syst. Res.* 97 151–157, 2013.
- [133] P. Konar, J. Sil & P. Chattopadhyay. "Knowledge extraction using data mining for multi-class fault diagnosis of induction motor". *Neurocomputing*, 166, 14–25, 2015.
- [134] J. D. M. Morales, E. Palacios & D. U. Campos-Delgado. « Data fusion for multiple mechanical fault diagnosis in induction motors at variable operating conditions". In *Electrical Engineering Computing Science and Automatic Control (CCE)*, 2010 7th International Conference on (pp. 176–181). IEEE.
- [135] A. Tabrizi; L. Garibald, A. Fasana& S. Marchesiello. Early damage detection of roller bearings using wavelet packet decomposition, ensemble empirical mode decomposition and support vector machine. *Meccanica*, 50, 865–874, 2015.
- [136] L. Saidi, J. Ali, E. Bechhoefer & M. Benbouzid. "Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR". *Appl. Acoust*, 120, 1–8, 2017.
- [137] V. A. D. Silva & R. Pederiva. "Fault detection in induction motors based on artificial intelligence". *Surveillance 7*, International Conference -October 29-30, 2013, Institute of Technology of Chartres, France.
- [138] K. H. Hui, M. H. Lim, M. S. Leong, & S. M. Al-Obaidi, "Dempster-Shafer evidence theory for multi-bearing faults diagnosis," *Eng. Appl.Artif. Intell.*, vol. 57, no. October 2016, pp. 160–170, 2017.
- [139] P. Gangsar & R. Tiwari. "Multifault diagnosis of induction motor at intermediate operating conditions using wavelet packet transform and support vector machine". *J. Dyn. Syst. Meas. Contr.* 140 (8), 081014, 2018.
- [140] G. F. Bin, J. J. Gao, X. J. Li & B. B. Dhillon. "Early fault diagnosis of rotating machinery based on wavelet packets-Empirical mode decomposition feature extraction and neural network". *Mech. Syst. Signal Process.* 27, 696–711, 2012.
- [141] Z. Zhang, Y. Wang & K. Wang. "Fault diagnosis and prognosis using wavelet packet decomposition, Fourier transform and artificial neural network," *Journal of Intelligent Manufacturing*, vol. 24, pp. 1213-1227, 2013.
- [142] J. Ben Ali, N. Fnaiech, L. Saidi, B. ChebelMorello, & F. Fnaiech, "Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals," *Appl. Acoust.*, vol. 89, pp. 16–27, 2015.

- [143] S. R. Huang, K.H. Huang, K.H. Chao & W.T. Chiang, "Fault analysis and diagnosis system for induction motors". *Comput. Electr. Eng.* 54, 195–209, 2016.
- [144] J. S. L. Senanayaka, H. Van Khang and K. G. Robbersmyr, "Towards online bearing fault detection using envelope analysis of vibration signal and decision tree classification algorithm," 2017 20th International Conference on Electrical Machines and Systems (ICEMS), Sydney, NSW, 2017, pp. 1-6, doi: 10.1109/ICEMS.2017.8056146.
- [145] F. B. Abid, M. Sallem and A. Braham, "Optimized SWPT and Decision Tree for Incipient Bearing Fault Diagnosis," 2019 19th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA), Sousse, Tunisia, 2019, pp. 231-236, doi: 10.1109/STA.2019.8717197.
- [146] H. Kumar, ranjitkumar.ta, A. Muniyappa & V. Sugumaran. « Fault diagnosis of bearings through vibration signal using Bayes classifiers”. *International Journal of Computer Aided Engineering and Technology* 6(1):14 – 28, 2014. DOI: 10.1504/IJCAET.2014.058002.
- [147] P. Baraldi, F. Cannarile, F. Di Maio, & E. Zio, “Hierarchical k-nearest neighbours classification and binary differential evolution for fault diagnostics of automotive bearings operating under variable conditions,” *Eng. Appl. Artif. Intell.*, vol. 56, pp. 1–13, 2016.
- [148] A. Sharma, R. Jigyasu, L. Mathew and S. Chatterji, "Bearing Fault Diagnosis Using Weighted K-Nearest Neighbor," 2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI), Tirunelveli, 2018, pp. 1132-1137, doi: 10.1109/ICOEI.2018.8553800.
- [149] S. Rajabi, M. Samanazari, H. R. Momeni and A. Ramezani, "Automated fault diagnosis of rolling element bearings based on morphological operators and M-ANFIS," 2016 24th Iranian Conference on Electrical Engineering (ICEE), Shiraz, 2016, pp. 1757-1762, doi: 10.1109/IranianCEE.2016.7585805.
- [150] F. Gougam, C. Rahmoune, D. Benazzouz, C. Varnier and J. Nicod, "Health Monitoring Approach of Bearing : Application of Adaptive Neuro Fuzzy Inference System (ANFIS) for RUL-Estimation and Autogram Analysis for Fault-Localization," 2020 Prognostics and Health Management Conference (PHM-Besançon), Besançon, France, 2020, pp. 200-206, doi: 10.1109/PHM-Besançon49106.2020.00040.
- [151] V. Vapnik. *The nature of statistical learning theory*. Springer Verlag, 1995.
- [152] Z. Wang, X. Xue. Multi-class support vector machine. *Support Vector Machines Applications*, pp. 23–48, 2013. [https://doi.org/10.1007/978-3-319-02300-7\\_2](https://doi.org/10.1007/978-3-319-02300-7_2).
- [153] M. Gan & C. Wang. « Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings ». *Mechanical System and Signal processing*, 72, 92-104, 2016.
- [154] L. Li, D. Guilan & Y. Zhang. “A membership based multi-dimension hierarchical deep neural network approach for fault diagnosis”. *Conf. SEKE*, 197-200, 2017.
- [155] R. Yang, M. Huang, Q. Lu & M. Zhong. « Rotating Machinery Fault Diagnosis Using Long-short-term Memory Recurrent Neural Network”. *IFAC-PapersOnline*, Vol. 51, Issue 24, Pages 228-232, 2018. <https://doi.org/10.1016/j.ifacol.2018.09.582>.
- [156] J. Tang, J. Wu, B. Hu, & al. « A fault diagnosis method using Interval coded deep belief network”. *J Mech Sci Technol* 34, 1949–1956, 2020. <https://doi.org/10.1007/s12206-020-0416-9>.

- [157] D. Han, K. Liang & P. Shi. “Intelligent fault diagnosis of rotating machinery based on deep learning with feature selection”. *Journal of Low Frequency Noise, Vibration and Active Control*. 39(4):939-953, 2020. doi:10.1177/1461348419849279.
- [158] J. Li, X. Li, & D. He. et al. « Unsupervised rotating machinery fault diagnosis method based on integrated SAE–DBN and a binary processor”. *J Intell Manuf* 31, 1899–1916, 2020. <https://doi.org/10.1007/s10845-020-01543-8>
- [159] B.B. Le Cun, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard & L. D. Jackel. “Handwritten digit recognition with a back-propagation network”. in: *Advances in Neural Information Processing Systems*, Citeseer, 1990.
- [160] A. Krizhevsky, I. Sutskever, G. E. Hinton. “Imagenet classification with deep convolutional neural networks”. In: *Advances in Neural Information Processing Systems*, 1097–1105, 2012.
- [161] O. Janssens & al. “Convolutional Neural Network Based Fault Detection for Rotating Machinery,” *J. Sound Vib.*, vol. 377, pp. 331–345, 2016.
- [162] X. Ding & Q. He. “Energy-fluctuated multiscale feature learning with deep convnet for intelligent spindle bearing fault diagnosis”. *IEEE Trans. Instrum. Meas.* 66 (8), 1926–1935, 2017.
- [163] L. Eren. "Bearing Fault Detection by One-Dimensional Convolutional Neural Networks", *Mathematical Problems in Engineering*, vol. 2017, Article ID 8617315, 9 pages, 2017. <https://doi.org/10.1155/2017/8617315>
- [164] W. Zhang, C. Li, G. Peng, Y. Chen & Z. Zhang. “A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load”. *Mech Syst Signal Process* 100:439–458, 2018.
- [165] S. Li, G. Liu, X. Tang, J. Lu & J. Hu. “An ensemble deep convolutional neural network model with improved D-S evidence fusion for bearing fault diagnosis”. *Sensors* 17:1729, 2017.
- [166] W. Qian, S. Li, J. Wang, Z. An & X. Jiang. “An intelligent fault diagnosis framework for raw vibration signals: Adaptive overlapping convolutional neural network,” *Meas. Sci. Technol.*, vol. 29, no. 9, Art. no. 095009, 2018.
- [167] J. Zhang, Y. Sun, L. Guo, H. Gao, X. Hong & H. Song. “A new bearing fault diagnosis method based on modified convolutional neural networks”. *Chinese Journal of Aeronautics*, Vol. 33, Issue 2, Pages 439-447, 2020.
- [168] H. Pan, X. He, S. Tang & F. Meng. “An Improved Bearing Fault Diagnosis Method using One-Dimensional CNN and LSTM”. *Journal of Mechanical Engineering*, 64 no, 1-10, 2018.
- [169] W. Mao, J. He, Y. Li & Y. Yan. “Bearing fault diagnosis with auto-encoder extreme learning machine: A comparative study”. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. 231(8):1560-1578, 2017. doi:10.1177/0954406216675896
- [170] Amarouayache, I.I.E., Saadi, M.N., Guersi, N. et al. Bearing fault diagnostics using EEMD processing and convolutional neural network methods. *Int J Adv Manuf Technol* 107, 4077–4095 (2020). <https://doi.org/10.1007/s00170-020-05315-9>
- [171] Amarouayache, I.I.E., Saadi, M.N., Guersi, N. Bearing Fault Diagnosis Method Based on Vibration Image and Convolutional Neural Network. Conference: Multi-Conference OCTA on: “Organization of Knowledge and Advanced Technologies.” Tunisia, 5-8 February 2020.

- [172] K. A. Loparo, “Case western reserve university bearing data center” [http://esegroups, case.edu/bearingdata-center/pages/12k-drive-end-bearing-fault-data](http://esegroups.case.edu/bearingdata-center/pages/12k-drive-end-bearing-fault-data). 2012.
- [173] P. Schober, C. Boer & L.A. Schwarte. “Correlation Coefficients”. *Anesthesia & Analgesia*, 126(5), 1763–1768, February 2018.
- [174] D. Verstraete, A. Ferrada, E.L. Droguett, V. Meruane, & M. Modarres. “Deep Learning Enabled Fault Diagnosis. Using Time-Frequency Image Analysis of Rolling Element Bearings”. *Shock and Vibration*, 1–17, October 2017.
- [175] J. Pan, Y. Zi, J. Chen, Z. Zhou, & B. Wang. “LiftingNet: A Novel Deep Learning Network With Layerwise Feature Learning From Noisy Mechanical Data for Fault Classification”. *IEEE Transactions on Industrial Electronics*, 65(6), 4973–4982, June 2018.
- [176] A.Zhang, S. Li, Y. Cui, W. Yang, R. Dong, J. Hu. “Limited Data Rolling Bearing Fault Diagnosis With Few-Shot Learning”. *IEEE Access*, vol. 7, August 2019.
- [177] W. Qian, S. Li, J. Wang, Z. An, & X. Jiang. “An intelligent fault diagnosis framework for raw vibration signals: adaptive overlapping convolutional neural network”. *Measurement Science and Technology*, 29(9), 095009, July 2018.
- [178] S. Haidong, J. Hongkai, L. Xingqiu, & W. Shuaipeng. “Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine”. *Knowledge-Based Systems*, 140, 1–14, October 2017.
- [179] H. Jiang, X. Li, H. Shao, & K. Zhao. “Intelligent fault diagnosis of rolling bearings using an improved deep recurrent neural network”. *Measurement Science and Technology*, vol. 29(6), March 2018.
- [180] S. Nandi, H. A. Toliyat, X. Li. “Condition monitoring and fault diagnosis of electrical motors—a review”. *IEEE Transact Energy Convers* 20(4):719–729, 2005.
- [181] F. Immovilli, M. Cocconcelli, A. Bellini, R. Rubini. “Detection of generalized-roughness bearing fault by spectral-kurtosis energy of vibration or current signals”. *IEEE Trans Ind Electron* 56(11):4710–4717, 2009.