

Ministère de l'enseignement Supérieur et de la recherche Scientifique

وزارة التعليم العالي والبحث العلمي

Badji Mokhtar Annaba University  
Université Badji Mokhtar – Annaba  
Faculté de Technologie  
Département d'électromécanique



جامعة باجي مختار – عنابة  
كلية التكنولوجيا  
قسم الالكتروميكانيك

## Thèse

Présentée pour obtenir le diplôme de

## Doctorat

Spécialité :

Filière : Electromécanique

Par :

**ZAIEM Kamar**

Thème :

## **Contribution à la surveillance des défaillances dans la transmission mécanique des systèmes industriels entraînés par un moteur triphasé à induction.**

Thèse soutenue le 17/12/2025 devant le jury composé de :

N°	Nom et prénom	Grade	Etablissement	Qualité
01	HADJADJ. Aouel Elyes	Prof.	Université Badji Mokhtar - Annaba	Président
02	RACHEDI Med Faouzi	Prof.	Université Badji Mokhtar - Annaba	Rapporteur
03	BOURAS Hichem	MCA	Université Badji Mokhtar - Annaba	Co-rapporteur
04	LAKEHAL Abdelaziz	Prof.	Université de Souk-Ahras	Examineur
05	SAHRAOUI Yacine	Prof.	Université de Souk-Ahras	Examineur
06	FARAH Lotfi	MCA	Université Badji Mokhtar - Annaba	Examineur

# *Dédicaces*

*“À mes chers parents, pour leur amour et leurs sacrifices,*

*À ma sœur, ma confidente et mon alliée,*

*À mon mari, pour avoir toujours été à mes côtés, m’apportant son soutien et son aide avec générosité,*

*Et à toute ma famille, pour leur présence et leurs encouragements.”*

# Remerciements

Avant tout, je remercie Dieu, le Tout-Puissant, de m'avoir donné le courage, la patience et la force durant toutes ces années d'études, et grâce à qui ce travail a pu être réalisé.

Au terme de ce travail doctoral, je tiens à exprimer ma plus profonde gratitude à toutes les personnes et institutions qui ont, de près ou de loin, contribué à la réalisation de cette thèse. Cette aventure scientifique, humaine et intellectuelle n'aurait pu voir le jour sans l'accompagnement bienveillant, la confiance renouvelée et les échanges fructueux qui ont jalonné ces années.

Je tiens à remercier sincèrement Docteur Hichem BOURAS, mon Co-encadrant, pour sa présence constante, son accompagnement précieux tout au long de la thèse, et son aide précieuse dans les aspects administratifs parfois complexes. Son soutien m'a beaucoup aidé à garder le cap dans les moments difficiles.

Un grand merci également à Professeur Mohamed Faouzi RACHEDI pour sa confiance et son implication, notamment dans la finalisation des articles. Son regard critique et ses conseils avisés ont été essentiels pour faire avancer ce travail.

Je n'oublie pas le laboratoire des Systèmes Électromécaniques de l'Université Badji Mokhtar – Annaba, qui m'a accueilli avec générosité et m'a offert un environnement de travail très stimulant. Merci aussi au Département d'Électromécanique pour son appui quotidien et la qualité de ses services.

Je remercie également les membres du jury pour avoir accepté de faire partie de mon jury de soutenance. Leur présence et le temps qu'ils consacrent à l'évaluation de ce travail sont pour moi un honneur et une marque d'intérêt précieuse.

À tous ceux qui ont, d'une manière ou d'une autre, contribué à cette aventure, je suis profondément reconnaissant.

## Résumé

Dans un contexte industriel où la fiabilité des transmissions mécaniques conditionne directement la performance globale des systèmes, ce travail s'inscrit dans une démarche de renforcement des capacités de diagnostic et de maintenance prédictive (PHM) face à la complexité croissante des défauts rencontrés. L'objectif est de développer une approche méthodologique innovante, robuste et interprétable, capable d'identifier et d'isoler des défauts multiples et simultanés affectant conjointement les engrenages, les arbres de transmission et les roulements. Ces défauts, souvent imbriqués et difficilement séparables dans les signaux vibratoires, posent un défi important pour les systèmes de surveillance classiques.

En combinant une décomposition adaptative du signal (type CEEMDAN) à des réseaux de neurones convolutifs bayésiens (BCNN) structurés en branches spécialisées, cette étude propose un cadre hybride permettant d'extraire les signatures dynamiques pertinentes tout en quantifiant l'incertitude associée à chaque décision. L'approche met l'accent sur l'adaptabilité, la transparence algorithmique et la capacité à fonctionner dans des environnements industriels bruités et contraints. Validé sur un banc d'essai représentatif à travers le jeu de données PHM 2009, ce modèle montre des performances prometteuses pour le suivi intelligent des systèmes de transmission soumis à des scénarios de dégradation complexes. Ce travail ouvre ainsi la voie à des solutions de PHM de nouvelle génération, alliant rigueur scientifique, interprétabilité et applicabilité industrielle.

**Mots clés :** Réseau Neuronal de Convolution Bayésien. Traitement empirique des signaux. Diagnostic des défauts composés. Boîte de vitesses. Défaillance de la transmission mécanique.

## Abstract

In an industrial landscape where the reliability of mechanical transmission systems directly impacts global performance and operational continuity, this work aims to strengthen fault diagnosis and predictive maintenance (PHM) capabilities in the face of increasingly complex degradation phenomena. The central objective is to develop an innovative, robust, and interpretable framework capable of identifying and isolating multiple, simultaneous faults that may simultaneously affect gears, shafts, and bearings. These types of failures often overlap and remain difficult to distinguish in real-world vibration signals, posing significant challenges for traditional monitoring techniques.

By combining adaptive signal decomposition methods such as CEEMDAN with a multi-branch Bayesian Convolutional Neural Network (BCNN) architecture, this study proposes a hybrid approach that not only extracts meaningful dynamic patterns from raw data but also provides a probabilistic estimate of decision confidence. The method emphasizes adaptability, algorithmic transparency, and practical feasibility in noisy and constrained industrial environments. Validated on a representative experimental platform using the PHM 2009 Gearbox dataset, the proposed model demonstrates promising performance in detecting and characterizing complex fault scenarios in rotating machinery. This research opens the door to

a new generation of PHM solutions, ones that are scientifically rigorous, interpretable by design, and truly deployable in the field.

**Keywords:** Bayesian Convolution Neural Network. Empirical signal processing. Compound fault diagnosis. Gearbox. Mechanical transmission failure.

## المخلص

في سياقٍ صناعيٍّ تُحدّد فيه موثوقيّة أنظمة النقل الميكانيكي بشكلٍ مباشر الأداء العام للأنظمة، يندرج هذا العمل ضمن مسعى تعزيز قدرات التشخيص والصيانة التنبؤية (PHM) في مواجهة التعقيد المتزايد للأعطال المكتشفة. ويهدف هذا البحث إلى تطوير مقاربة منهجية مبتكرة، قوية وقابلة للتفسير، قادرة على تحديد الأعطال المتعددة والمتزامنة وعزلها، والتي تؤثر في آنٍ واحد على التروس، ومحاور النقل، والمحامل.

تعد هذه الأعطال، التي غالباً ما تكون متداخلة وصعبة الفصل داخل إشارات الاهتزاز، تحدياً رئيسياً لأنظمة المراقبة التقليدية. ومن خلال الجمع بين تقنيات التفكير التكيفي للإشارات، من نوع (CEEMDAN)، وشبكات عصبونية التفاضلية بايزية (BCNN) منظمة في فروع متخصصة، تقترح هذه الدراسة إطاراً هجيناً يسمح باستخلاص التوقعات الديناميكية ذات الصلة، مع تقدير عدم اليقين المرتبط بكل قرار تشخيصي.

تركز المقاربة المقترحة على القابلية للتكيف، والشفافية الخوارزمية، والقدرة على العمل في البيئات الصناعية المليئة بالضجيج والقيود التشغيلية. وقد تم التحقق من صحة هذا النموذج على منصة اختبار تمثيلية باستخدام مجموعة بيانات (PHM 2009)، حيث أظهر أداءً واعدًا في المراقبة الذكية لأنظمة النقل الخاضعة لسيناريوهات تدهور معقّدة. ويفتح هذا العمل آفاقاً جديدة نحو حلول صيانة تنبؤية من الجيل الجديد، تجمع بين الصرامة العلمية، وقابلية التفسير، وإمكانية التطبيق الصناعي.

## الكلمات المفتاحية:

الشبكات العصبية التفاضلية البايزية، المعالجة التجريبية للإشارات، تشخيص الأعطال المركبة، علب التروس، فشل أنظمة النقل الميكانيكي.

# Table des matières

<b>Table des matières</b> .....	v
<b>Liste des figures</b> .....	x
<b>Liste des tableaux</b> .....	xii
<b>Introduction générale</b> .....	1
<b>Synthèse bibliographique</b> .....	4
<b>Chapitre I : Généralités sur la surveillance des transmissions mécanique.</b>	
<b>I.1 Introduction</b> .....	16
<b>I.2 Moteur triphasé à induction</b> .....	16
<b>I.2.1 Définition du moteur</b> .....	16
<b>I.2.2 Principe de fonctionnement</b> .....	17
<b>I.2.3 Choix du moteur (application)</b> .....	17
<b>I.3 Transmissions mécaniques</b> .....	17
<b>I.3.1 Principales défaillances des transmissions mécaniques</b> .....	18
<b>I.3.1.1 Défauts de roulements</b> .....	18
<b>I.3.1.2 Défauts d'engrenages</b> .....	21
<b>I.3.1.3 Défauts de courrois</b> .....	22
<b>I.3.1.4 Défauts de balourd</b> .....	25
<b>I.3.1.5 Défaut d'alignement</b> .....	26
<b>I.4 La maintenance industriel</b> .....	26
<b>I.4.1 La maintenance corrective</b> .....	27
<b>I.4.2 La maintenance préventive</b> .....	27
<b>I.5 Méthodologie de diagnostic</b> .....	28
<b>I.6 Méthodes de surveillance</b> .....	29
<b>I.6.1 Analyse d'huile</b> .....	29
<b>I.6.2 Analyse thermique</b> .....	29
<b>I.6.3 Analyse vibratoire</b> .....	30
<b>I.7 Méthodes d'analyse</b> .....	31
<b>I.7.1 Analyse temporelle</b> .....	31
<b>I.7.2 Analyse fréquentielle</b> .....	32
<b>I.7.2.1 Analyse spectrale</b> .....	33
<b>I.7.2.2 Analyse cepstrale</b> .....	34
<b>I.7.2.3 Analyse d'enveloppe</b> .....	34

---

I.7.3 Analyse temps-fréquence.....	34
<b>I.8 Méthodes de diagnostic .....</b>	<b>36</b>
I.8.1 Méthodes de diagnostic à base de modèles .....	37
I.8.2 Méthode de diagnostic à base de données.....	37
<b>I.9 Conclusion .....</b>	<b>38</b>
<b>II.1 Introduction .....</b>	<b>40</b>
<b>II.2 La classification intelligente de défauts .....</b>	<b>40</b>
<b>II.3 Intelligence artificielle (IA).....</b>	<b>40</b>
<b>II.4 Apprentissage automatique (ML).....</b>	<b>41</b>
II.4.1 Apprentissage supervisé.....	42
II.4.2 Apprentissage non supervisé .....	43
II.4.3 Apprentissage par renforcement .....	43
II.4.4 Comparaison des différents types d'apprentissage automatique.....	44
II.4.5 Les techniques de classification supervisée .....	45
II.4.5.1 Machines à vecteurs de support (SVM).....	45
II.4.5.2 Arbre et forêt de décision .....	46
II.4.5.3 L'algorithme des K-voisins les plus proches (KNN) .....	47
<b>II.5 Les réseaux de neurones artificiels (ANN).....</b>	<b>48</b>
II.5.1 Entraînement d'un réseau de neurone .....	51
II.5.2 Les différents types de réseaux de neurones .....	52
II.5.2.1 Perceptron Multicouche.....	53
II.5.2.2 Réseau à Fonction Radiale.....	53
II.5.2.3 Réseaux de Neurones Probabilistes .....	54
II.5.2.4 Réseau de neurone bayésien .....	56
<b>II.6 Apprentissage profond.....</b>	<b>58</b>
II.6.1 Les réseaux de neurones récurrents .....	59
II.6.2 Réseaux neuronaux convolutifs.....	60
II.6.3 Réseau Neuronal Convolutionnel Bayésien (BCNN).....	63
II.6.3.1 Architecture typique d'un réseau convolutionnel bayésien.....	64
II.6.3.2 Extension bayésienne des réseaux de neurones convolutifs.....	66
II.6.3.3 Méthodes d'inférence approximative en BCNN .....	68
<b>II.7 Conclusion.....</b>	<b>71</b>
<b>III.1 Introduction.....</b>	<b>73</b>
<b>III.2 Décomposition en mode empirique (EMD) : un outil de décomposition adaptatif aux signaux.....</b>	<b>74</b>

---

III.2.1 Bases mathématiques.....	74
<b>III.3 Décomposition en Mode Empirique par Ensemble (EEMD) : Une amélioration robuste contre le mélange de modes .....</b>	<b>75</b>
III.3.1 Bases mathématiques.....	76
III.3.2 Les avantages .....	76
III.3.3 Les limites .....	77
<b>III.4 Décomposition Complète en Mode Empirique par Ensemble (CEEMD) : Vers une reconstruction fidèle du signal .....</b>	<b>77</b>
III.4.1 Bases mathématiques.....	78
III.4.2 Les avantages .....	78
III.4.3 Les limites .....	78
<b>III.5 CEEMDAN – Décomposition Complète par Ensemble avec Bruit Adaptatif : Précision et stabilité dans la séparation fréquentielle.....</b>	<b>79</b>
III.5.1 Bases mathématiques.....	80
III.5.2 Les avantages .....	80
III.5.3 Les limites .....	81
<b>III.6 Comparaison théorique des méthodes EMD et dérivées.....</b>	<b>81</b>
<b>III.7 Étude comparative des méthodes EMD, EEMD, CEEMD et CEEMDAN pour le diagnostic de défauts .....</b>	<b>83</b>
III.7.1 Description du Signal .....	83
III.7.2 Résultats de Décomposition et Observations Qualitatives .....	84
III.7.3 Évaluation Quantitative des Performances .....	87
<b>III.8 Intégration d'un classificateur : De la décomposition CEEMDAN vers les BCNN.....</b>	<b>87</b>
<b>III.8.1 Architecture du classificateur bayésien basé sur l'inférence variationnelle : formulation et comparaison.....</b>	<b>88</b>
III.8.1.1 Formulation mathématique de l'entraînement variationnel.....	89
III.8.1.2 Comparaison conceptuelle avec Monte Carlo Dropout.....	89
III.8.1.3 Entraînement du Bayesian CNN : procédures, réglages et validation.....	91
III.8.1.4 Inférence bayésienne : agrégation des prédictions et quantification de l'incertitude .....	92
III.8.1.5 Evaluation des performances du BCNN : précision et calibration des incertitudes.....	92
III.8.1.6 Choix de l'architecture du classificateur BCNN .....	93
III.8.1.7 Justification de la comparaison des architectures et introduction des jeux de données .....	94
<b>III.9 Introduction Présentation du jeu de données.....</b>	<b>95</b>
III.9.1 Présentation du jeu de données CWRU (Case Western Reserve University) .....	95
III.9.2 Présentation du jeu de données PU (Paderborn University) .....	96

---

<b>III.10 Comparaison des méthodes de diagnostics</b> .....	97
<b>III.10.1 Comparaison des méthodes EMD, EEMD, CEEMD et CEEMDAN pour la pré-analyse des signaux vibratoires</b> .....	99
<b>III.10.2 Comparaison entre CNN et BCNN appliqués aux signaux CEEMDAN</b> .....	100
<b>III.11 Conclusion</b> .....	103
<b>IV.1 Introduction</b> .....	106
<b>IV.2 Complexité des défauts dans les engrenages : une analyse approfondie à partir du jeu de données PHM 2009</b> .....	107
<b>IV.2.1 Taxonomie des défauts rencontrés</b> .....	107
<b>IV.2.2 Origine physique et signature vibratoire des défauts</b> .....	109
<b>IV.2.3 Difficultés liées à l'isolement des défauts dans les systèmes d'engrenages</b> .....	111
<b>IV.2.4 Visualisation des signaux vibratoires bruts et justification de l'approche retenue</b> ....	112
<b>IV.3 Étude de sensibilité aux paramètres de la décomposition CEEMDAN</b> .....	114
<b>IV.3.1 Objectifs et méthodologie</b> .....	115
<b>IV.3.2 Résultats de décomposition</b> .....	116
<b>IV.3.3 Évaluation quantitative</b> .....	117
<b>IV.3.4 Impact sur la classification BCNN</b> .....	118
<b>IV.4 Comparaison avec d'autres techniques de décomposition de signaux</b> .....	120
<b>IV.4.1 Protocole expérimental et résultats de comparaison</b> .....	121
<b>IV.5 Comparaison entre architectures monolithique et multi-branche</b> .....	124
<b>IV.5.1 Objectif : aller au-delà de la simple classification multi-classe</b> .....	125
<b>IV.5.2 Implémentation de l'architecture multi-branche spécialisée</b> .....	126
<b>IV.5.3 Comparaison entre architectures monolithiques et multi-branche (CNN vs BCNN)</b> ..	128
<b>IV.6 Analyse de la quantification de l'incertitude</b> .....	132
<b>IV.6.1 Types d'incertitude considérés</b> .....	133
<b>IV.6.1.1 L'incertitude épistémique (modélisation)</b> .....	133
<b>IV.6.1.2 L'incertitude aléatoire (intrinsèque ou observationnelle)</b> .....	133
<b>IV.6.1.3 Extraction par échantillonnage stochastique</b> .....	133
<b>IV.6.2 Résultats expérimentaux</b> .....	134
<b>IV.7 Identification des erreurs et défauts non vus</b> .....	136
<b>IV.7.1 Corrélation entre incertitude et erreur de classification</b> .....	136
<b>IV.7.2 Détection des défauts hors distribution (OOD)</b> .....	137
<b>IV.7.3 Seuils de confiance et stratégie de décision</b> .....	137
<b>IV.8 Interprétabilité avancée des prédictions</b> .....	138
<b>IV.8.1 Cartes de saillance (Saliency Maps)</b> .....	139
<b>IV.8.2 Interprétabilité locale avec SHAP et LIME</b> .....	139

<b>IV.8.2.1 SHAP – SHapley Additive exPlanations .....</b>	<b>140</b>
<b>IV.8.2.2 LIME – Local Interpretable Model-Agnostic Explanations .....</b>	<b>141</b>
<b>IV.8.3 Bénéfices pour l’adoption industrielle.....</b>	<b>142</b>
<b>IV.9 Limitations et perspectives d’amélioration.....</b>	<b>143</b>
<b>IV.10 Conclusion .....</b>	<b>144</b>
<b>Conclusion générale .....</b>	<b>146</b>
<b>Bibliographie.....</b>	<b>152</b>

## Liste des figures

### Chapitre I : Généralités sur la surveillance des transmissions mécanique.

<b>Figure I. 1</b> Moteur triphasé à induction.....	16
<b>Figure I. 2</b> Les composants d'un roulement.....	19
<b>Figure I. 3</b> Les principaux types de roulements.....	19
<b>Figure I. 4</b> Exemples des avaries affectant les roulements.....	20
<b>Figure I. 5</b> Les défauts de roulement.....	20
<b>Figure I. 6</b> Les types d'engrenages.....	21
<b>Figure I. 7</b> Défauts d'engrenages : usure, pique.....	22
<b>Figure I. 8</b> Défauts d'engrenages : rupture de dent, écaillage, grippage, fissure.....	22
<b>Figure I. 9</b> Système de transmission par courroie.....	22
<b>Figure I. 10</b> Différents types de courroies.....	23
<b>Figure I. 11</b> Défaut de balourd.....	25
<b>Figure I. 12</b> Principaux défauts d'alignement.....	26
<b>Figure I. 13</b> Les différents types de maintenance.....	27
<b>Figure I. 14</b> Méthodologie du diagnostic.....	28
<b>Figure I. 15</b> Les différents techniques de la surveillance des machines tournantes.....	29
<b>Figure I. 16</b> Analyse des lubrifiants.....	29
<b>Figure I. 17</b> Thermographie infrarouge.....	30
<b>Figure I. 18</b> Chaîne de mesure de l'analyse vibratoire.....	30
<b>Figure I. 19</b> Différentes étapes du diagnostic des défauts.....	36

### Chapitre II : Méthode de classification pour le diagnostic des défauts.

<b>Figure II. 1</b> Les domaines de l'intelligence artificiel.....	41
<b>Figure II. 2</b> Les différents types d'apprentissage automatique.....	42
<b>Figure II. 3</b> Apprentissage supervisé.....	42
<b>Figure II. 4</b> Apprentissage non supervisé.....	43
<b>Figure II. 5</b> Apprentissage par renforcement.....	44
<b>Figure II. 6</b> Machines à vecteurs de support pour la classification binaire.....	46
<b>Figure II. 7</b> Arbre de décision.....	47
<b>Figure II. 8</b> Forêt d'arbre décisionnel.....	47
<b>Figure II. 9</b> Fonctionnement de l'algorithme KNN.....	48
<b>Figure II. 10</b> Schéma d'un réseau de neurone artificiel.....	49
<b>Figure II. 11</b> Modèle d'un neurone artificiel.....	50
<b>Figure II. 12</b> Entraînement d'un réseau de neurone.....	51
<b>Figure II. 13</b> Perceptron multicouche.....	53
<b>Figure II. 14</b> Réseau à fonction de base radiale (RBF).....	54
<b>Figure II. 15</b> Illustration d'un réseau neuronal probabiliste.....	55
<b>Figure II. 16</b> Comparaison entre un réseau neuronal standard et un réseau neuronal bayésien.....	56
<b>Figure II. 17</b> Machine Learning vs Deep Learning : Processus comparé.....	58
<b>Figure II. 18</b> L'impact des données sur les performances des modèles d'IA.....	59

<b>Figure II. 19</b> RNN et sa version dépliée dans le temps. ....	59
<b>Figure II. 20</b> Illustration de l'architecture des CNN. ....	61
<b>Figure II. 21</b> Différence entre CNN et BCNN. (a) : CNN avec des valeurs fixes des paramètres neuronaux ; (b) : BCNN avec des distributions de probabilités indépendantes des paramètres neuronaux. ....	64
<b>Figure II. 22</b> L'architecture d'un réseau convolutionnel bayésien (BCNN). ....	65

**Chapitre III : Vers un diagnostic interprétable : l'utilisation de CEEMDAN avec les réseaux neuronaux bayésiens.**

<b>Figure III. 1</b> Illustration de l'algorithme de l'EMD. ....	75
<b>Figure III. 2</b> Illustration de l'algorithme de l'EEMD. ....	77
<b>Figure III. 3</b> Illustration de l'algorithme de l'CEEMD. ....	79
<b>Figure III. 4</b> Illustration de l'algorithme de l'CEEMDAN. ....	81
<b>Figure III. 5</b> Illustration des IMFs des méthodes : (A) : EMD, (B) : EEMD, (C) : CEEMD, (D) : CEEMDAN. ....	85
<b>Figure III. 6</b> Illustration du spectre de Hilbert de pour les méthodes : (A) : EMD, (B) : EEMD, (C) : CEEMD, (D) : CEEMDAN. ....	86
<b>Figure III. 7</b> Illustration d'un réseau de neurones BCNN. ....	91
<b>Figure III. 8</b> Architecture de BCNN utilisée pour cette étude. ....	94
<b>Figure III. 9</b> Architecture générale de la méthode de diagnostic étudiée. ....	99
<b>Figure III. 10</b> Illustration des matrices de confusions : (A) : CNN+ CWRU, (B) : BCNN+CWRU, (C) : CNN+PU, (D) : BCNN+PU. ....	102

**Chapitre IV : Diagnostic spécialisé des défauts par BCNN multi-branche et CEEMDAN.**

<b>Figure IV. 1</b> Schéma de la chaine de transmission du banc d'essai PHM2009. ....	111
<b>Figure IV. 2</b> Photographie du banc d'essai utilise pour le jeu de données PHM2009. ....	112
<b>Figure IV. 3</b> Signaux temporels bruts (PHM2009). ....	113
<b>Figure IV. 4</b> Densité spectrale de puissance (PHM2009). ....	114
<b>Figure IV. 5</b> Des IMFs extraits selon les configurations CEEMDAN (N, $\epsilon$ ). ....	117
<b>Figure IV. 6</b> Impact des paramètres CEEMDAN sur le F1-score et l'incertitude du BCNN. ....	119
<b>Figure IV. 7</b> Performance et incertitude par méthode de décomposition. ....	123
<b>Figure IV. 8</b> Structure général d'un BCNN-MB. ....	127
<b>Figure IV. 9</b> Matrice de confusion : (A) : CEEMDAN avec CNN multi-branche; (B) : CEEMDAN avec BCNN multi-branche. ....	129
<b>Figure IV. 10</b> Evolution de la perte en validation (training convergence). ....	131
<b>Figure IV. 11</b> Heatmaps des activations : comparaison monolithique VS branche spécialisée. ....	132
<b>Figure IV. 12</b> Distribution des incertitudes épistémiques par classe (Boxplot). ....	135
<b>Figure IV. 13</b> Heatmap des incertitudes sur un signal a défauts composes. ....	135
<b>Figure IV. 14</b> Partition de l'incertitude selon les cas d'erreur. ....	136
<b>Figure IV. 15</b> Distribution de l'incertitude : échantillons vus VS hors distribution. ....	137
<b>Figure IV. 16</b> Carte de saillance sur une IMF (défaut de dent ébréchée). ....	139
<b>Figure IV. 17</b> Contribution des IMFs a la prédiction (SHAP). ....	140
<b>Figure IV. 18</b> Interprétation locale LIME d'une prédiction de défaut. ....	142

## Liste des tableaux

### Chapitre I : Généralités sur la surveillance des transmissions mécanique.

<b>Tableau I. 1</b> Localisation des défauts dans la transmission de puissance. ....	18
<b>Tableau I. 2</b> Causes des différents types de défauts d'un roulement. ....	20
<b>Tableau I. 3</b> Les types des défaillances des courroies. ....	24
<b>Tableau I. 4</b> Les différents types de balourd. ....	25
<b>Tableau I. 5</b> Fréquences caractéristiques des défauts. ....	33

### Chapitre II : Méthode de classification pour le diagnostic des défauts.

<b>Tableau II. 1</b> Les trois principaux types de l'apprentissage automatique. ....	44
<b>Tableau II. 2</b> Différents types de fonctions d'activations. ....	51

### Chapitre III : Vers un diagnostic interprétable : l'utilisation de CEEMDAN avec les réseaux neuronaux bayésiens.

<b>Tableau III. 1</b> Comparaison théorique des méthodes empiriques. ....	83
<b>Tableau III. 2</b> Tableau comparatif de méthodes empiriques de traitement des signaux. ....	87
<b>Tableau III. 3</b> Tableau comparatif de méthodes bayésiennes. ....	90
<b>Tableau III. 4</b> Tableau des classes de défauts sélectionnées pour la base de données CWRU. ....	96
<b>Tableau III. 5</b> Tableau des classes de défauts sélectionnées pour la base de données PU. ....	97
<b>Tableau III. 6</b> Résultats sur le jeu CWRU. ....	100
<b>Tableau III. 7</b> Résultats sur le jeu PU (5 classes). ....	100
<b>Tableau III. 8</b> Comparaison par rapport au jeu de donnée CWRU. ....	101
<b>Tableau III. 9</b> Comparaison par rapport au jeu de donnée PU (5 classes). ....	101

### Chapitre IV : Diagnostic spécialisé des défauts par BCNN multi-branche et CEEMDAN.

<b>Tableau IV. 1</b> Récapitulatif des cas de défaillance de l'ensemble de données PHM 2009. ....	109
<b>Tableau IV. 2</b> Erreur de reconstruction (RMSE) et corrélation pour différentes configurations CEEMDAN. ....	118
<b>Tableau IV. 3</b> Performances de classification BCNN selon les configurations CEEMDAN. ....	119
<b>Tableau IV. 4</b> Comparaison des méthodes de décomposition. ....	122
<b>Tableau IV. 5</b> Architecture du réseau multi-branches. ....	128
<b>Tableau IV. 6</b> Comparaison des résultats du réseau monolithique et multi-branches CNN vs BCNN. ....	130

## INTRODUCTION GÉNÉRALE

**D**ans un environnement industriel en constante évolution, la fiabilité et la disponibilité des équipements de production représentent des enjeux cruciaux pour assurer la compétitivité et la durabilité des systèmes de fabrication. Les moteurs électriques à induction triphasés figurent parmi les équipements les plus essentiels dans de nombreuses installations industrielles. Ils sont principalement employés pour entraîner divers mécanismes de transmission, tels que les réducteurs, les courroies, les arbres de transmission ou les engrenages. Cependant, le fonctionnement optimal de ces organes peut être altéré par l'émergence progressive de défaillances, souvent indétectables à un stade précoce, mais susceptibles de provoquer des interruptions de production onéreuses, voire des dommages irréversibles. Un simple défaut peut provoquer une série de dysfonctionnements dans le système de transmission, entraînant l'interruption de la production et occasionnant des dommages aux équipements et aux individus. Ces défauts multiples, ou combinés, peuvent dissimuler les symptômes individuels, rendant leur détection d'autant plus ardue. Il est alors impératif d'implémenter des techniques de surveillance avancées, aptes à différencier les signatures distinctives de défauts isolés et de défauts couplés, afin de garantir une maintenance prédictive efficace, de réduire les coûts d'entretien et d'assurer la disponibilité ainsi que la continuité opérationnelle dans des conditions optimales. Parmi les instruments de la maintenance prédictive, l'analyse vibratoire se distingue par son développement significatif, attribuable aux avancées technologiques dans le domaine de traitement de signal.

Les techniques de surveillance fondées sur l'analyse vibratoire cherchent à examiner les caractéristiques physiques présentes dans les signaux de vibration recueillis, où le défi du diagnostic réside dans la capacité à classer avec précision le signal vibratoire obtenu dans l'état adéquat, notamment en cas de défauts combinés, ce qui constitue généralement un problème de classification multi-classe. Il est essentiel de concevoir de nouvelles méthodes de surveillance, capables non seulement d'effectuer une détection et une identification précises des états de santé des machines, mais également de fournir une estimation de confiance pour chaque prédiction et d'assurer une détection précoce et précise des défauts.

L'objectif principal de ce travail de recherche est de développer une approche innovante et fiable pour le diagnostic automatique des défauts combinés dans les systèmes de transmission mécanique complexes. En combinant des techniques avancées de traitement du signal et des méthodes d'intelligence artificielle probabiliste, ce manuscrit vise à concevoir un outil capable de détecter, classifier et interpréter des anomalies mécaniques dans des environnements réels, souvent bruités et soumis à des conditions variables. L'accent est mis sur la robustesse, l'interprétabilité et l'adaptabilité du modèle proposé, afin de répondre aux exigences croissantes de la maintenance prédictive (PHM) dans le cadre de l'industrie 4.0. Ce travail s'inscrit ainsi dans une démarche à la fois scientifique et appliquée, orientée vers des solutions concrètes pour la surveillance intelligente des systèmes électromécaniques.

La structure du travail est la suivante :

Initialement, il est courant de débiter par une synthèse de la littérature afin d'explorer diverses applications dans le domaine de la détection et du diagnostic des anomalies affectant les machines tournantes, en particulier la boîte de vitesses.

Par la suite, cette étude structurée en quatre chapitres, qui couvrent les travaux réalisés.

Le premier chapitre s'ouvre sur une généralité au domaine des systèmes de transmission mécanique, abordant leurs principales défaillances ainsi que les stratégies et les techniques utilisées pour leur surveillance.

Le deuxième chapitre est consacré à la description de la procédure d'un système intelligent de classification et de diagnostic des défauts, qui fait appel aux outils de l'intelligence artificielle dans le domaine du diagnostic des machines tournantes. Une attention particulière est accordée à l'apprentissage profond, notamment aux réseaux de neurones convolutifs bayésiens (BCNN).

Le chapitre trois se divise en deux parties : la première consiste en une analyse comparative des méthodes empiriques de traitement du signal EMD et ses dérivés. La seconde partie de l'étude consiste à fusionner le CEEMDAN avec le classificateur BCNN en utilisant deux bases de données vibratoires réelles, à savoir la base CWRU (Case Western Reserve University) et la base PU (Paderborn University). Cette fusion sera ensuite comparée aux réseaux de neurones convolutifs (CNN) afin de garantir la validité externe des résultats.

Dans le chapitre final, nous présentons une analyse détaillée d'une méthode novatrice utilisant l'architecture Bayésienne Convolutionnelle Multi-branche (BCNN-MB), associée à une décomposition CEEMDAN, pour le diagnostic avancé des défauts combinés : les engrenages, les paliers et l'arbre d'une boîte de vitesse complexe, en se basant sur l'ensemble de données PHM2009.

Les recherches effectuées dans le cadre de cette thèse se présentent comme suit :

### **Article de revue :**

K. Zaiem, H. Bouras, et M. F. Rachedi, « Bayesian convolution neural network for mechanical transmission fault diagnosis with empirical signal processing », *J. Mech. Sci. Technol.*, mai 2025, <http://doi.org/10.1007/s12206-025-0512-y>.

### **Les conférences :**

1. K. Zaiem, H. Bouras, et M. F. Rachedi, "Comparison Of Empirical Signal Processing Methods For Bearing Fault Diagnosis", 2nd International Mediterranean Scientific Research and Innovation Congress, 30-31 July 2022/ kktc-girne.
2. K. Zaiem, H. Bouras, et M. F. Rachedi, "A GEAR FAULT DIAGNOSIS USING A COMPARISON OF EMPIRICAL SIGNAL TECHNIQUES WITH ANFIS", 8th International Black Sea Coastline Countries Scientific Research Conference, held on August 29-30, 2022 / Sofia, Bulgaria.

3. K. Zaiem, H. Bouras, et M. F. Rachedi, “BEARING FAULT DIAGNOSIS INVESTIGATION WITH THE USE OF DIFFERENT EMPIRICAL SIGNAL PROCESSING METHODS”, 7th International New York Conference On Evolving Trends In Interdisciplinary Research & Practices, October 1-3, 2022 / Manhattan, New York City.
4. K. Zaiem, H. Bouras, et M. F. Rachedi, “FAULT DIAGNOSIS METHOD OF ROLLING BEARINGS BASED ON CEEMDAN-NNs BY USING VIBRATION SIGNAL”, 7th Asia Pacific International Modern Sciences Congress, held on November 4-5, 2022 / Jakarta, Indonesia.
5. K. Zaiem, H. Bouras, et M. F. Rachedi, “Fault diagnosis method of spur gear based on CEEMDAN and Neural Networks”, 4th International Conference on Applied Engineering and Natural Sciences, on 10-13 November in 2022 at Konya/Turkey.

## Synthèse bibliographique

Le secteur de l'industrie bénéficie de machines et d'installations de plus en plus complexes et performantes. La maintenance des systèmes joue un rôle crucial en raison des exigences élevées en matière de sécurité, de la nécessité de réduire les coûts d'exploitation et de garantir la disponibilité des équipements. Les systèmes de transmission mécanique revêtent une importance capitale pour assurer le bon fonctionnement des équipements industriels [1]. Ils sont responsables de la transmission du mouvement et de la puissance entre les diverses composantes d'un mécanisme, ce qui assure la performance et l'efficacité des machines. Un simple défaut dans un composant de transmission, tel qu'un balourd [2], désalignement [3], un engrenage défectueux [4] ou une courroie usée [5], a la capacité de provoquer une série de pannes qui impactent la performance, la fiabilité et la durabilité du système lorsqu'elles ne sont pas identifiées précocement. Elles peuvent aussi entraîner une consommation excessive d'énergie, des interruptions de production et des coûts de maintenance élevés. C'est pourquoi il est crucial de surveiller et diagnostiquer les composants de transmission afin d'éviter toute dégradation progressive et garantir le bon fonctionnement des équipements industriels.

Les boîtes de vitesses, en tant que composants essentiels des systèmes de transmission, sont largement intégrées dans les dispositifs mécaniques modernes en tant qu'éléments fondamentaux de la transmission permettant le changement de vitesse et la transmission de puissance. Constitué d'engrenages, de roulements et d'arbres d'entraînement qui forment un système complexe. En règle générale, les boîtes de vitesses opèrent en continu dans le système de production, ce qui explique que les pannes des boîtes de vitesses constituent 78% de l'ensemble des pannes, entraînant des pertes financières importantes pour l'entreprise ou des accidents du travail graves. Ainsi, il est crucial d'effectuer un diagnostic prédictif des défaillances des boîtes de vitesses afin de détecter de manière efficace le mode de défaillances potentiel du système de transmission avant toute occurrence d'accident, est essentiel pour réaliser des économies, assurer un fonctionnement fiable et améliorer l'efficacité du système mécanique [6].

Au fil du temps, diverses méthodes de diagnostic ont été mises en œuvre pour surveiller l'état des boîtes de vitesses, notamment les techniques basées sur les vibrations [7], le courant [8], les émissions acoustiques [9], l'analyse de l'huile [10] et la thermographie infrarouge [11]. L'analyse vibratoire est largement reconnue comme la méthode la plus efficace pour évaluer l'état de fonctionnement d'une machine. Plus de 75% des méthodes de diagnostic de pannes sont effectuées en utilisant l'analyse vibratoire [12]. Les signaux de vibration se sont révélés être un outil efficace pour diagnostiquer l'état de santé des machines en rotation. En ce qui a trait aux diagnostics des défauts des boîtes de vitesses basés sur les vibrations, Setti et al [13] ont mis en lumière l'analyse vibratoire pour diagnostiquer les défauts de la boîte de vitesses d'une turbine éolienne entre l'état sain et l'état de la dent cassée avec une charge variable, en mettant l'accent sur le domaine temporel, ils ont décomposé le signal discret en une série de

coefficients de détail et d'approximation à l'aide de filtres adaptés, séparant les hautes et basses fréquences. Mukherjee et al [14] ont exposé une méthode pour examiner les défauts des boîtes de vitesse afin d'analyser les caractéristiques non stationnaires du signal de vibration brut, cette démarche d'investigation est appuyée par l'utilisation de trois états distincts de boîte de vitesses (saine, endommagée et manquante), chacun soumis à trois vitesses et à des charges d'excitation variées. L'objectif de Xue et Howard [15] est d'analyser l'efficacité de l'intégration du signal de vibration de torsion à l'intérieur d'un bras porteur en tant qu'outil de diagnostic pour détecter les défauts des réducteurs planétaires.

En général, les pannes les plus courantes des composants de la boîte de vitesses sont l'ébréchées des dents d'engrenage, les fissures à la base des dents, les piqûres sur les bagues des roulements, le déséquilibre des arbres d'entraînement, etc. Une défaillance peut induire une autre, engendrant ainsi une faute composée, qui se caractérise par la présence simultanée de plusieurs défauts au sein d'une transmission mécanique. Cependant, les caractéristiques des défauts les plus intenses peuvent facilement couvrir les informations des caractéristiques faibles. En outre, en raison de la complexité des voies de transmission des signaux, les vibrations des diverses défaillances s'influencent mutuellement, ce qui aggrave les phénomènes de couplage et de modulation. [16]. L'analyse des vibrations se divise principalement en trois approches qui font appel à des méthodes de traitement du signal : l'analyse temporelle, l'analyse fréquentielle et l'analyse temps-fréquence. Les techniques utilisées dans le domaine temporel comprennent la moyenne synchronisée [17] et l'analyse statistique [18]. Les techniques utilisées dans le domaine des fréquences comprennent une analyse spectrale, notamment la densité spectrale de puissance [19] et l'analyse Cepstrum [20]. Les techniques du domaine temps-fréquence, telles que la transformée de Fourier à court terme [21], l'analyse par transformée en ondelettes [22] et les techniques empiriques de traitement du signal [23], sont fréquemment employées dans le cadre du diagnostic des défauts complexes. Elles permettent de résoudre le problème du masquage des défauts faibles amplitude par les défauts dominants, de réduire les interférences entre défaillances et de faciliter l'extraction et la séparation des caractéristiques couplées.

Le traitement des signaux s'est avéré être l'approche la plus prépondérante et la plus efficace pour diagnostiquer les défauts et mener des recherches sur la surveillance des boîtes de vitesses. Les méthodes classiques de traitement du signal, notamment l'analyse temporelle et fréquentielle, sont basées sur l'hypothèse de la stationnarité et de la linéarité du processus de génération des signaux. Leur utilisation pour l'analyse des signaux de défauts mécaniques peut conduire à des résultats incorrects, en raison de la nature non stationnaire de ces défauts qui peuvent engendrer des événements transitoires. Afin de traiter ces signaux non stationnaires, diverses techniques avancées d'analyse temps-fréquence ont été développées et mises en œuvre dans le cadre du diagnostic des défauts des transmissions mécaniques [24]. Les techniques empiriques de traitement de signal sont considérées comme l'approche optimale pour l'analyse temps-fréquence des signaux multi composants en raison de leurs performances supérieures. En comparaison avec les approches théoriques qui s'appuient sur des modèles mathématiques et des connaissances préalables du système physique telles que la transformée de Fourier rapide (FFT) [25] et les ondelettes (WT) [26], ces méthodes basées sur

les données ne requièrent pas d'hypothèses spécifiques derrière un modèle fondamental, elles procèdent à l'extraction directe des composantes intrinsèques du signal en analysant les données elles-mêmes, ce qui les rend particulièrement efficaces pour le traitement des signaux linéaires et non stationnaires [27]. Ces méthodes sont fréquemment employées pour diagnostiquer des défaillances complexes et difficiles à modéliser analytiquement.

Les techniques de décomposition adaptative des modes offrent une flexibilité accrue dans l'analyse de signaux complexes et arbitraires à plusieurs composantes, permettant ainsi une extraction des informations pertinentes. Elles surpassent les limites des méthodes traditionnelles basées sur l'expansion de base et comblent les lacunes des approches conventionnelles, offrant ainsi une méthode efficace pour analyser les signaux complexes dans le cadre du diagnostic des défaillances des machines [28].

Depuis que Huang [29] a proposé la transformé de Hilbert-Huang (HHT) en 1998, la méthode de décomposition adaptative des modes a attiré de plus en plus l'attention des chercheurs, menant à l'obtention de résultats fondamentaux significatifs. Actuellement, des études sont toujours en cours concernant ces méthodes et leurs applications. Parmi les multiples propositions trouvées dans la littérature scientifique, on distingue les approches les plus renommées :

En 1998, Huang et al [30] a introduit la méthode de décomposition de mode empirique (EMD), qui permet de décomposer de façon adaptative tout signal composite en un ensemble de fonctions de mode intrinsèque (IMF) représentant des oscillations locales à diverses échelles. Cette approche s'avère efficace pour l'analyse de signaux présentant des caractéristiques non linéaires et non stationnaires. De plus, l'EMD ne nécessite aucune hypothèse sur les composants fondamentaux du signal, ce qui en fait une méthode orientée vers les données capable d'extraire les caractéristiques intrinsèques du signal [31]. EMD a été récemment développée et largement appliquée utilisée dans le domaine du diagnostic des défauts des transmissions mécaniques, notamment pour le diagnostic des défauts des boîtes de vitesses [32], [33], le diagnostic des défauts d'engrenages [34], [35], le diagnostic des défauts de roulements [36], [37], défauts multiples composés d'engrenage et de roulement [38], diagnostic des défauts de déséquilibre [39] et défauts des arbres rotatifs [40]. Cependant, l'EMD est sujette à divers problèmes tels que la sensibilité au bruit, les effets de point final et le mélange de modes en cas d'asymétrie dans la distribution des points extrêmes du signal, ce qui peut impacter les résultats de la décomposition EMD.

Inspirées par l'idée de la décomposition adaptative des modes, de nouvelles approches ont été développées pour résoudre les problèmes associés à l'EMD, telles que la décomposition moyenne locale (LMD) introduite par Smith [41] en 2006, la décomposition de l'échelle caractéristique locale (LCD) proposée par Jinde et al [42] en 2013 pour traiter les problèmes de mélange de modes et de sur/sous-adaptation de l'EMD, ainsi que la décomposition des vibrations de Hilbert (HVD) par Feldman [43] en 2006, la transformée en ondelettes empirique (EWT) par Gilles [44] en 2013 et la décomposition en modes variationnels (VMD) par Dragomiretskiy et Zosso [45] en 2013. Ces différentes méthodes sont principalement empiriques, bien qu'elles puissent également reposer sur des principes théoriques justifiant leur approche. Bien que ces méthodes aient pour objectif commun de faciliter une analyse

temps-fréquence appropriée des données pour les séries temporelles non stationnaires de systèmes, qu'ils soient linéaires ou non linéaires, elles souffrent de diverses limitations. Tous d'abord, il convient de noter que certaines techniques telles que la LMD et la HVD sont vulnérables au bruit, ce qui peut conduire à des composantes déformées ou non pertinentes. D'autres méthodes, telles que la VMD, requièrent la préalable sélection du nombre de modes à extraire, ce qui peut avoir un impact significatif sur la qualité de la décomposition en cas d'estimation incorrecte de ce paramètre. En outre, la complexité algorithmique de certaines méthodes, telles que la VMD et l'EWT, peut restreindre leur utilisation en temps réel. De plus, certains phénomènes comme le chevauchement spectral entre les modes ou le mélange de modes peuvent altérer la précision des résultats, particulièrement lorsqu'il s'agit de signaux complexes [46]. Ces contraintes mettent en évidence l'importance de concevoir des techniques de décomposition plus solides, flexibles et aptes à s'adapter de manière plus précise aux particularités locales du signal. D'importantes améliorations et dérivations ont été intégrées à l'EMD dans divers autres algorithmes, tels que la décomposition en modes empiriques d'ensemble (EEMD), la décomposition en modes empiriques d'ensemble complémentaires (CEEMD), la décomposition en modes empiriques d'ensemble complémentaires avec bruits adaptatifs (CEEMDAN), qui se révèlent plus efficaces pour l'analyse des signaux non linéaires et non stationnaires.

Wu et Huang [47] ont proposé en 2009 une amélioration de la méthode EMD, appelée Décomposition en Modes Empiriques d'Ensemble (EEMD) pour surmonter ses limites. Cette approche consiste en une analyse statistique des résultats de la méthode EMD appliquée à la décomposition du bruit blanc. Pour illustrer la supériorité de l'EEMD par rapport à l'EMD, une décomposition et une analyse ont été effectuées sur un exemple concret et un signal vocal. Ils ont été démontrés que l'EEMD est véritablement une méthode NADA efficace pour extraire les signaux des données. En se basant sur les principes établis par l'EEMD. L'algorithme EEMD fait appel à une distribution uniforme du bruit blanc gaussien afin d'incorporer ce bruit au signal d'entrée, ce qui permet de rendre le signal initial continu à diverses échelles temporelles, réduisant ainsi le phénomène de mélange de modes. L'EEMD est capable de décomposer les signaux composites en une série de IMF, répartissant ainsi les différentes fréquences en différentes IMF, ce qui permet d'améliorer l'efficacité de la décomposition tout en réduisant le bruit [48].

Guo et al [49] ont analysé le signal de vibration d'accélération non stationnaire de l'engrenage en le décomposant en un ensemble limité de fonctions de mode propre stationnaires, grâce à la méthode d'EEMD. Chaque composante IMF d'un certain ordre est formée par une matrice de vecteurs propres initiale. L'avantage de l'EEMD réside dans sa capacité à éliminer le phénomène de repliement de mode.

Wang et al [50] ont exposé une approche pour le diagnostic automatique des défaillances de machines qui repose sur une mesure de distance statistique faisant appel à l'EMD et tirant parti des bénéfices de l'EEMD, démontrant ainsi son efficacité même en présence d'un faible nombre d'échantillons étiquetés. Testée sur deux cas réels, notamment un ensemble de données des roulements et un ensemble de données combinant des roulements et des engrenages.

Xu et al [51] ont présenté une méthode de diagnostic des défaillances de la boîte de vitesses, qui repose sur une version améliorée de l'EEMD. Cette approche inclut un mécanisme d'ajustement dynamique du bruit, qui autorise l'adaptation de l'amplitude du bruit en fonction des caractéristiques du signal. Ceci contribue à renforcer la stabilité et la précision de la décomposition du signal, ce qui permet de réduire de manière efficace l'instabilité et l'accumulation d'erreurs liées au bruit blanc d'amplitude fixe dans les EEMD classiques.

Diverses autres études ont également utilisé la méthode EEMD pour analyser des signaux non linéaires et non stationnaires dans le domaine de la surveillance des systèmes de transmission mécanique [52], [53], [54], [55].

Malgré le fait que l'EEMD atténue le problème de mélange des modes, elle est toujours confrontée à deux limitations significatives : la présence de composantes de bruit redondantes, ce qui entraîne de multiples itérations coûteuses en temps, et l'instabilité du nombre de composantes extraites en raison de la nature aléatoire du bruit blanc ajouté [48].

En 2010, Yeh et al [56] a introduit la méthode de décomposition en modes empiriques d'ensemble complémentaire (CEEMD). Dans cette méthode, le résidu de bruit blanc ajouté peut être séparé des mélanges de données et de bruit blanc en utilisant des paires d'IMF d'ensemble complémentaires avec des bruits blancs ajoutés positifs et négatifs. La méthode CEEMD présente des performances similaires à celles de l'EEMD, tout en offrant une efficacité de calcul nettement améliorée [57].

Athisayam et Kondal [58] ont appliqué la méthode CEEMD en tant que technique de prétraitement afin d'extraire les caractéristiques significatives du signal tout en réduisant efficacement le bruit. Cette approche permet de mieux distinguer les éléments importants associés aux défauts composites des roulements d'engrenages, ce qui facilite une analyse plus fiable et précise en vue du diagnostic.

Une décomposition en mode empirique d'ensemble complémentaire est proposée par Guo [59] pour analyser les signaux de vibration des boîtes de vitesses, dans le but d'extraire plusieurs fonctions de mode intrinsèque. En effectuant le calcul de l'entropie de l'échantillon des composants d'IMF en tant que vecteurs de caractéristiques.

Song et al [60] ont proposé une version optimisée de la méthode CEEMD en intégrant une technique de rééchantillonnage adaptatif du signal basé sur l'interpolation spline cubique. L'objectif de cette optimisation est d'améliorer la précision de la décomposition en définissant des paramètres standards et en calculant de manière automatique la fréquence de rééchantillonnage optimale à l'aide du coefficient de corrélation. La méthode de la CEEMD repose sur l'incorporation de bruits blanc opposés, ce qui facilite l'extraction des caractéristiques des défauts des engrenages planétaires de manière plus efficace.

D'autres applications de l'analyse CEEMD ont montré des performances satisfaisantes dans [61], [62], [63], [64], [65]. En comparaison avec l'EEMD, la CEEMD nécessite moins d'essais d'ensemble. Cependant, une difficulté réside dans la prise de la moyenne d'ensemble, un problème qui reste non résolu.

Ces dernières années, Torres et al [66] ont proposé une méthode de décomposition empirique des modes d'ensemble complète avec bruit adaptatif (CEEMDAN). En incorporant les éléments modaux du bruit adaptatif à chaque itération de la décomposition EMD, et en effectuant une moyenne des éléments modaux après la décomposition, le CEEMDAN surpasse l'EEMD en termes de capacité de décomposition et permet de réduire de manière efficace le bruit résiduel dans le signal reconstruit [67]. Par la suite, des chercheurs se sont penchés sur l'étude de la méthode CEEMDAN et ont obtenu des résultats prometteurs [68], [69], [70], [71], [72], [73], [74], [75].

Athisayam et Kondal [76] ont essayé à identifier les défauts complexe des engrenages et des roulements en appliquant la méthode CEEMDAN pour décomposer les signaux vibratoires bruts. Ensuite, ils ont choisi les IMFs exemptes de bruit en se basant sur leur corrélation croisée avec le signal brut. Pour prévenir toute perte d'information durant le processus de débruitage, un seuil de corrélation croisée optimale est calculé.

Zhang et al [77] ont développé une approche pour détecter les défauts dans les boîtes de vitesses, en combinant un processus de débruitage du signal basé sur l'optimisation de la fonction seuillage en ondelettes par recuit simulé avec la méthode CEEMDAN. Cette méthode novatrice permet de remédier aux problèmes de perte de données associés à la sur-planéité des fonctions de seuil souples classique suit à la réduction du bruit, tout en réduisant les pseudo-interférences engendrées par les oscillations locales des fonctions de seuil dures durant le processus de réduction du bruit.

Une méthode de diagnostic des défaillances de la boîte de vitesses est proposée par Wang et al [78], repose sur la combinaison de l'utilisation du CEEMDAN pour la décomposition adaptative des signaux en diverses bandes de fréquence, ainsi que l'application d'un modèle à mémoire à long terme (LSTM) pour l'extraction des caractéristiques temporelles des signaux à différents instants, les résultats obtenus ont démontré que le modèle CEEMDAN-LSTM présente une précision de prédiction supérieure par rapport aux modèles EMD-SVM et LSTM.

Afin de remédier à la problématique liée à la complexité du diagnostic précis des défauts des boîtes de vitesses dans un environnement bruyant, Xu et al [79] ont employé la méthode CEEMDAN pour traiter l'entropie d'échantillon du signal initial ainsi que de chaque composante d'IMF. La méthode de l'ondelette adaptative est utilisée pour effectuer la décomposition et la reconstruction de l'IMF en présence d'une entropie d'échantillonnage élevée dans le but de minimiser le bruit.

Ces dernières années, le CEEMDAN a attiré une attention croissante en raison de son efficacité remarquable dans la décomposition du signal et de sa précision élevée dans la reconstruction. Elle a été choisie en raison de ses performances supérieures par rapport aux méthodes précédentes, en particulier pour l'analyse de signaux non linéaires et non stationnaires. Diverses recherches récentes ont mis en évidence les avantages de l'utilisation de la méthodes CEEMDAN, notamment une meilleure séparation des composantes intrinsèques du signal, une réduction significative du bruit de mode et une reconstruction plus

précise des signaux d'origine. Cette aptitude à extraire de manière efficace les caractéristiques temporelles et fréquentielles pertinentes en fait une méthode privilégiée pour le diagnostic de défauts complexes de boîte de vitesses, comme l'ont souligné de nombreux chercheurs dans la littérature.

De manière classique, les systèmes de diagnostic de défauts basés sur des modèles d'apprentissage superficiel suivent un processus de cinq étapes : acquisition des données/signaux, prétraitement des données/signaux, extraction des caractéristiques, réduction/sélection des caractéristiques et diagnostic des défauts. Les approches classiques d'apprentissage automatique telles que les machines à vecteurs de support (SVM) [80], les k-plus proches voisins (KNN) [81], le classificateur Naïve Bayes [82], la forêt aléatoire (RF) [83], etc., exigent beaucoup de connaissances spécialisées et d'expérience, tant dans la phase de prétraitement des données que dans celle de l'extraction des caractéristiques. Par ailleurs, il est difficile d'extraire les caractéristiques optimales d'un environnement dynamique et d'effectuer un diagnostic des défauts complexe dans des conditions de travail variées. Au cours des dernières années, les modèles d'apprentissage profond (DL), une méthode relativement récente et en plein développement introduit par Hinton [84] depuis 2006, ont attiré beaucoup d'attention dans divers domaines. Le processus de diagnostic des défauts a été simplifié en trois étapes clés : acquisition des signaux, prétraitement des signaux et diagnostic des défauts. Étant donné que les modèles d'apprentissage profond sont composés de plusieurs couches cachées, les processus d'extraction et de sélection des caractéristiques sont automatisés. En outre, le deep learning se distingue par sa capacité à s'accumuler à généraliser et à ajuster les modèles, notamment lorsqu'il est confronté à des problèmes non linéaires et à des environnements variés. En comparaison avec les approches classiques d'apprentissage automatique, l'apprentissage profond se distingue par sa capacité à extraire de manière adaptative des caractéristiques, entraînant ainsi le besoin d'une extraction manuelle. Avec le développement rapide de l'ère du big data [85] [86].

Ces derniers temps, l'apprentissage profond (DL) a connu un succès notable grâce à son évolution rapide. De ce fait, un nombre croissant de chercheurs se penchent sur les techniques intelligentes d'apprentissage profond et déploient des efforts considérables pour les intégrer dans le domaine du diagnostic des défauts. Certains de ces efforts ont abouti à des résultats remarquables et à des performances excellentes.

Jiang et al [87] ont présenté une méthode de diagnostic des défauts d'une boîte de vitesse qui repose sur l'utilisation d'un réseau neuronal convolutif (CNN) associé à un algorithme de classification fine. Cette approche prend en compte les conditions de fonctionnement pour une classification approximative et les défauts spécifiques pour une classification fine. Cette approche exploite efficacement tous les échantillons des différentes conditions de fonctionnement des variables afin d'obtenir une double reconnaissance des défauts et des conditions de fonctionnement spécifiques avec une précision plus élevée.

Shi et al [88] ont présentés un nouveau modèle de réseau de neurones profonds qui repose sur des réseaux convolutifs bidirectionnels à mémoire à long terme (BiConvLSTM). Il permet d'identifier le type, la localisation et la direction des défauts des réducteurs planétaires en extrayant de manière automatique et simultanée des caractéristiques spatiales et temporelles à partir de mesures de vibrations et de vitesse de rotation.

Lin et al [89] ont exposé un système de diagnostic à distance des défauts des composites pour les boîtes de vitesses en utilisant un réseau de neurones convolutif unidimensionnel. Leurs principales contributions résident dans la comparaison des divers types de données en entrée et dans l'optimisation de la taille du noyau de convolution. Ces aspects influent non seulement sur la précision du diagnostic, mais également sur la réduction significative du temps nécessaire à l'entraînement du modèle.

Haj Mohamad et al [90] ont recours à un réseau de neurone convolutifs (CNN) en combinaison avec un réseau de mémoire à long terme (LSTM) pour effectuer la classification des défauts présents dans les données vibratoires générées à partir d'une maquette de boîte de vitesses d'hélicoptère. Lors de tests expérimentaux, divers engrenages soumis à différentes conditions sont examinés, et les performances de ce modèle sont éprouvées à l'aide de méthodes de prétraitement.

Han et al [91] ont présenté une nouvelle approche de détection de défauts en se basant sur un modèle CNN-LSTM dilaté multi-échelle. Ce modèle combine un CNN dilaté afin de tirer parti de manière efficace des caractéristiques distinctives des petits échantillons, il inclut également une unité de pondération adaptative combinée à un LSTM pour fusionner ces caractéristiques distinctives et améliorer leur résistance au bruit, une nouvelle fonction de perte nommée entropie croisée améliorée, conçue pour prendre en considération les petits échantillons ainsi que les échantillons facilement confondus. Les résultats expérimentaux obtenus à partir de données de boîte de vitesses planétaires démontrent une performance supérieure par rapport aux méthodes déjà existantes.

Athisayam et al [76] ont développé une méthodologie intégrant la méthode CEEMDAN, qui permet un débruitage efficace des signaux vibratoires en utilisant une sélection optimisée des composantes pertinentes, la transformation de Bassel pour faciliter l'analyse temps-fréquence, ainsi que le CNN pour effectuer la classification des défauts. Les résultats mettent en évidence que la méthode exposée se révèle être une solution robuste et efficace pour la détection des défauts des roulements d'engrenages composés.

D'autres études dans la littérature se sont également penchées sur l'application des CNN [92], [93], [94], [95], [96], [97] pour la détection des anomalies des boîtes de vitesses. De plus, différentes méthodes de deep learning comme l'apprentissage par transfert [98], [99], [100], [101] les réseaux de neurones à mémoire à court terme (LSTM) [102], [103], [104], [105], [106], [107], et les autoencodeurs [108], [109], [110], [111], [112] ont été utilisés dans ce domaine, avec pour objectif d'optimiser la précision de la détection et la résistance au bruit.

En dépit de l'efficacité des approches mentionnées précédemment, les difficultés liées au diagnostic pratique des défauts subsistent sans solution. L'un des défis largement reconnus des approches classiques de l'apprentissage profond réside dans leur incapacité à prendre en compte de manière adéquate l'incertitude lors de la prise de décision. La nature déterministe de ces méthodes peut conduire à des prédictions erronées de défauts en présence d'incertitudes inévitables. En général, on distingue deux catégories d'erreurs : les faux positifs, qui correspondent à des machines saines incorrectement identifiées comme défectueuses, et les faux négatifs, qui désignent des machines défectueuses à tort considérées comme normales. Les faux positifs engendrent des dépenses additionnelles mais comportent moins de risques, alors que les faux négatifs peuvent entraîner des pertes significatives.

Heureusement, la prise en compte de l'incertitude de prédiction permet d'améliorer la décision concernant la détection de défauts des machines, et la quantification de cette incertitude est indicative de la fiabilité des résultats de classification [113], [114].

Les méthodes bayésiennes proposent une approche novatrice pour la construction de réseaux neuronaux intégrant l'incertitude, permettant ainsi d'obtenir des résultats de diagnostic fiables. Kang et al [115] ont appliqué les réseaux bayésiens pour diagnostiquer les dysfonctionnements dans les systèmes à engrenages en présence d'informations incertaines ou incomplètes.

Romahadi et al [116] ont mis au point un système de diagnostic intelligent utilisant les réseaux bayésiens à états multiples et l'analyse des vibrations afin de surveiller l'état des boîtes de vitesses. En intégrant les caractéristiques courantes des vibrations dans un modèle probabiliste, ce système offre une détection des défauts précise et rapide. Les résultats confirment l'efficacité des réseaux bayésiens dans la fourniture d'informations fiables concernant la localisation et la probabilité d'occurrence des dommages.

Wang et al [117] ont développé une méthode hybride basée sur un modèle d'arbre de défaillance dynamique, qui intègre les données historiques de défaillances du système de gestion du contrôle du réseau ferroviaire et un réseau bayésien qui vise à estimer la probabilité de défaillance et à évaluer la fiabilité du système, les résultats obtenus mettent en évidence l'importance d'améliorer les modules critiques afin de faciliter le diagnostic des défaillances. D'autres études font également usage de l'approche bayésienne [118], [119], [120], [121], [122], [123], [124], [125], [126], [127], ce qui confirme l'importance croissante de cette méthode dans le domaine.

Dans cette thèse, nous proposons le Bayesian Convolutional Neural Network (BCNN) comme une approche novatrice récente pour le diagnostic des défauts combiné, suscitant un intérêt croissant ces dernières années. Elle combine les avantages des CNN en termes de capacité à extraire de manière automatique des caractéristiques pertinentes, avec les fondements de l'apprentissage bayésien, qui autorisent la représentation de l'incertitude des prédictions, offrant ainsi un cadre plus solide et explicite, spécialement approprié pour les contextes incertains ou bruités. Le BCNN représente une évolution des réseaux de neurones convolutifs traditionnels, qui intègre une approche bayésienne dans le but d'appréhender de manière plus précise l'incertitude associée aux prédictions. Contrairement aux standards du CNN qui attribuent des poids fixes aux connexions du réseau, un BCNN traite ces poids comme des variables aléatoires suivant des distributions de probabilité, souvent gaussiennes. L'apprentissage implique de prendre en compte la distribution postérieure de ces poids, ce qui permet au modèle de réaliser des prédictions tout en quantifiant l'incertitude associée. Les principaux bénéfices des BCNN résident dans leur capacité à généraliser de manière plus efficace, à être plus résistants au surapprentissage, et à fournir une estimation fiable de la confiance associée aux prédictions. En incorporant la théorie bayésienne dans le domaine de l'apprentissage profond, les BCNN fournissent un cadre plus formel et explicite pour la prise de décisions automatisée, permettant ainsi une haute précision dans le diagnostic et une estimation précise de l'incertitude [128].

Fang et al [129] ont exposé une approche améliorée pour le diagnostic des défauts, incluant une estimation de l'incertitude, en se basant sur BCNN. La méthode de Monte Carlo est

utilisée comme une approximation bayésienne. Le modèle BCNN proposé génère des prédictions sous la forme de distributions de probabilités, ce qui renforce la fiabilité du modèle et permet de mesurer l'incertitude des prédictions en présence de bruit ou de défauts inconnus. Lorsqu'elle est appliquée à un jeu de données de roulements, cette méthode démontre une précision et une robustesse élevées en présence de bruit, ce qui laisse entrevoir un potentiel promoteur pour la surveillance des moteurs d'imprimantes 3D.

Zhou et Tang [130] ont mis au point un BCNN afin de réaliser le diagnostic des défauts des engrenages en prenant en considération l'incertitude dans les prédictions. Cette approche a la capacité de générer une prédiction probabiliste afin de faciliter la prise de décisions judicieuses et de s'adapter aux applications concrètes. Les expériences menées en laboratoire sur une boîte de vitesses, sous forme d'études de cas, ont validé l'efficacité du modèle, démontrant ainsi une précision satisfaisante même en situation de bruit.

Mostafavi et Friedmann [131] ont développé un BCNN utilisant une méthode d'inférence variationnelle pour la surveillance de l'état des roulements. Ce modèle incorpore une approche humaine dans la boucle pour le processus de diagnostic du système, fournissant des données sur l'incertitude du diagnostic afin de prévenir tout excès de confiance. Le modèle repose sur l'utilisation de couches convolutives 1D afin de simplifier la structure, et une couche Softplus normalisée pour contrôler le niveau de confiance excessif. La quantification de l'incertitude des résultats permet aux experts de discriminer entre les prédictions hautement fiables et celles moins fiables, ce qui contribue à une meilleure appréhension de l'état réel du système.

Amin et al [132] ont étudié l'application des BCNN dans le domaine du diagnostic des défauts des réducteurs d'éoliennes. Leur approche a permis d'obtenir des résultats précis, tout en réduisant les incertitudes associées et en limitant les erreurs de classifications trop confiantes. En comparaison avec les approches classiques qui sont sensibles aux défauts inconnus, les modèles bayésiens intègrent l'incertitude, ce qui permet de réduire les risques de classification erronées.

Wang et al [133] ont exposé un modèle de réseau neuronal convolutif à inférence bayésienne variationnelle afin d'améliorer la précision du diagnostic des anomalies de roulements, en se basant sur une approche de fusion multi-capteurs. Cette approche est employée pour former une série de modèles de diagnostic de base qui reposent sur des signaux monocanaux, dans le but de produire plusieurs résultats de diagnostic préliminaires. La méthode a été évaluée en utilisant des données expérimentales provenant de roulements de boîtes d'essieux de trains à grande vitesse, démontrant ainsi une précision élevée et une stabilité satisfaisante.

Pour optimiser le diagnostic des défauts mécaniques avec des données limitées, Feng et al [134] ont proposé un réseau de généralisation bayésien fiable intégrant une couche convolutionnelle bayésienne basée sur l'inférence variationnelle, traitant les paramètres comme des variables aléatoires afin d'accroître la robustesse et la généralisation. L'optimisation s'appuie sur la reparamétrisation locale et l'échantillonnage de Monte Carlo, intégrant l'incertitude pour une interprétabilité améliorée. Testée sur des données de roulement et de boîtes de vitesses, la méthode atteint une grande précision et surpasse les modèles de référence dans un contexte multi-sources avec un nombre limité d'échantillons.

He et al [135] ont développé un modèle de fusion utilisant des BCNN dans le but d'optimiser la détection des anomalies des capteurs dans les systèmes de trains à grande vitesse pour acquérir les caractéristiques spatiales d'un unique capteur. Cette méthode permet une identification précise des défauts du capteur, ce qui facilite la mise en évidence de la corrélation inhérente et le filtrage des données non pertinentes.

Malgré les résultats encourageants obtenus par les BCNN dans des domaines tels que la médecine ou la vision par ordinateur, l'application de cette technique au diagnostic et à la détection des défauts combinés demeure largement sous-étudiée dans la littérature scientifique. Les publications traitant de ce thème sont peu nombreuses, ce qui montre que le domaine est encore en phase d'exploration. L'absence de recherches préalables représente un défi significatif, mais également une opportunité scientifique stimulante. Ce choix méthodologique confère ainsi une double valeur à cette étude : d'une part, cette approche propose une solution novatrice pour traiter la complexité des signaux provenant de multiples défauts. D'autre part, elle cherche à pallier une lacune dans la littérature en présentant de nouvelles découvertes et en évaluant l'efficacité du BCNN dans un environnement industriel concret. Dans l'ensemble, l'utilisation du BCNN dans cette thèse constitue un défi ambitieux visant à étudier les avantages d'une méthode récente et peu utilisée jusqu'à présent dans ce domaine particulier. Cela confère à cette étude un aspect novateur, tout en présentant un défi stimulant du point de vue méthodologique et scientifique.

# **Chapitre I :**

## Généralités sur la surveillance des transmissions mécaniques

### I.1 Introduction

La transmission englobe tous les composants qui concourent à l'exécution d'un mouvement particulier dans un contexte d'application donné. Il s'agit de la transmission d'énergie d'une source d'alimentation triphasée à induction vers un dispositif récepteur. Les systèmes industriels se composent de différentes transmissions adaptées au type de mouvement requis. Cependant, ces transmissions sont susceptibles d'être affectées par diverse forme de dégradation et de défaillance, pouvant entraîner l'arrêt de la production et causer des dommages aux équipements et aux individus. Il est donc essentiel de mettre en place une surveillance et un diagnostic de ces transmissions afin de réduire les coûts de maintenance, tout en garantissant la disponibilité et la continuité optimale de leur fonctionnement.

Diverses approches de diagnostic ont été suggérées. Elles jouent un rôle essentiel dans la mise en œuvre de la maintenance prédictive, qui vise à prévoir les défaillances le plus précocement possible afin d'assurer la sécurité et la continuité des opérations de l'entreprise, tout en évitant des conséquences graves telles que l'arrêt des machines et la diminution de la production.

Ce chapitre propose une étude bibliographique concernant la maintenance des équipements et des machines, en mettant l'accent sur la maintenance prédictive basée sur l'analyse vibratoire. A ce propos, nous présenterons les diverse méthodes et techniques déjà mises en œuvre ainsi que celles actuellement en cours de développement.

### I.2 Moteur triphasé à induction

#### I.2.1 Définition du moteur

Le moteur triphasé à induction ou bien le moteur asynchrone est un type de moteur électrique qui convertit l'énergie électrique triphasé du courant alternatif en mouvement mécanique. Il se compose de deux parties : le stator qui est la partie fixe et le rotor la partie mobile. Le stator comporte trois enroulements alimentés par des courants alternatifs triphasés, qui génère un champ magnétique tournant qui vient induire le courant dans le rotor.




Figure I. 1 Moteur triphasé à induction.

### I.2.2 Principe de fonctionnement

Le moteur triphasé à induction fonctionne sur le principe de l'induction des courants dans les enroulements du rotor par un champ tournant généré dans l'entrefer dû à la circulation de courant triphasé dans le stator. Ce champ croise les conducteurs du rotor, induisant selon la loi de Faraday une force électromotrice dans ces conducteurs. Cette force entraîne un courant qui crée son propre champ magnétique. L'interaction de ces deux champs engendre un couple moteur qui entrainera le démarrage et la rotation du rotor. [136]

### I.2.3 Choix du moteur (application)

Le moteur triphasé à induction présente 80% des types de moteurs les plus fréquemment employés dans l'industrie comme les compresseurs, les convoyeurs, les pompes et les machines-outils, plus précisément, dans les systèmes de transmissions, le moteur fournit la puissance nécessaire pour entraîner les composants mécaniques ainsi les chaînes, les courroies ou les engrenages. Ces transmissions présentent une importance cruciale dans la régulation de la vitesse et du couple transmis, assurant une efficacité optimale spécifique aux besoins de chaque application industrielle. Le choix du moteur dépend de divers critères qui le rend idéal pour les systèmes de transmissions, certains critères sont indiqués comme suit : [137]

- **Robustesse et fiabilité** : ces moteurs sont destinés pour supporter à des conditions difficiles, cela permet de les rendre fiables et durables sur le long terme avec peu d'entretien.
- **Couple et puissance** : les moteurs triphasés à induction ont la capacité de fournir un couple de démarrage élevé, leur permettant donc de délivrer une haute puissance continue, ce qui les rendant capable de démarrer et d'accélérer de manière efficace les charges lourdes, et d'adapter aux exigences des applications industrielles.
- **Faible coût** : ils ont des coûts de maintenance et de fabrication plus faible par rapport à d'autres types de moteur, en faisant une option rentable pour les applications industrielles.
- **Contrôle de vitesse** : l'utilisation de variateurs de vitesse permet de contrôler avec précision la vitesse de rotation et le couple, ce qui améliore la performance des systèmes de transmission.
- **Rendement** : ces moteurs se caractérisent par un rendement élevé, entraînant une diminution de coût et de la consommation d'énergie.
- **Compatibilité** : les moteurs triphasés à induction sont adaptés aux réseaux d'alimentation triphasés standard, ce qui simplifie leur installation et leur compatibilité avec les systèmes existants.

### I.3 Transmissions mécaniques

La transmission mécanique est un système qui inclut des composants mécaniques utilisés pour transmettre ou convertir la puissance ou bien le mouvement d'une pièce à une autre, cet élément a pour but d'adapter et contrôler la vitesse et le couple entre l'organe moteur et l'organe entraîné. Cela est effectué par l'intermédiaire de différents mécanismes comme les courroies, les arbres de transmission, les chaînes, les poulies, et les engrenages... etc. Ces mécanismes sont couramment utilisés dans les industries, ce qui les rend très sensibles et souvent exposés à des contraintes mécaniques importantes et à des conditions de travail sévères, provoquant l'apparition de différentes défaillances.

### I.3.1 Principales défaillances des transmissions mécaniques

Le tableau I.1 présente les statistiques à propos des causes de défaillances et leur localisation dans les transmissions de puissance. [138]

Localisation des défauts	(%)
Dentures	60%
Paliers	20%
Arbres	10%
Carters	7%
Autres	3%

Tableau I. 1 Localisation des défauts dans la transmission de puissance.

#### I.3.1.1 Défauts de roulements

Un roulement est un mécanisme utilisé dans le système de transmission mécanique pour guider la rotation d'un assemblage, ainsi il permet à une pièce de tourner par rapport à une autre autour d'un axe de rotation défini avec un minimum de frottement et il assure une position précise de l'arbre pour corriger les défauts d'alignement. Il existe généralement quatre éléments principaux dans le roulement : deux bagues (intérieur et extérieur), une cage et des éléments roulants pouvant être des rouleaux, des billes ou des aiguilles en fonction de l'application envisagée et du type de roulement. Les composants d'un roulement sont illustrés dans la figure I.2, tandis que La figure I.3 montre les principaux types de roulements.

Chaque type de roulement a sa propre vitesse limite de rotation, ses capacités à supporter des charges radiales et axiales et gérer les défauts d'alignement. Leur contribution essentielle à la transmission mécanique les amène à fonctionner dans des conditions difficiles avec des températures élevées et des charges lourdes. En conséquence, au fil du temps les composants des roulements exposent différent type de dommage ce qui les rend l'un des composants les plus délicats et une source fréquente de défaillance. Selon les statistiques du tableau I.1, les roulements sont responsables de 20% des défaillances de la transmission, ces défaillances peuvent être distinguer et causées par quatre grandes familles de causes, qu'on peut les répertoriées suivant le tableau I.2. [139]




Figure I. 2 Les composants d'un roulement.




Figure I. 3 Les principaux types de roulements.

Types de défauts	Causes	(%)
<ul style="list-style-type: none"> <li>Rupture des bagues.</li> <li>Ecaillage.</li> <li>Grippage.</li> <li>Détérioration des cages.</li> </ul>	<b>Mauvaise lubrification</b> : choix des lubrifiants, quantité, fréquence de lubrification	36%
<ul style="list-style-type: none"> <li>Ecaillage.</li> <li>Détérioration des cages.</li> <li>Grippage.</li> </ul>	<b>La fatigue</b> : contrainte mécanique excessive (la vitesse, les charges axiales et radiales).	34%

<ul style="list-style-type: none"> <li>• Empreintes par déformation.</li> <li>• Corrosion par contact.</li> <li>• Détérioration des cages.</li> </ul>	<b>Montage incorrect</b> : désalignement.	16%
<ul style="list-style-type: none"> <li>• Corrosion du roulement.</li> <li>• Usure.</li> </ul>	<b>Contamination</b> : environnement humide, la présence d'acides et de polluants abrasifs (poussière et sable)	14%

Tableau I. 2 Causes des différents types de défauts d'un roulement.

La figure I.4 montre certains types de défaillances affectant le fonctionnement des roulements.



Figure I. 4 Exemples des avaries affectant les roulements.

Selon des données plus précises, 90 % des défauts de roulement se trouvent sur la bague intérieure ou extérieure, tandis qu'une incidence rare sur la cage ou les billes.[140]




Figure I. 5 Les défauts de roulement. [141]

### I.3.1.2 Défauts d'engrenages

Les engrenages sont des mécanismes qui transmettent le mouvement et la puissance mécanique entre deux arbres. Ils sont composés de deux roues dentées mobiles autour d'axes fixe, dont l'une entraîne l'autre par l'interaction de dents en contact successif, ils peuvent servir à diverses fonctions, telles que la variation de la vitesse de rotation avec une réduction ou augmentation du couple et même pour changer la direction du mouvement rotatif. Il existe divers types d'engrenages employées dans l'industrie, chacun adapté à des objectifs et des applications spécifiques. La figure I.6 représente les types d'engrenages les plus courants :




Figure I. 6 Les types d'engrenages.

Du fait de leurs conditions de travail pénible, ces engrenages subissent une détérioration progressive, entraînant l'apparition de défauts. Selon le tableau I.1 la denture concentre la majorité des défaillances (60%) dans les transmissions mécaniques. Cela indique que les engrenages, en tant qu'éléments sensible de la machine, sont soumis à un nombre important d'avaries qui peuvent survenir au cours de leur fonctionnement.

Les défauts des engrenages sont couramment regroupés en trois classes : [142]

- a. Défauts de fabrication : comme l'excentricité des roues ou les erreurs de profil des dents.
- b. Défauts de montage : tels que les défauts de parallélisme et d'entraxe.
- c. Défauts de fonctionnement : il existe principalement deux catégories :
  - Défauts repartis : sont des défauts affectant toutes les dentures d'engrenage tels que les piqûres et l'usure abrasive et adhésive. Figure I.7.
  - Défauts localisés : sont des défauts localisés sur une partie de la denture et ils entraînent rapidement la rupture de ces dents, on peut citer la fissuration, l'écaillage et le grippage. Figure I.8.




Figure I. 7 Défauts d'engrenages : usure, piqure.




Figure I. 8 Défauts d'engrenages : rupture de dent, écaillage, grippage, fissure.

### I.3.1.3 Défauts de courrois

Un système de transmission par courroie se compose d'une poulie motrice appelée « poulie vilebrequin » qui transmet la puissance à une ou plusieurs poulies réceptrices appelées « poulie accessoire » sous la forme d'un mouvement de rotation, soit par adhérence, soit par obstacle grâce à un lien flexible « courroie » figure I.9. Ce type de transmission est largement utilisé dans diverses applications industrielles et automobiles en raison de sa simplicité, de son faible coût et de sa capacité à fonctionner sur des distances d'entraxes variables, ainsi qu'entre des arbres éloignés non alignés.








Figure I. 9 Système de transmission par courroie.

Selon les exigences des utilisateurs, la puissance à transmettre, les domaines d'application et les conditions de fonctionnement, il existe de nombreuses configurations possibles de systèmes. Cette diversité est due à la variété des types de courroies, chacune possédant des caractéristiques et des usages spécifiques. Figure I.10.



**Figure I. 10** Différents types de courroies.

Au cours de leurs utilisations, les courroies peuvent présenter diverses défaillances qui affectent l'efficacité et la fiabilité des équipements, le tableau I.3 résume les types et les causes des défaillances courantes des courroies. [143].

Types de défauts	Causes
<p>Arrachement des particules</p> 	<ul style="list-style-type: none"> <li>• Usure des poulies.</li> <li>• Désalignement des poulies.</li> <li>• Collage des particules provoquant un bruit anormal.</li> <li>• Tension excessive.</li> <li>• Température de fonctionnement élevée.</li> </ul>
<p>Rupture irrégulière.</p> 	<ul style="list-style-type: none"> <li>• Pénétration de gravillons en raison de l'absence de capot de protection.</li> <li>• Pollution liquide ou solide.</li> <li>• Surtension de la courroie.</li> <li>• Blocage d'un élément extérieur.</li> </ul>
<p>Fissure de la courroie</p> 	<ul style="list-style-type: none"> <li>• Cuisson du caoutchouc due à une surtension.</li> <li>• Glissement de la courroie sur les galets entraîne une surchauffe.</li> </ul>





<p>Rupture nette</p> 	<ul style="list-style-type: none"> <li>• L'intrusion d'un objet étranger entre la courroie et la (les) poulie(s).</li> <li>• Tension excessive.</li> <li>• Détérioration de la structure interne de la courroie (fibres de verre).</li> <li>• Usage des outils inappropriés (tournevis).</li> <li>• Pollution (solide ou liquide).</li> </ul>
<p>Défaut de tension</p> 	<p>L'usure marquée du dos de la courroie peut être attribuée à une tension excessive ou à un glissement causé par une mauvaise tension.</p>
<p>Usure des flancs</p> 	<ul style="list-style-type: none"> <li>• Décalage de la courroie pendant la mise en place de la poulie.</li> <li>• Désalignement des tendeurs et/ou des poulies.</li> <li>• Contact avec un objet étranger.</li> </ul>
<p>Arrachement des dents</p> 	<ul style="list-style-type: none"> <li>• Vieillissement prématuré due à la chaleur.</li> <li>• Présence d'un corps étranger dans les gorges.</li> <li>• Blocage partiel ou totale des composants du moteur.</li> <li>• Arrachement des dents de la trame de la courroie : pollution liquide ou sous-tension de courroie.</li> </ul>

Tableau I. 3 Les types des défaillances des courroies.

I.3.1.4 Défauts de balourd




Figure I. 11 Défaut de balourd.

Le balourd, aussi appelé le déséquilibre est un phénomène dû à une distribution inégale des masses tournantes d'un rotor autour de son axe, entraînant un écart entre l'axe de rotation et le centre de gravité de chaque tranche élémentaire du rotor, ce déséquilibre engendre des forces centrifuges qui provoquent des vibrations, du bruit, usure prématurée et des dommages mécaniques. Il existe différents types de balourd qui peuvent être distingués : [144]

Balourd statique	Balourd de couple	Balourd dynamique
<p>Le rotor présente une masse distribuée de manière égale autour du centre de gravité et se trouve du même côté du rotor ou l'axe d'inertie est parallèle à l'axe de rotation.</p>	<p>Le rotor présente deux masses lourdes identiques situées à 180° l'une par rapport à l'autre sur des plans opposés de l'axe de rotation, l'axe d'inertie et le centre de gravité sont croisés.</p>	<p>Il s'agit d'une combinaison des deux types précédents et du type le plus courant il se produit lorsque la répartition de la masse est inégale sur plusieurs plans autour de l'axe de rotation.</p>

Tableau I. 4 Les différents types de balourd.

Ce balourd est souvent dû à des défauts d'assemblage, d'usinage et de montage ou provient de : [145]

Une altération mécanique se produit lorsque des défauts d'usinage ou de fabrication provoquent une accumulation ou perte inégale de la matière du rotor comme la rupture d'une aube ou perte d'ailette, érosion ou encrassement de matière et fluage du rotor... etc.

Une altération thermique se manifeste lorsque les changements de température affectent sur la structure des composants tournants ce qui entraîne des déformations des rotors, fissuration transversale sur l'arbre ou une dissymétrie structurelle. Dans les machines électriques, ces variations thermiques provoquent une dilatation irrégulière et glissement des bobinages.

### I.3.1.5 Défaut d'alignement

Défaut d'alignement, également appelé désalignement est un écart entre l'axe de rotation d'un arbre moteur et l'arbre récepteur au niveau de l'accouplement. La figure I.12 présente les divers types d'alignement. [146]




Figure I. 12 Principaux défauts d'alignement.

Un mauvais alignement de l'arbre peut être causé par plusieurs facteurs qui peuvent être d'origine : [147]

- Origine mécanique
  - Mauvaise installation : telles que l'assemblage incorrecte de l'accouplement.
  - Usure des composants : les assemblages et les pièces mécanique peuvent se détériorer et s'user.
  - Forces externes : comme les vibrations de machine ou des chocs violents.
  - Déformation : les charges excessives appliquées aux composants mécaniques entraînent des déformations ou des flexions, ce qui affecte l'alignement.
- Origine thermique : le changement de température provoque une dilatation ou une contraction des arbres ce qui perturbe leur alignement.

Les défaillances dans les systèmes de transmissions mécaniques ont généralement un effet en chaîne, un simple défaut a le potentiel de perturber l'équilibre du système et d'entraîner des dommages supplémentaires sur d'autres composants, et peut donc accélérer leur détérioration. Si ces anomalies ne sont pas détectées et traitées rapidement à temps, peuvent causer des pannes majeures et des interruptions couteuses de production. C'est là où la maintenance intervient, jouant un rôle essentiel dans la prévention et le traitement de ces défaillances.

### I.4 La maintenance industriel

Suivant l'AFNOR (NF X 60-010) « La maintenance est un ensemble des actions visant à maintenir ou rétablir un bien dans un état spécifié ou assurer un service déterminé ». [148]

Les opérations de maintenance assurent à la fois l'amélioration de la qualité des produits et la réduction des coûts de production.

Selon la figure I.13, La maintenance se compose de deux grandes familles, la maintenance préventive et la maintenance corrective. [149]

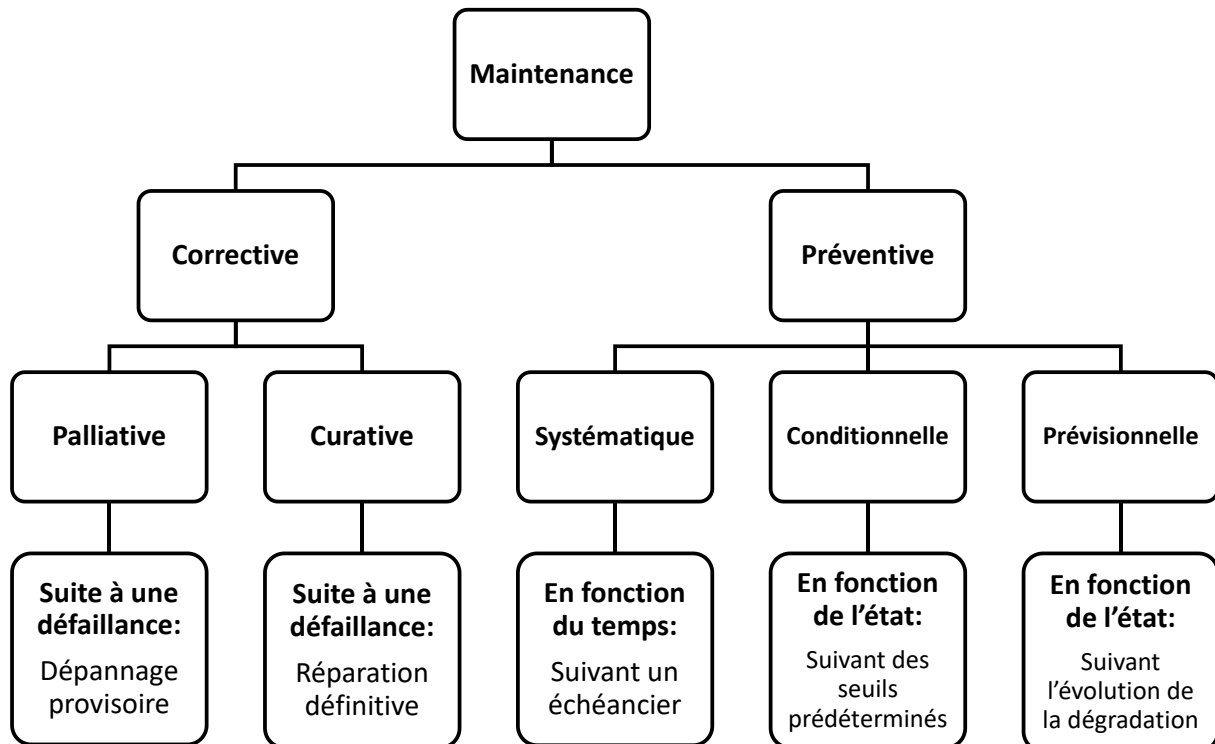


Figure I. 13 Les différents types de maintenance

### I.4.1 La maintenance corrective

Les opérations effectuées sur une machine ou un équipement en cas d'une panne. Elle peut avoir deux types : [150]

- **La maintenance Palliative** : c'est un dépannage temporaire du matériel défaillant, permettant à l'équipement de maintenir sa fonction que ce soit partiellement ou totalement, en attendant sa réparation.
- **La maintenance curative** : consiste à réparer en profondeur les pannes de l'équipement de manière définitive et à le rétablir à son état initial avec un impact à long terme, contrairement à la maintenance palliative.

### I.4.2 La maintenance préventive

L'entretien régulier d'une machine ou un équipement avant une défaillance, dans le but de prévenir les pannes. On distingue trois sous-types : [151]

- **La maintenance systématique** : implique la planification des actions de maintenance selon un échancier prédéfini, avec des intervalles de contrôle fixés arbitrairement ou en fonction des caractéristiques de détérioration du système.
- **La maintenance conditionnelle** : consiste à surveiller les actifs selon un événement prédéfini, elle utilise des données collectées en temps réel à l'aide des techniques de

maintenance pour intervenir dès qu'un actif dépasse un seuil de dégradation ou d'usure prédéterminé. Le but est de choisir la bonne opération au moment opportun, pour optimiser la gestion des coûts.

- **La maintenance prévisionnelle :** il s'agit d'une technique de maintenance conditionnelle basée sur les prévisions extraites du traitement et de l'évaluation des paramètres de dégradation du bien. Elle vise à prévoir le dépassement d'un seuil prédéfini qui indique l'état de dégradation de l'équipement avant l'apparition d'une panne ou d'une défaillance.

Le choix de type adéquat de maintenance dépend de divers critères, notamment l'importance de l'équipement, la nature spécifique de la défaillance, le coût liés à la maintenance et la sécurité du personnel. La maintenance prédictive est la stratégie de maintenance la plus efficace elle dispose des méthodes fiables pour surveiller régulièrement l'état des équipements et évaluer leur durée de vie restante afin de prévoir les pannes éventuelles, ce qui améliore la disponibilité des équipements et réduire les coûts. Pour cela le travail de cette thèse est destiné à la maintenance prédictive et consiste en une méthodologie de diagnostic visant à améliorer la détection des défauts.

### I.5 Méthodologie de diagnostic

Dans le contexte de la maintenance prédictive, la supervision se réfère à une méthodologie de diagnostic améliorant la détection des défaillances, elle comprend les procédures nécessaires pour répondre aux anomalies du système, notamment les interruptions inattendues ou les pannes. L'objectif est de planifier les opérations de maintenance à temps pour optimiser la fiabilité des systèmes. Le principe de diagnostic en supervision implique trois opérations essentielles, selon la figure I.14. [138]




Figure I. 14 Méthodologie du diagnostic.

- **Surveillance :** Consiste à suivre l'état de fonctionnement des équipements en continu ou à intervalle réguliers à l'aide de capteurs et d'instruments de mesure, son objectif est de recueillir des données sur une variété de paramètres.
- **Analyse :** vise à interpréter, manipuler et analyser les signaux pour extraire des informations pertinentes à l'aide des techniques de traitement de signal pour convertir les données brutes collectées en informations significatives concernant l'état de fonctionnement de la machine.
- **Diagnostic :** C'est l'identification et la localisation du défaut, elle est utilisée pour évaluer le risque de défaillance et guider les actions à entreprendre en conséquence, les signes détectés lors de surveillance sont utilisés pour confirmer ou infirmer l'existence des défauts et les classer avant toute décision.

### I.6 Méthodes de surveillance

Les méthodes de surveillance désignent les diverses approches utilisées pour surveiller le bon fonctionnement des machines dans le contexte de la maintenance prédictive. La figure I.15 illustre les méthodes les plus fréquemment employées pour le diagnostic, avec un accent mis sur l'analyse vibratoire, qui a été adoptée dans ce travail. [12]

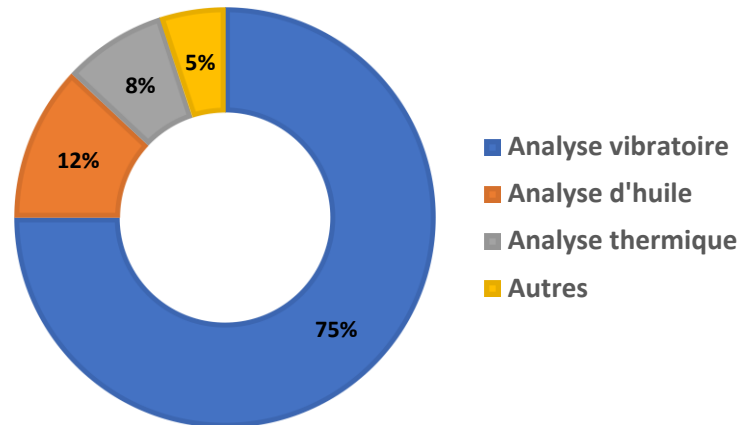


Figure I. 15 Les différents techniques de la surveillance des machines tournantes.

#### I.6.1 Analyse d'huile

L'analyse d'huile est capable d'évaluer l'état de lubrifiant ainsi que les systèmes contenant un fluide (la graisse ou l'huile), tels que les roulements ou les engrenages. Elle détecte divers indicateurs, notamment la dégradation de l'huile causée par l'oxydation, identifiée par l'analyse spectrographique, ainsi que la viscosité de l'huile et la teneur en eau, qui indiquent une augmentation de la température. Le capteur de copeaux détecte la présence de particules métalliques, ce qui peut indiquer une usure des composants. Néanmoins, cette analyse ne permet pas une localisation précise des défauts et elle exige des précautions lors de la collecte des échantillons. [138]



Figure I. 16 Analyse des lubrifiants.

#### I.6.2 Analyse thermique

L'analyse thermique implique la surveillance de la chaleur d'un matériau en utilisant des sondes de température ou la thermographie infrarouge, ce qui génère un thermogramme qui cartographie la température en deux dimensions. Après l'étalonnage, le rayonnement infrarouge détecté est converti en mesures de température, ce qui facilite l'identification des

défauts associées à l'échauffement. Malgré la rapidité de l'interprétation des résultats, cette approche limite le diagnostic approfondi et la détection précoce des défauts en raison du manque de visibilité des capteurs. [152]



Figure I. 17 Thermographie infrarouge.

### I.6.3 Analyse vibratoire

L'analyse vibratoire est l'approche la plus couramment employée dans le secteur afin de détecter une grande variété de dysfonctionnement mécanique, les vibrations engendrées par le fonctionnement d'une machine créent une signature vibratoire, une simple variation des vibrations de machine peut indiquer la présence d'anomalies au niveau des composants, susceptibles de causer une panne de la machine. Ainsi, la surveillance régulière de ces vibrations permet de détecter efficacement les défaillances. La figure I.18 illustre la chaîne de mesure de l'analyse vibratoire.

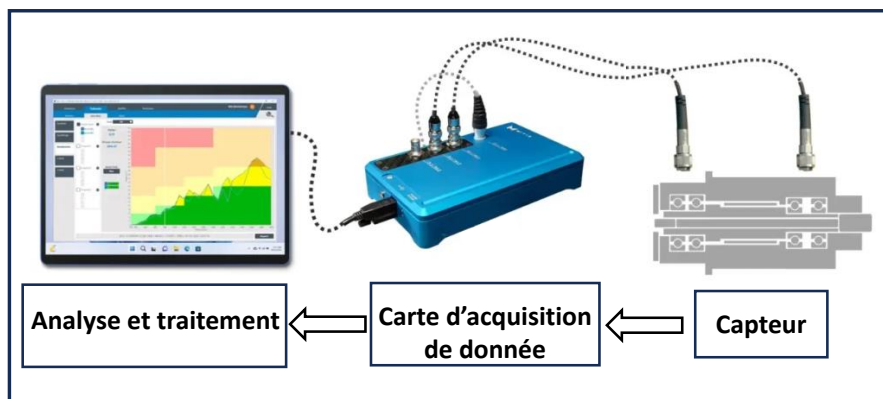


Figure I. 18 Chaîne de mesure de l'analyse vibratoire.

Les signaux vibratoires sont enregistrés en permanence sur les machines tournantes à partir des capteurs comme ceux de vitesse, du déplacement et d'accélération, parmi lesquels l'accéléromètre piézoélectrique est le plus répandu, il est caractérisé par sa robustesse, sa précision et son coût abordable. Ce capteur, doit être positionné dans des zones critiques présentant une charge locale maximale et aligné selon les axes axial, vertical ou radial en fonction de la structure de l'équipement et de l'origine des vibrations tels que les axes de roues, les roulements de la transmission...etc. Il transforme les accélérations des vibrations en signaux électriques proportionnelle, ces signaux sont traités par un système d'acquisition de données, qui amplifie le signal analogique et le converti en données numérique. Cette acquisition assure l'intégrité et la précision du signal avant d'être analysé. Ensuite, l'analyse des données consiste à interpréter les vibrations enregistrées à l'aide d'outils de traitement de

signal pour identifier les indicateurs de dysfonctionnements des équipements, ce qui favorise la mise en œuvre d'une maintenance prédictive performante. [152]

La polyvalence de l'analyse vibratoire ne s'arrête pas à ce stade, cette approche est appliquée à tous les éléments soumis à des contraintes significatives et présentant un risque élevé de tomber en panne. L'analyse vibratoire est un outil efficace pour identifier les divers défauts fréquemment rencontrés dans les transmissions mécaniques tels que l'alignement, le déséquilibre, les engrenages, les roulements. Elle est capable de s'adapter à diverse machines présentes dans une usine, il s'agit d'un moyen efficace de diminuer à l'aide d'un unique outil à la fois l'indice de fréquence et la probabilité de non-détection d'une défaillance. Diverses techniques de surveillance, comme l'analyse d'huile, l'analyse thermique et l'analyse électrique, présentent également des avantages et peuvent s'avérer très pertinentes et complémentaires pour aborder un problème spécifique. Toutefois, aucune de ces méthodes ne parvient à combiner efficacement la détection précoce de multiples défauts avec une explication fiable de ces défaillances. [153]

D'autres approches de la maintenance prédictive comme l'analyse électrique, l'analyse acoustique, l'inspection par ultrasons et l'inspection visuelle, représentent 5% du classement.

### I.7 Méthodes d'analyse

L'analyse du signal repose sur un ensemble des méthodes spécialisées visant à examiner et à modifier les signaux d'entrée pour extraire les caractéristiques des défauts. Les données recueillies par les mesures ne sont généralement pas immédiatement exploitables et nécessitent un prétraitement avant d'être utilisées. Divers outils d'analyse vibratoire ont été mis en œuvre dans la littérature [154] [155] [156]. Ces techniques peuvent classer en trois catégories : l'analyse temporelle, fréquentielle et temps-fréquence.

#### I.7.1 Analyse temporelle

Les méthodes temporelles reposent sur l'analyse statistique des signaux collectés pour surveiller l'évolution des défaillances dans les systèmes des transmissions mécaniques, elle implique la réalisation de mesures de vitesse dans des bandes de basses fréquences et de mesures d'accélération dans des bandes de hautes fréquences. L'objectif est de réduire l'effet des vibrations engendrées par la rotation des arbres. Cette approche utilise des indicateurs scalaires pour suivre l'évolution de la puissance ou de l'amplitude crête du signal, afin de détecter un défaut sans recourir à une valeur absolue spécifique, mais en se basant plutôt sur l'évolution temporelle de cette caractéristique, les variations d'amplitude indiquent la présence d'un défaut, et la régularité de ces variations peut fournir des indications sur son origine, parmi ces indicateurs on peut citer : [157]

- **RMS** : La moyenne quadratique ou la valeur efficace qui peut être calculer à l'aide de l'équation (I.1). Elle est utilisée pour évaluer l'écart des valeurs par rapport à la moyenne, les vibrations sont considérées comme préjudiciables en présence de variations soudaines du signal de la courbe de RMS, une augmentation de cette valeur indique une dégradation du système.

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_i)^2} \quad (I.1)$$

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

$x_i$  : L'amplitude des vibrations.

- **Kurtosis** : le kurtosis ( $k$ ) représente le quatrième moment statistique d'une distribution, comme défini dans l'équation (I.2). L'aplatissement de la loi de probabilité par rapport à une distribution gaussienne peut être évalué à l'aide d'un paramètre spécifique. Ainsi, un système en bon état de fonctionnement produit un signal vibratoire avec un aplatissement d'ordre 3, tandis que pour un système défectueux, l'aplatissement est égal ou supérieur à 4. Cet indicateur est largement employé pour détecter les chocs anormaux périodique dans un système.

$$k = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\sigma^4} \quad (I.2)$$

$\bar{x}$  : La moyenne de l'amplitude des vibrations.

$\sigma$  : L'écart-type.

- **Skewness** : c'est le coefficient de dissymétrie, correspond au troisième moment centré en statistique. Il représente une mesure de l'asymétrie de la distribution d'une variable réelle aléatoire. [158]

$$Skewness = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\sigma^3} \quad (I.3)$$

- **Facteur crête** : le facteur de crête (FC), largement employé dans la détection des défauts des roulements, est un indicateur qui indique la longévité de ces derniers. Lorsque le facteur crête diminue, cela constitue une situation alarmante et indique que la durée de vie de roulement est proche de sa fin. Il correspond à la division de la valeur crête par la valeur efficace, équation (I.4) :

$$FC = \frac{Peak}{RMS} = \frac{sup|x_i|}{RMS} \quad (I.4)$$

- **Facteur K** : le facteur K d'un signal représente le produit de la valeur crête par la valeur efficace, équation (I.5). Le coefficient K s'effectue en observant sa variation au cours de la détérioration du roulement, sa valeur augmente en fonction de l'usure du roulement.

$$K = Peak \times RMS \quad (I.5)$$

### I.7.2 Analyse fréquentielle

Les méthodes d'analyse dans le domaine fréquentiel permettent de révéler des informations spécifiques liées aux caractéristiques fréquentielles qui ne peuvent pas être observées directement dans le domaine temporel. Dans la pratique, les signaux vibratoires sont convertis

en une représentation fréquentielle en utilisant 3 analyses essentiels : analyse spectrale, cepstrale et d'enveloppe.

### I.7.2.1 Analyse spectrale

L'analyse spectrale est désormais l'outil essentiel dans le domaine du traitement des signaux vibratoires. Elle repose sur l'utilisation de la transformée de Fourier (FT) qui consiste à analyser les signaux complexes en décomposant chacun en une série de composantes sinusoïdales élémentaires et les représenter ensuite sous la forme d'un spectre « Amplitude-Fréquence ». Cette représentation détermine le spectre d'énergie ou de puissance du signal à la fréquence donnée, détectant la présence d'une anomalie induisant des chocs périodiques à une fréquence spécifique. On peut déterminer la localisation des défauts par la comparaison de cette fréquence avec les fréquences caractéristiques des défauts théoriques potentiels selon le tableau I.5 [159]. Il y'a deux catégories essentielles de FT, la transformation de fourrier continue (CFT) et la transformation de fourrier discrète (DFT), cette dernière revêt une importance capitale dans l'analyse spectrale des signaux temporels discrets  $x(n)$  qui peut être représenté par l'équation (I.6) : [139], [160].

$$X_{DFT}(k) = \sum_{n=0}^{N-1} x(n)e^{-\frac{2j\pi kn}{N}} \quad (I.6)$$

k: L'indice de fréquence ( $0 < k < N-1$ ).

Défauts	Fréquences caractéristiques
Balourd	Fréquence de rotation ( $F_r$ )
Désalignement	$F_r$ , vibrations radiales. $2F_r$ , vibrations axiales.
Roulements	$F_{b\ ext} = \frac{F_r}{2} N \left( 1 - \frac{d}{D} \cos\theta \right)$ (I.7) $F_{b\ int} = \frac{F_r}{2} N \left( 1 + \frac{d}{D} \cos\theta \right)$ (I.8) $F_{cage} = \frac{F_{b\ ext}}{N}$ (I.9) $F_{bille} = \frac{DF_r}{2d} \left[ 1 - \left( \frac{d}{D} \cos\theta \right)^2 \right]$ (I.10) N : Nombre d'éléments roulants. d : Diamètre des éléments roulants. D : Diamètre moyen du roulement. $\theta$ : L'angle de contact.
Engrenage	$F_{eng} = Z \times F_r$ (I.11) Z : nombre de dents.
Courroie	$F_c = \frac{\pi D}{L} F_r$ (I.12) D : Diamètre du poulie. L : longueur de la courroie.

Tableau I. 5 Fréquences caractéristiques des défauts.

### I.7.2.2 Analyse cepstrale

Le cepstre d'un signal  $x(t)$  est définie comme l'inverse de la transformée de Fourier du logarithme du spectre de puissance  $x(f)$  : [161]

$$C[x(t)] = C(\tau) = TF^{-1}[\log_{10}(x(f))] \quad (I.13)$$

$\tau$  : Quérence ; elle caractérise les intervalles de temps pendant lesquels les réponses impulsionnelles de la structure oscillent, et les forces d'excitation se répètent où se modulent.

L'objectif du cepstre est d'identifier et de mesurer toutes les structures périodiques présentes dans le spectre. Il établit des indicateurs appropriés pour détecter précocement les défauts à différents stades de progression. Le cepstre est défini par les amplitudes des composantes dont les quérences correspondent aux intervalles de temps des chocs périodiques provoqués par les anomalies notamment ceux des engrenages [145].

### I.7.2.3 Analyse d'enveloppe

L'analyse d'enveloppe, également connue sous le nom de HFRT (High Frequency Resonance Technique), représente une approche complémentaire au cepstre qui affecte par sa sensibilité élevée au bruit et aux variations aléatoires de la vitesse de rotation. Tout comme le cepstre, la HFRT est utilisée pour détecter et suivre l'évolution de défauts qui génèrent des forces impulsionnelles périodiques, mais sur une plage de fréquences beaucoup plus large. Elle est basée sur l'analyse du signal d'enveloppe obtenu en appliquant la transformée de Hilbert (HT) à un signal filtré dans une plage de fréquence centrée sur une ou plusieurs résonances de la structure, en effet, les fréquences les plus énergétiques dans le spectre du signal. Cela permet d'extraire des informations de basse fréquence difficilement détectables sur une porteuse haute fréquence [162].

HT est utilisé pour déterminer l'enveloppe d'un signal  $x(t)$ , définie par la formule suivante :

$$H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (I.14)$$

### I.7.3 Analyse temps-fréquence

Bien que les approches fréquentielles offrent de multiples avantages, elles présentent un problème essentiel d'être applicables uniquement aux signaux stationnaires, ce qui rend impossible l'association d'une signature fréquentielle à l'intervalle temporel spécifique. Pour surmonter ce problème, l'analyse temps-fréquence intègre à la fois les données temporelles et fréquentielles, consistant à étudier la variation temporelle d'un harmonique à une fréquence donnée. Cette méthode s'avère particulièrement pertinente pour surveiller et diagnostiquer les défauts, en extrayant des informations relatives aux caractéristiques présentes dans des signaux non stationnaires. Parmi les méthodes temps-fréquence, on peut citer :

La transformée de Fourier à court terme (STFT) consiste à segmenter un signal temporel long en fenêtres plus courtes, sur lesquelles est appliquée la transformée de Fourier. Cette procédure est itérée en déplaçant la fenêtre sur toute la longueur du signal, ce qui permet d'obtenir un ensemble de spectres locaux pour chaque intervalle de temps, aboutissant ainsi à une représentation temps-fréquence [163].

Morlet [164], [165], [166], a présenté analyse qui diffère légèrement de la STFT, plutôt que d'opter pour une fenêtre glissante le long d'un signal, Morlet a suggéré l'utilisation des "ondelettes". La transformée en ondelette (WT) permet de décomposer le signal vibratoire en

une série d'ondelettes mères dilatées et décalées, offrant ainsi une résolution temporelle élevée pour les hautes fréquences et une résolution fréquentielle précise pour les basses fréquences [140]. Il existe deux catégories principales de transformations en ondelettes : la transformée en ondelettes continue (CWT) consiste à analyser un signal en effectuant des mises à l'échelle et des décalages de manière continue de l'ondelette mère, ce qui permet d'obtenir une analyse approfondie mais qui requiert des calculs intensifs [167]. Et la transformée en ondelettes discrète (DWT) repose sur l'utilisation d'échelle et de décalages discrets, ce qui facilite la décomposition efficace d'un signal en différentes résolutions avec de faibles coûts de calculs [168].

Toutefois, ces approches peuvent rencontrer des obstacles lorsqu'elles sont appliquées à des signaux fortement non linéaires, ou lorsque la présence de bruit et de fluctuations rend l'interprétation plus complexe. Afin de surmonter ces contraintes, des approches empiriques plus récentes peuvent être utilisées pour améliorer l'analyse des signaux non stationnaires et non linéaires, elles décomposent les signaux vibratoires automatiquement sans nécessiter l'intervention d'un expert ou une connaissance approfondie des signaux contrairement aux approches classiques de traitement du signal. Parmi les méthodes empiriques, on trouve :

L'analyse de décomposition vibratoire de Hilbert (HVD) est employée pour extraire les composantes (modes) de signaux non stationnaires à large spectre. Elle repose sur un processus de décomposition récursif appliqué au signal résiduel de façon itérative. Cette approche se base sur l'utilisation de la transformée de Hilbert (HT) afin d'évaluer la fréquence moyenne de la composante dominante à chaque étape du processus. Malgré son efficacité pour la détection de signaux périodiques bruités, la complexité algorithmique de cette méthode peut entraîner la présence d'artefacts et une diminution de la précision [169].

La décomposition en modes variationnels (VMD) décompose le signal original en diverses composantes à bande limitée, représentées par un ensemble de fonctions appelées modes intrinsèques de fréquence (IMF). Chaque IMF est défini comme une série de signaux modulés en amplitude et en fréquence (AM-FM) présentant une largeur de bande limitée. Cette méthode présente une plus grande résistance au bruit et assure une analyse plus stable. Toutefois, elle exige une prédéfinition des paramètres tels que le nombre de modes, ce qui peut restreindre sa flexibilité [170].

La méthode de décomposition en mode empirique (EMD) réalise une décomposition adaptative du signal en se basant sur ses caractéristiques locales, ce qui permet d'obtenir une série de composantes IMFs présentant des échelles de temps typiques variées, offrant ainsi une fondation solide pour une réduction efficace du bruit. Malgré sa simplicité et son intuitivité, cette méthode est souvent sujette à des problèmes de mélange de modes, où plusieurs fréquences peuvent se superposer dans un même mode, ce qui rend l'analyse plus complexe [171]. Afin de dépasser cette contrainte, la technique de décomposition en mode empirique d'ensemble (EEMD) a été mise en place, ajoutant un bruit blanc au signal initial qui remplit de manière uniforme l'ensemble de l'espace temps-fréquence, cette approche facilite une séparation naturelle des différentes échelles de fréquence, réduisant ainsi l'occurrence du mélange de modes. Cependant, cette technique peut entraîner une diminution de la reproductibilité de la décomposition, tandis que la présence de bruit peut impacter la précision des résultats [172].

La méthode EEMD complémentaire (CEEMD) représente une amélioration algorithmique dérivée de la méthode EEMD, implique l'ajout itératif de paires de bruits de nature opposée au signal initial afin d'altérer la distribution des points extrêmes du signal, cela permet d'obtenir des enveloppes supérieures et inférieures reflétant les caractéristiques du signal, ce qui contribue à réduire le repliement modal de manière plus claire. Par contre, il peut être nécessaire d'apporter des ajustements manuels pour optimiser l'insertion de bruit et prévenir les interférences non désirées [173].

Le CEEMD avec bruit adaptatif (CEEMDAN) est une technique de décomposition avancée, permet de dépasser les limitations des techniques classiques telles que EMD et EEMD. En intégrant du bruit adaptatif à chaque itération, il atténue le phénomène de mélange de modes, ce qui assure une meilleure distinction entre les différentes composantes fréquentielles et favorise une décomposition plus fiable et reproductible. Contrairement à VMD et HVD, le CEEMDAN préserve l'intégrité du signal tout en étant capable de s'ajuster aux variations non stationnaires et non linéaires, cette caractéristique le rend particulièrement approprié pour l'analyse des signaux complexes [174]. Il est donc un choix favori pour le diagnostic et la détection précoce des défauts combinés en raison de sa robustesse et sa précision.

### I.8 Méthodes de diagnostic

Diverses méthodes ont été mise au point afin de résoudre les divers problèmes de diagnostic de défaut en se basant sur l'approche de la détection et de l'identification des fautes (FDI). Cette méthode est employée pour détecter les défauts, déterminer leur nature et leur emplacement, dans le but de prévenir les pannes non planifiées et de réduire au minimum la perte de productivité qui en découle.

Dans le cadre de l'approche FDI, la détection des défauts s'effectue en trois étapes [175] :

- Détecter la présence d'un défaut.
- Localiser la faute.
- Déterminer l'ampleur de l'erreur (l'identifier).

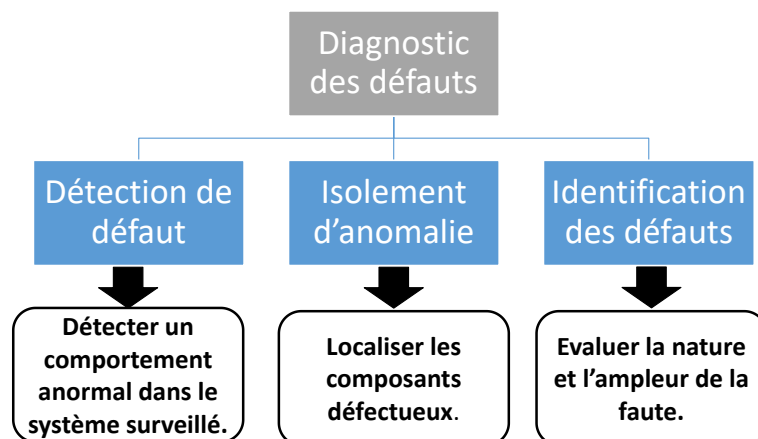


Figure I. 19 Différentes étapes du diagnostic des défauts.

Il existe diverses techniques de diagnostic, regroupées en deux catégories principales, qui sont basées sur des modèles et sur des données.

### I.8.1 Méthodes de diagnostic à base de modèles

Les techniques de diagnostic de défauts par modèles se basent sur l'utilisation des systèmes physiques. Leur principe fondamental repose sur la comparaison des données observées pendant le fonctionnement du système avec les connaissances préalablement acquises sur son comportement normal et ses modes de défaillance. En fonction de la nature du modèle (quantitatif et/ou qualitatif), il est possible de catégoriser les approches en deux branches distinctes : les méthodes quantitatives et les méthodes qualitatives [175].

Les méthodes qualitatives reposent sur la configuration du modèle de système, les liens de causalité et les relations régies par des règles afin de réaliser des inférences de diagnostic. Ces approches basant sur des modèles symbolique (non mathématique) utilisent fréquemment des représentations graphiques telles que les diagrammes, les graphes bipartites ou les arbres de défaillance, qui permettent d'évaluer la surveillance, l'observabilité et le contrôle en se basant sur les caractéristiques structurelles des graphes. Toutefois, en raison de leur caractère qualitatif, ces méthodes présentent des limitations dans leur capacité à discriminer de manière précise les défaillances [176].

Les méthodes quantitatives offrent une solution aux limitations des approches qualitatives, en se fondant sur l'évaluation de l'état de fonctionnement en se basant sur des modèles mathématiques du système qui décrivent son comportement. Lorsque la différence entre le comportement observé et le comportement prédit du système physique dépasse un seuil prédéfini, une défaillance est alors identifiée. Suite à l'étape de détection, un résidu sera engendré puis comparé à l'ensemble des signatures de défauts répertoriées, dans le but d'isoler et d'identifier la défaillance. Au sein des diverses approches de détection et de diagnostic reposant sur des modèles mathématiques, on distingue principalement l'utilisation de l'espace de parité, des observateurs et de l'estimation paramétrique. Cependant, cette approche nécessite une excitation continue, ce qui peut être un problème pour les processus stationnaires [177].

### I.8.2 Méthode de diagnostic à base de données

Le principe fondamental de FDI basé sur les données réside dans la création d'un modèle de FDI à partir des données historiques du système, de manière directe. Ceci permet de simplifier la complexité liée à la création et à l'étalonnage du modèle physique. Les méthodes centrées sur les données englobent un large éventail de techniques, notamment celles basées sur l'intelligence artificielle (IA) telles que les systèmes experts [178], la reconnaissance de formes [179], ainsi que les approches en apprentissage automatique (ML) [180] et en apprentissage profond (DL) [181]. Cette étude se concentre principalement sur les approches de DL qui sont considérées comme les outils appropriés pour effectuer cette tâche en exploitant les données collectées par les capteurs, sans recourir à une modélisation complexe difficile à mettre en œuvre dans ce contexte [176].

### **I.9 Conclusion**

Ce chapitre a abordé de manière succincte le concept fondamental des systèmes de transmission mécanique entraînés par un moteur triphasé à induction, mis en évidence leur importance dans ces systèmes en raison de leur robustesse et leur efficacité. Nous avons également présenté les principales anomalies mécaniques observées dans le système de transmission, en décrivant les diverses techniques de maintenance basant sur la maintenance prédictive et leur méthodologie de diagnostic. Une attention particulière a été apporté à l'analyse vibratoire, qui est considérée comme méthode la plus courante et la plus informative pour la surveillance ou les principales techniques dédiées à exploiter et traiter les données vibratoires sont détaillées. Enfin, nous avons abordé les différentes approches de détection et d'identification des fautes (FDI) reposant sur l'intelligence artificielle que l'on trouve dans le prochain chapitre.

# Chapitre II :

# Méthodes de classification pour le diagnostic des défauts

### II.1 Introduction

L'Intelligence Artificielle (IA) représente un champ d'étude en informatique dont l'objectif est de concevoir des systèmes informatiques capables de reproduire les capacités cognitives humaines. Il a révolutionné le domaine de la maintenance industrielle en introduisant de nouvelles opportunités, telles que la surveillance en temps réel de l'état des équipements et la prédiction des pannes potentielles, dans le but d'éviter les interruptions non planifiées et les dépenses qui en découlent. L'évolution des machines industrielles tournantes a entraîné une augmentation significative et une diversification des données à analyser. Les algorithmes classiques d'apprentissage automatique ont rencontré des difficultés en raison de cela. Récemment, le deep learning a été intégré en tant que nouvelle branche de l'apprentissage machine pour aborder ces problématiques, offrant ainsi une approche efficace pour extraire automatiquement des caractéristiques complexes à partir des données brutes sans nécessiter d'intervention humaine, le positionnant ainsi comme une méthode avancée dans le domaine du diagnostic des défauts combinés. Ce chapitre vise à exposer les principes fondamentaux nécessaires à la conception d'un système de classification des défauts reposant sur l'apprentissage profond. Dans un premier temps, nous exposerons les concepts de l'apprentissage automatique et de l'apprentissage profond. Ensuite, nous examinerons les thèmes des réseaux de neurones convolutifs et des réseaux de neurones convolutifs bayésiens.

### II.2 La classification intelligente de défauts

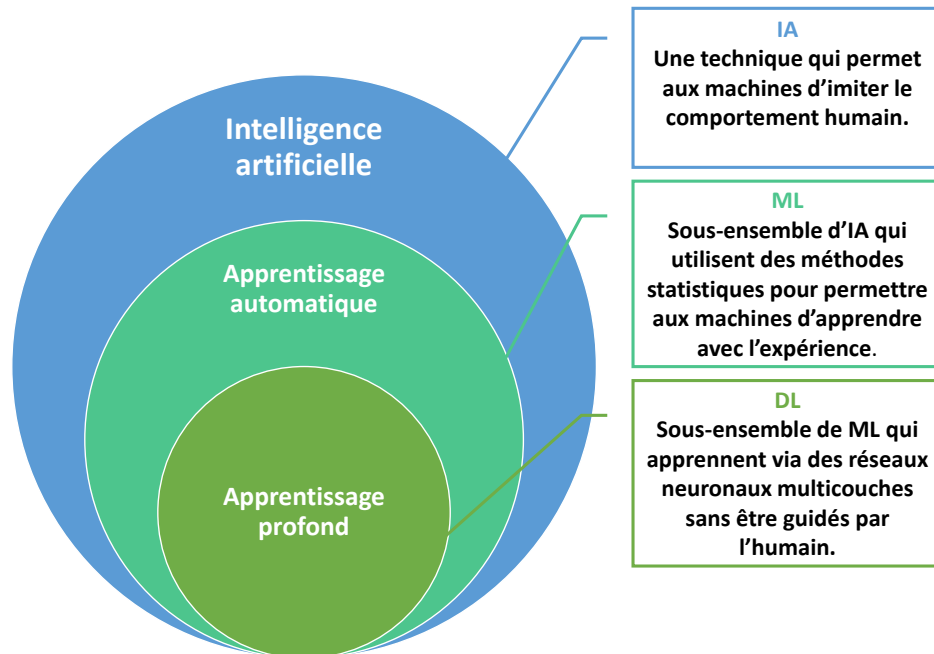
Comme indiqué au chapitre précédent, le diagnostic des défauts des machines tournantes se divise en deux approches principales : le diagnostic à base de modèles et le diagnostic sans modèles. Le diagnostic basé sur des modèles utilise des modélisations mathématiques pour décrire le comportement d'un système et ses modes de défaillance. Bien qu'elle soit efficace, cette méthode nécessite la création d'un modèle précis, ce qui peut être difficile, voire impossible, pour les systèmes complexes. En réponse à cette limitation, le diagnostic sans modèles a été développé et s'appuie sur l'analyse des données de surveillance collectées par des capteurs, évitant ainsi la modélisation explicite du système.

La détection des anomalies au sein des données constitue une compétence essentielle à enseigner aux systèmes de transmissions mécaniques. Actuellement cette détection des défauts et leur classification sont mises en œuvre dans le domaine de l'intelligence artificielle (IA) dans le cadre de la maintenance prédictive des équipements industriels. Cette tâche constitue une variante de la classification, dont l'objectif est de déterminer si l'information fournie à la machine correspond à une situation ordinaire ou à une situation irrégulière. De plus, elle peut également fournir des indications sur la nature de cette irrégularité [182].

### II.3 Intelligence artificielle (IA)

L'intelligence artificielle constitue un domaine d'étude étendu, se consacrant à la conception de machines intelligentes capables de réaliser des tâches habituellement requérant une forme d'intelligence humaine. Un système est considéré comme intelligent lorsqu'il possède la capacité d'apprendre et d'exécuter une tâche associée au processus auquel il est assigné sans intervention humaine, tout en garantissant une grande précision [183]. L'intelligence artificielle a été appliquée dans le domaine de la maintenance des machines tournantes par l'analyse vibratoire, connue pour une évolution significative au cours des dernières années, principalement en raison des techniques avancées d'IA. Ces méthodes permettent de détecter

de manière précoce l'apparition d'anomalies à travers l'analyse des signaux [184]. L'objectif de cette étude est de détecter et classifier les défauts de transmissions mécaniques, en recourant à des techniques d'intelligence artificielle tels que l'apprentissage automatique (ML) et profond (DL) comme illustré à la figure II.1.



**Figure II. 1** Les domaines de l'intelligence artificiel.

### II.4 Apprentissage automatique (ML)

L'apprentissage automatique est une branche de l'intelligence artificielle, qui se focalise sur le développement d'algorithmes et de modèles capables d'extraire des connaissances à partir de données, afin de réaliser des prédictions ou de prendre des décisions sans recourir à une programmation explicite ni à une intervention humaine. Son principal objectif est de concevoir des systèmes capables d'apprendre et de s'améliorer à travers l'expérience, plutôt que de se restreindre à l'exécution d'instructions spécifiques pour chaque tâche. Les algorithmes optimisés sont généralement formés sur un ensemble de données d'entraînement et ajustés pour améliorer leur précision tout en minimisant le temps de calcul. Une fois qu'un modèle a été entraîné, il peut être utilisé pour effectuer des prédictions sur des nouvelles données [185].

Les catégories de l'apprentissage automatique peuvent être classées en trois groupes, comme illustré dans la figure II.2 : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement.

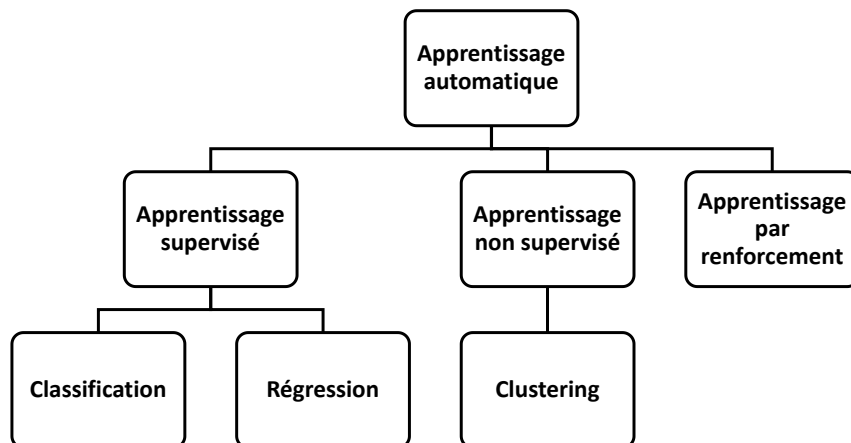


Figure II. 2 Les différents types d'apprentissage automatique.

#### II.4.1 Apprentissage supervisé

Dans le cadre de l'apprentissage supervisé, un algorithme acquiert la capacité de formuler des prédictions ou de prendre des décisions en se fondant sur des données d'apprentissage préalablement étiquetées. Autrement dit, les données d'entrées sont liées à une étiquette de sortie ou à une valeur cible correspondante, permettant ainsi à l'algorithme d'apprendre à établir une association entre l'entrée et la sortie appropriée. L'objectif principal consiste à formuler des prédictions précises concernant les futures observations d'entrée-sortie, tout en s'efforçant de minimiser les erreurs autant que possible [186].

Durant le domaine de l'application, l'apprentissage automatique supervisé se divise essentiellement en deux catégories : la classification et la régression. Le premier acquiert une compréhension des frontières entre les classes afin de réaliser la classification des nouvelles données. Le deuxième modèle ajuste les régularités aux données afin de prédire les propriétés de nouveaux points de données. De manière similaire, le diagnostic des défauts au sein des machines industrielles constitue un problème de classification, tandis que le pronostic des défauts s'apparente à un problème de régression [185].




Figure II. 3 Apprentissage supervisé.

### II.4.2 Apprentissage non supervisé

L'apprentissage non supervisé constitue une approche d'apprentissage automatique dans laquelle l'algorithme s'efforce de découvrir de manière autonome les caractéristiques discriminantes, sans recourir à des étiquettes prédéfinies. L'objectif de ce type consiste à identifier des structures ou des modèles cachés au sein de grands ensembles de données. De manière générale, les systèmes d'apprentissage non supervisés recourent à des algorithmes de regroupement (clustering) ou d'association afin de réaliser des tâches de classification. Les algorithmes de clustering sont employés pour regrouper des points de données présentant des similarités, fondées sur leurs caractéristiques communes, comme le démontre la figure II.4. Par ailleurs, les algorithmes d'association ont pour objectif d'identifier des relations ou des associations significatives entre les variables d'un ensemble de données [187].




Figure II. 4 Apprentissage non supervisé.

### II.4.3 Apprentissage par renforcement

L'apprentissage par renforcement représente une technique d'apprentissage automatique permettant à un agent de prendre des décisions et d'interagir avec son environnement sans instructions directes de l'humain, dans le but d'identifier un modèle d'action optimal qui maximise les récompenses ou minimise les risques. Les robots ainsi que les véhicules autonomes constituent des illustrations d'agents autonomes. Dans le cadre de l'apprentissage par renforcement, les agents autonomes acquièrent la capacité d'exécuter des tâches par le biais d'une approche d'essai-erreur, en s'appuyant sur les retours d'information relatifs à leurs propres actions et expériences, l'apprentissage par renforcement aborde spécifiquement les problématiques de prise de décision séquentielle au sein d'un environnement incertain, et il est susceptible d'accélérer le progrès de l'intelligence artificielle [188].

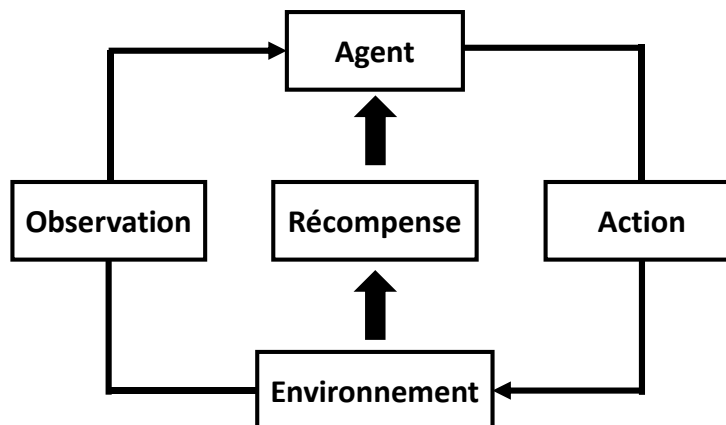


Figure II. 5 Apprentissage par renforcement.

#### II.4.4 Comparaison des différents types d'apprentissage automatique

Il existe une variété d'algorithmes d'apprentissage automatique ; il convient donc de s'interroger sur le choix de celui à utiliser. Un premier critère de sélection se rapporte au type d'apprentissage souhaité ou envisagé, par conséquent, le choix entre l'apprentissage supervisé, non supervisé ou par renforcement sera déterminée en fonction des exigences spécifiques de la tâche envisagée et des données disponibles [189].

Le tableau ci-après synthétise les différences entre les 3 types d'apprentissage automatique [190]:

Critères d'évaluation	Apprentissage supervisé	Apprentissage non supervisé	Apprentissage par renforcement
Données nécessaires	Étiquetées	Non étiquetées	Interaction avec un environnement
Objectif visé	Classifier ou prédire	Découvrir des structure	Maximiser une récompense
Exemples représentatifs	<b>Classification :</b> -Détection de défauts. -Classement des images. -Diagnostic. <b>Régression :</b> -Prédictions. -Processus optimal. -Nouvelles perspectives.	<b>Clustering (regroupement) :</b> -Système de recommandation. - segmentation. -Exploration des données. -Compression.	- Décision en temps réel. -Jeu IA. -Navigation des robots. -Acquisition de compétences.
La complexité	Moyenne	Variable	Élevée

Tableau II. 1 Les trois principaux types de l'apprentissage automatique.

Selon le tableau, l'apprentissage supervisé constitue une approche privilégiée pour le diagnostic et la détection des anomalies, en raison de sa capacité à exploiter des données étiquetées afin de classifier avec précision les états normaux et défailants. Il s'adapte aux systèmes industriels complexes, présente une bonne capacité de génération sur de nouvelle données et facilite une intégration efficace dans des système de surveillance en temps réel. Bien qu'il requière des données annotées et une actualisation régulière, cet outil facilite une

détection précoce des anomalies, contribuant ainsi à l'optimisation des performances industrielles.

### II.4.5 Les techniques de classification supervisée

La classification consiste à organiser des éléments en classes ou en catégories en fonction de leurs caractéristiques communes, les méthodes de classification supervisée impliquent le classement d'objets en se fondant sur une base de données désignée comme étant d'apprentissage. Divers types de classificateurs ont été élaborés dans le domaine de l'apprentissage automatique afin d'atteindre une précision et une efficacité optimales [185].

Nous procéderons à une présentation succincte des techniques d'apprentissage automatique les plus fréquemment employés.

#### II.4.5.1 Machines à vecteurs de support (SVM)

L'algorithme de machines à vecteurs de support (SVM) est couramment employé dans le domaine de l'apprentissage automatique en raison de sa capacité à gérer des tâches de classification tant linéaires que non linéaires. Cependant, lorsque les données ne peuvent pas être séparées de manière linéaire, des fonctions de noyau sont employées pour projeter les données dans un espace de dimension supérieure, facilitant ainsi leur séparation linéaire. L'application des fonctions de noyau est couramment désignée sous le terme d'« astuce du noyau ». Le choix de la fonction de noyau, qu'il s'agisse de noyaux linéaires, de noyaux polynomiaux, de noyaux à base radiale ou de noyaux sigmoïdes, est déterminé par les caractéristiques de données ainsi que le cas d'utilisation spécifique.

L'objectif de l'algorithme SVM consiste à établir la ligne ou la frontière de décision la plus efficace pour séparer deux catégories de classes (classe positive ou classe négative), en identifiant l'hyperplan optimal qui maximise la marge entre les points de données les plus proches des classes adverses. Le nombre de caractéristiques existantes dans les données d'entrée détermine si l'hyperplan se manifeste sous la forme d'une ligne dans un espace à deux dimensions ou d'un plan dans un espace à  $n$  dimensions. Étant donné qu'il est possible d'identifier plusieurs hyperplans pour distinguer les classes, la maximisation de la marge entre les points permet à l'algorithme de déterminer la frontière de décision optimale entre les classes. Cela lui permet, à son tour, de se généraliser efficacement à de nouvelles données et d'effectuer des prédictions de classification avec précision. Les lignes situées à proximité de l'hyperplan optimal sont désignées sous le terme de vecteurs de support, en raison du fait que ces vecteurs traversent les points de données qui définissent la marge maximale [191], [192].

Examinons le diagramme présenté ci-dessous, dans lequel deux catégories distinctes sont classées à l'aide d'une frontière de décision ou d'un hyperplan selon la figure II.6. En revanche, cet algorithme présente une efficacité réduite lorsqu'il est appliqué à des ensembles de données volumineux et éprouve des difficultés à s'adapter à des tâches de classification multi classes complexes, telles que celles impliquant des défauts combinés.




Figure II. 6 Machines à vecteurs de support pour la classification binaire.

#### II.4.5.2 Arbre et forêt de décision

Un arbre de décision constitue l'une des méthodes d'apprentissage supervisé, il est un outil d'identification basé sur la résolution de problèmes à l'aide de questions/réponses, cet outil représente un dispositif de classification de premier plan, en raison de la précision remarquable de ses performances ainsi que de son faible coût computationnel, offrant un cadre à la fois transparent et interprétable pour la détection et la classification des défauts. Il permet de structurer l'analyse des défaillances en s'appuyant sur des symptômes quantifiables, tels que des vibrations anormales, des bruits atypiques ou des fluctuations de vitesse. Chaque nœud de l'arbre symbolise une étape du processus de diagnostic, telle que l'examen de l'état des engrenages, l'évaluation de l'alignement des axes ou l'analyse des roulements. Par exemple, un excès de vibrations peut indiquer des causes potentielles d'un désalignement.

Cette approche se caractérise par une structure arborescente hiérarchique, comprenant un nœud racine, des branches, des nœuds internes et des nœuds feuilles. Comme l'illustre le diagramme ci-dessous, un arbre de décision débute par un nœud racine, lequel ne possède aucune branche entrante, ce nœud constitue le point de départ de l'arbre et représente l'ensemble des données d'apprentissage. Les données sont ensuite segmentées en plusieurs sous-groupes, selon une variable discriminante (un des attributs). Les branches issues du nœud racine transmettent par la suite des données aux nœuds internes, généralement désignés sous le terme de nœuds de décision. Chaque nœud représente une question relative à un attribut spécifique [193]. En s'appuyant sur les caractéristiques disponibles, les deux catégories de nœuds procèdent à des évaluations afin de constituer des sous-ensembles homogènes, appelés nœuds feuilles ou nœuds terminaux. Ces nœuds constituent l'ensemble des résultats (classes) possibles présents dans l'ensemble de données [194].




Figure II. 7 Arbre de décision.

En revanche, cette technique peut être sujette au surapprentissage, en raison d'une adaptation excessive aux données d'entraînement, ce qui restreint sa capacité de généralisation. De plus, ces modèles présentent une instabilité, une légère variation dans les données peut conduire à une structure d'arbre radicalement différente. Elle peut présenter des complexités d'utilisation lorsqu'un arbre est très profond [195].

Afin de surmonter ces limites, l'algorithme de forêt d'arbre décisionnel est mis en œuvre, qui est capable de générer un ensemble d'arbres décisionnels aléatoire à partir d'un ensemble de données. Cette méthode détermine la prédiction optimale pour chaque arbre et choisit la décision la plus appropriée par le biais d'un processus de vote. Par conséquent, cela exige l'implémentation de plusieurs arbres générant des valeurs, ce qui atténue le surapprentissage de l'algorithme en procédant à une moyenne des résultats obtenus [196].

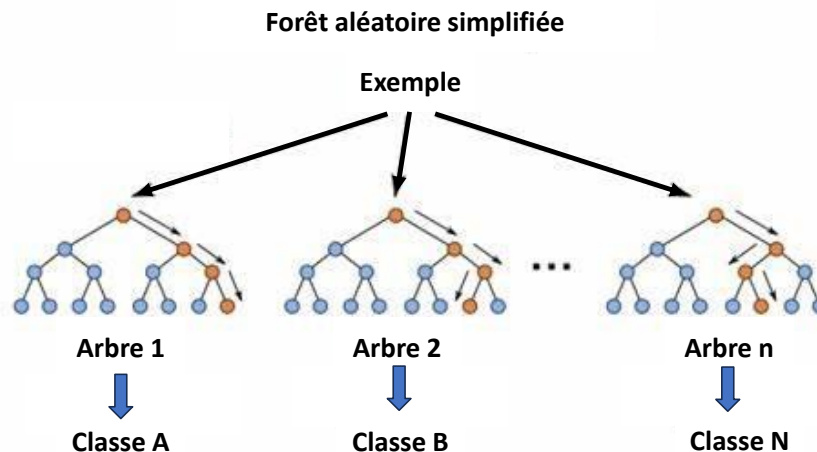


Figure II. 8 Forêt d'arbre décisionnel.

### II.4.5.3 L'algorithme des K-voisins les plus proches (KNN)

L'algorithme des K plus proches voisins (K-Nearest Neighbors KNN) constitue une méthode classique et élémentaire de classification, largement employée dans divers domaines, notamment la reconnaissance de forme, l'exploration de données et la détection de fraudes. Le principe de cet algorithme repose sur l'identification des K échantillons d'apprentissage les plus proches d'un point de test spécifique dans l'espace des caractéristiques. Il se forme à

partir de données étiquetées et vise à prédire la classe associée à des variables d'essai, en mesurant la distance entre la variable explicative d'essai et les points d'entraînement. En d'autres termes, cette méthode consiste à enregistrer les points d'entraînement, puis à prendre une décision de classification pour de nouveaux points en fonction des valeurs de leurs voisins. La valeur de  $K$  constitue un hyperparamètre susceptible d'être ajusté afin d'optimiser les performances de l'algorithme [197].

Ci-après, un exemple de méthode impliquant deux voisins est présenté, l'objectif consiste à déterminer à quelle classe le point  $X$  est associé.




Figure II. 9 Fonctionnement de l'algorithme KNN.

### II.5 Les réseaux de neurones artificiels (ANN)

Les réseaux de neurones artificiels constituent des modèles computationnels qui s'inspirent de la structure et du fonctionnement des réseaux de neurones biologiques, notamment ceux présents dans le cerveau humain, ils sont employés pour aborder des problèmes complexes liées à l'apprentissage automatique, à la classification, à la reconnaissance de motifs, ainsi qu'à de nombreuses autres applications.

Un réseau de neurones constitue un ensemble d'opérateurs non linéaires interconnectés, qui reçoit des signaux externes par le biais de ses entrées et génère des signaux de sortie. Ces réseaux de neurones représentent une métaphore des structures cérébrales, illustrant le traitement parallèle et la distribution de l'information, et comportent plusieurs éléments de traitement désignés sous le terme de neurones. Chaque neurone opère de manière autonome par rapport aux autres, de sorte que l'ensemble constitue un système parallèle hautement interconnecté. L'information conservée par le réseau de neurones est répartie entre l'ensemble de ses composants, plutôt que d'être localisée dans une portion spécifique de la mémoire sous la forme d'un symbole.

Le réseau de neurones n'est jamais programmé pour exécuter une tâche spécifique ; il est plutôt entraîné sur des données collectées, grâce à un mécanisme d'apprentissage qui agit sur les éléments constitutifs du réseau afin d'optimiser l'exécution de la tâche visée.

Les réseaux de neurones artificiels se composent de multiples unités de calcul, désignées sous le terme de neurones ou nœuds, qui sont agencées en différentes couches. Chaque neurone reçoit des entrées qui sont pondérées, effectue une somme pondérée de ces entrées, puis applique une fonction d'activation non linéaire afin de générer une sortie [198].

Dans son modèle le plus élémentaire, un ANN se compose exclusivement de trois couches de neurones [199] selon la figure II.10:

- La couche d'entrée : celle par laquelle les données pénètrent dans le système.
- La couche cachée : où les informations sont analysées.
- La couche de sortie : c'est l'instance où le système détermine les actions à entreprendre en fonction des données reçues.

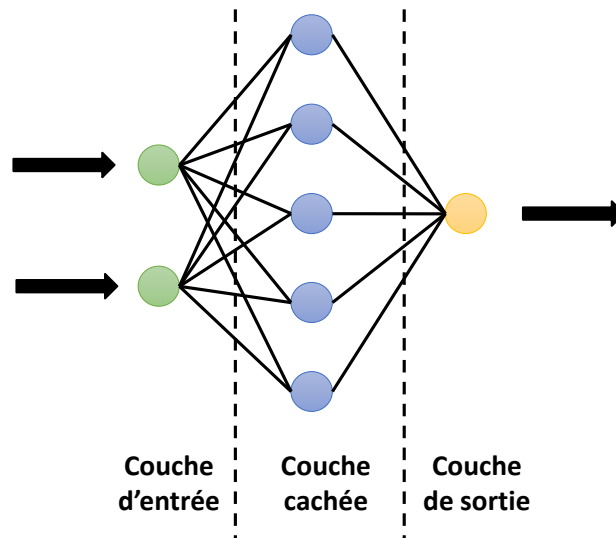


Figure II. 10 Schéma d'un réseau de neurone artificiel.

Comme illustré dans la figure II.11, un neurone artificiel reçoit des entrées notées  $X = \{x_1, x_2, \dots, x_n\}$ . Les poids synaptiques  $W = \{w_1, w_2, \dots, w_n\}$  reflètent l'importance relative des signaux d'entrée. Le biais noté ( $b$ ) représente un terme constant permettant d'ajuster le point de départ de la fonction d'activation  $f$  qui est constituée une fonction non-linéaire appliquée à la somme pondérée des entrées et des poids synaptiques. Enfin, la sortie notée ( $z$ ) correspond à la réponse du neurone, laquelle peut être interprétée soit comme une sortie finale, soit comme une entrée vers d'autres neurones. La sortie ( $z$ ) d'un neurone formel est déterminée par le calcul de la fonction  $f(x)$  selon l'équation suivante [185]:

$$z = f(w_1x_1 + \dots w_nx_n + b) \quad (\text{II.1})$$

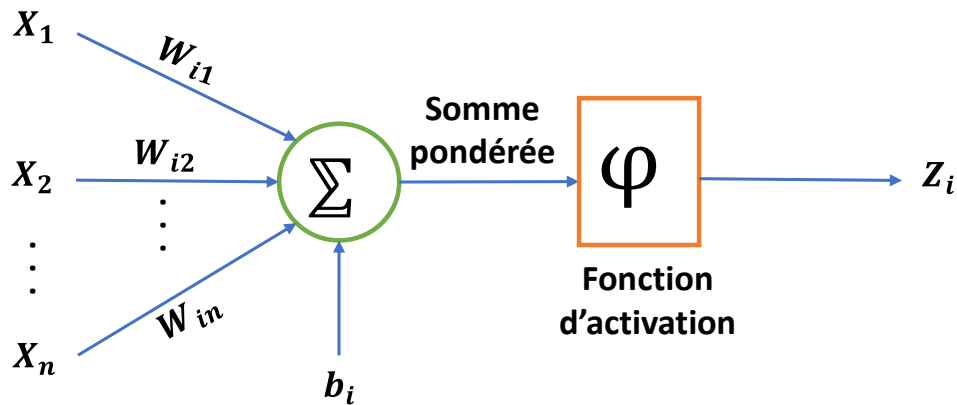


Figure II. 11 Modèle d'un neurone artificiel.

- **Le poids** : le poids constitue le coefficient qui régule le signal d'entrée ; autrement dit, il détermine l'impact de l'entrée sur la sortie.
- **Le biais** : le biais est relié aux neurones de la couche précédente par l'intermédiaire d'un poids, souvent appelé seuil. Il présente une analogie avec l'ordonnée à l'origine ajoutée dans une équation linéaire. Il s'agit d'un paramètre additionnel au sein du réseau neuronal, servant à moduler la sortie en fonction de la somme pondérée des entrées du neurone. Ainsi, le biais constitue une constance qui permet au modèle de s'ajuster de manière optimale aux données.
- **La fonction d'activation** : la fonction d'activation constitue une fonction mathématique déterminante pour le type d'information générée par le neurone. Elle intervient après le calcul de la somme pondérée et l'ajout du biais, exerçant une influence significative sur les performances du réseau. Il est donc essentiel de sélectionner judicieusement le type de fonction d'activation approprié pour chaque couche du réseau. À noter que les neurones d'entrée ne disposent pas de fonction d'activation, mais utilisent plutôt la fonction identité [200].

Fonction	Équation	Représentation graphique
Heaviside (Échelon)	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	
Rampe (Linéaire)	$f(x) = x$	
Sigmoïde	$f(x) = \frac{1}{1 + e^{-x}}$	

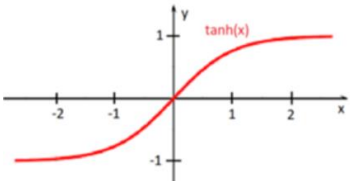

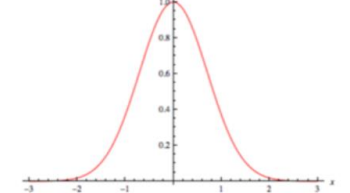
Tangente hyperbolique	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
Unité de rectification linéaire (ReLU)	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
Gaussienne	$f(x) = e^{-x^2}$	

Tableau II. 2 Différents types de fonctions d'activations.

### II.5.1 Entraînement d'un réseau de neurone

Le processus d'entraînement d'un réseau de neurones consiste à faire passer les données d'entrée à travers le réseau, ce qui est désigné par le terme de propagation avant, puis à mettre à jour les poids et les biais en fonction de l'erreur de la sortie du réseau, ce qui est connu sous le nom de rétropropagation [201], [202].

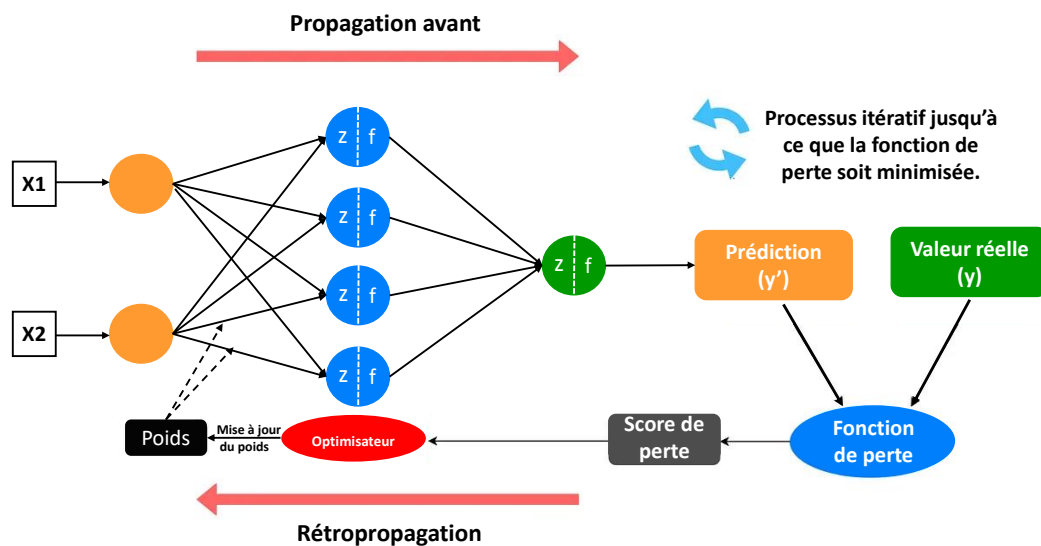


Figure II. 12 Entraînement d'un réseau de neurone.

- 1. Propagation avant :** Désigne le processus par lequel les données d'entrée sont transmises à travers les différentes couches d'un réseau de neurones artificiels. Au cours de la propagation avant les données d'entrée sont traitées de manière itérative, couche par couche, en appliquant des poids et des biais qui sont optimisés durant le processus d'apprentissage du réseau. À chaque couche, la somme pondérés de ses

entrées est calculée, suivie de l'application d'une fonction d'activation qui génère une sortie. Cette sortie est ensuite transmise à la couche suivante, et ce processus se répète jusqu'à atteindre la couche de sortie, où la valeur prédite finale est obtenue.

2. **Calcul de l'erreur** : Après avoir obtenu la sortie du réseau, celle-ci est comparée à la sortie réelle attendue, c'est-à-dire à la vérité de terrain dérivée des données d'entraînement. Employons la fonction de perte afin de quantifier la différence entre la valeur prédite ( $y'$ ) obtenue par les calculs, et la valeur réelle ( $y$ ) pour évaluer l'erreur commise par le réseau dans ses prédictions.
3. **Rétropropagation** : Cette méthode simplifie le calcul de l'erreur pour chaque neurone en suivant un parcours de la dernière couche à la première. C'est à cet endroit que se déroule le processus d'apprentissage. Pour chaque couche, les gradients de la fonction de coût pour les sorties de cette couche sont calculés par rapport aux poids et aux biais, ce qui nous permet de déterminer dans quelle mesure la modification de chaque poids et de chaque biais influencerait l'erreur.
4. **Calcul des gradients** : La fonction de coût permet d'évaluer l'écart entre les prédictions et les valeurs réelles. Pour améliorer le modèle, il est nécessaire de minimiser cette fonction de coût à l'aide d'un algorithme d'optimisation tel que la descente de gradient, d'autres algorithmes peuvent également être utilisés, notamment Stochastic Gradient, AdaGrad, RMSprop et ADAM. La descente de gradient ajuste de manière itérative les paramètres, les orientant dans la direction qui minimise la fonction de coût, jusqu'à ce qu'elle identifie les paramètres correspondant au coût le plus bas possible.

À chaque itération de l'algorithme d'apprentissage, les poids dans un réseau de neurones utilisant la descente de gradient sont mis à jour. La mise à jour est calculée pour chaque poids de la manière suivante :

$$w = w - \alpha \frac{\partial E}{\partial w} \quad (\text{II.2})$$

$\alpha$  : Le taux d'apprentissage.

$E$  : La fonction de coût.

$\frac{\partial E}{\partial w}$  : Descente de gradient.

On répète ce cycle à plusieurs itérations (ou époques) au cours du processus d'apprentissage, ce qui permet progressivement d'améliorer la précision des prédictions du réseau en ajustant ses poids et ses biais, ce qui lui permet d'apprendre de ses erreurs.

Dans le domaine de l'apprentissage des réseaux de neurones, il est possible de rencontrer des architectures qui se basent exclusivement sur la phase de propagation avant, sans avoir recours à la rétropropagation. Ces réseaux, communément désignés sous le nom de réseaux à propagation directe, se limitent à acheminer les données des entrées vers les sorties sans effectuer d'itération pour ajuster les poids en fonction de l'erreur. À la différence des réseaux entraînés par rétropropagation, qui se basent sur l'utilisation du gradient de l'erreur pour itérer l'amélioration des poids synaptiques.

### II.5.2 Les différents types de réseaux de neurones

Les réseaux neuronaux peuvent être catégorisés en plusieurs types, chacun étant destiné à des applications spécifiques. Bien qu'il ne s'agisse pas d'une liste exhaustive, les réseaux

neuronaux présentés ci-dessous illustrent les types de réseaux à propagation directe les plus fréquemment rencontrés [203]:

### II.5.2.1 Perceptron Multicouche

Le perceptron multicouche est une architecture de réseau de neurones artificiels qui est caractérisée par l'utilisation de plusieurs couches de neurones pour le traitement des données en entrée et la génération de données en sortie. La figure II.13 présente de manière explicite l'architecture caractéristique d'un réseau multicouche. Il est constitué d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie. Les données se propagent de la couche d'entrée à la couche de sortie de manière unidirectionnelle, formant ainsi un réseau de neurones à propagation directe (feedforward), où la couche d'entrée reçoit des données d'entrée exprimées sous la forme de valeurs numériques. Par la suite, elle transmet ces données aux couches cachées, où la plupart des calculs sont effectués, en réalité, chaque couche cachée est composée d'un ensemble de neurone artificiels agissant comme des unités de traitement de base. Ces neurones reçoivent des entrées des couches précédentes et utilisent des coefficients synaptiques pour appliquer un ensemble de poids et de biais à ces entrées. Le résultat de cette opération sera soumis à une fonction d'activation pour produire la sortie de la fonction [186].




Figure II. 13 Perceptron multicouche.

### II.5.2.2 Réseau à Fonction Radiale

Une alternative viable au perceptron multicouche (MLP) est représentée par le réseau à fonction de base radiale (RBF). Ce dernier se présente comme un réseau feedforward multicouche comprenant une unique couche d'entrée et de sortie, ainsi qu'une couche cachée composée d'unités de traitement non linéaires, comme illustré dans la figure II.14. La sortie d'un réseau RBF avec un vecteur d'entrée  $x \in R^n$  est caractérisée par l'équation ci-dessous :

$$y = f(x) = \sum_{i=1}^N w_i R_i \quad (\text{II.3})$$

$N$  : Le nombre de neurones dans la couche cachée.

$w_i$ : Les poids du réseau neuronal.

$R_i$ : Les fonctions d'activation de base radiale, définies par :

$$R_i(u) = \phi(\|x - c_i\|), c_i \in R^n \quad (\text{II.4})$$

$\varphi$  : La fonction gaussienne atteint son maximum à l'origine et tend vers zéro lorsque son argument tend vers l'infini.

$c_i$  : Vecteur central du neurone  $i$ .

La fonction dépend de manière décroissante de la distance entre l'entrée et le vecteur central, il y'a une multitude d'options de fonctions disponible. La fonction gaussienne est fréquemment choisie comme fonction de base radiale pour développer une fonction de décision locale qui se concentre sur un sous-ensemble spécifique de l'espace d'entrée. Une fois que les fonctions de base radiales sont définies, les seuls paramètres du réseau pouvant être ajustés sont les poids. Étant donné leur lien linéaire avec la sortie  $y$  et par conséquent avec l'erreur de sortie, ces paramètres peuvent être ajustés en utilisant une méthode directe des moindres carrés. C'est ce qui a rendu les réseaux à base radiale attrayants pour l'identification du défaut, ils ont la capacité d'effectuer des calculs complexes et leur apprentissage est plus rapide et plus simple, cependant, ils nécessitent une plus grande capacité neuronale par rapport aux réseaux multicouches. En outre, ils sont plus sensibles à la destruction de leurs poids [186],[204].

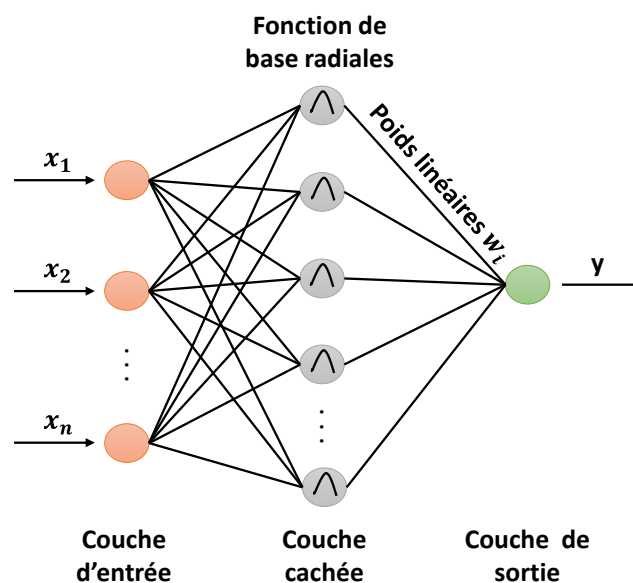


Figure II. 14 Réseau à fonction de base radiale (RBF).

### II.5.2.3 Réseaux de Neurones Probabilistes

Les réseaux de neurones probabilistes (PNN) sont une forme spécifique des réseaux de neurones à base radiale (RBF) peut s'avérer utile dans le cadre de la classification multi-classes, disposons un ensemble de données pour chaque classe, dans le but de catégoriser et estimer la probabilité qu'un nouvel échantillon de données fasse partie d'une catégorie apprise. Les PNN reposent sur des principes statistiques, en exploitant les fonctions de densité de probabilité (PDF) et la prise de décision bayésienne afin d'obtenir des résultats de classification précis et fiables.

L'algorithme PNN utilise une approche où la fonction de distribution de probabilité (PDF) de chaque classe est approximée à l'aide d'une fenêtre de Parzen. Cette méthode repose sur

l'estimation de la densité du noyau (Kernel density estimation KDE), qui est une technique non paramétrique ne faisant aucune distribution prédéfinie pour les données. Par la suite, en utilisant la PDF de chaque classe, on estime la probabilité de classe d'une nouvelle donnée d'entrée, puis la règle de Bayes est appliquée pour assigner la classe ayant la plus haute probabilité a posteriori aux nouvelles données d'entrée [205]. L'équation II.5 fournit l'estimation de la fonction de densité de probabilité  $f(x)$  pour un point de données  $x$  dans la méthode de l'estimation par noyau (KDE).

$$f(x) = \frac{1}{nh^d} \sum_{i=1}^n \phi\left(\frac{x - x_i}{h}\right) \quad (\text{II.5})$$

$n$ : Le nombre d'échantillons d'apprentissage.

$d$ : La dimension de l'espace d'entrée.

$h$ : La largeur de bande (un paramètre de lissage).

$\phi$ : La fonction noyau, souvent une fonction de base radiale (RBF), telle qu'une gaussienne.

Dans un PNN, les opérations sont structurées selon un réseau feedforward multicouche composé de quatre couches comme montré dans la figure II.15 : [206]

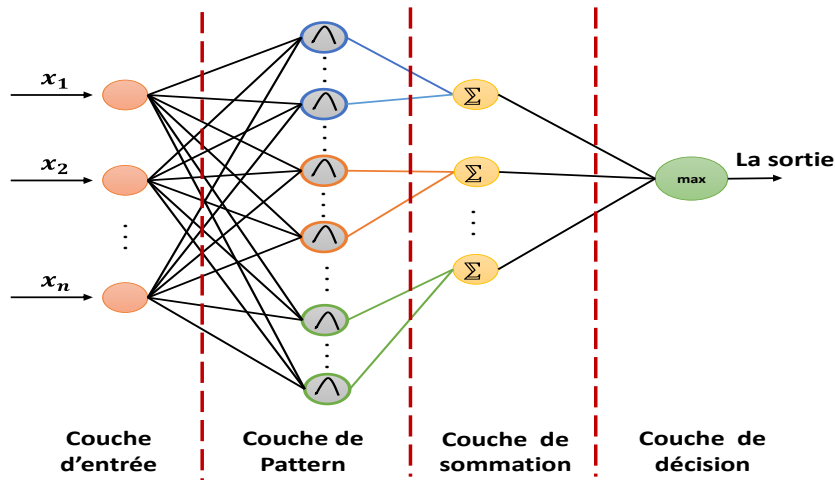


Figure II. 15 Illustration d'un réseau neuronal probabiliste.

**La couche d'entrée** : constitue l'étape initiale du réseau, permettant l'injection des données externes. Un neurone de cette couche représente une caractéristique d'entrée. La couche d'entrée a pour fonction de recevoir les données et de les traiter en vue de leur utilisation pour l'estimation directe des probabilités, par opposition à une transmission directe au réseau telle que celle des réseaux MLP.

**La couche de Motif (Pattern)** : constitue le trait distinctif de l'architecture PNN par rapport aux autres approches. Chaque neurone de la couche Motif est associé à un exemple d'apprentissage spécifique de l'ensemble de données donné. Les neurones de cette couche mettent en œuvre des fonctions de noyaux couramment fonction à base radiales (RBF) afin d'évaluer la similarité des motifs par exemple. La fonction de base radiale (RBF),

généralement une fonction gaussienne l'équation II.6 mesure la distance entre le modèle d'entrée et l'exemple d'apprentissage dans l'espace des caractéristiques, puis génère une valeur d'activation en fonction de cette distance [207].

$$\phi(x) = \exp\left(-\frac{\|x - c_i\|^2}{2h^2}\right) \quad (\text{II.6})$$

**La couche de sommation** : agrège les sorties des neurones de la couche de motifs pour chaque classe. Chaque neurone de cette couche représente une classe et effectue la somme des sorties des neurones de motifs associés à cette classe. En fait, cette couche correspond à une somme pondérée des activations RBF pour chaque classe [207].

**Couche de sortie** : c'est la partie finale du réseau, elle compare les probabilités agrégées de la couche de sommation pour attribuer l'entrée à la classe avec la probabilité estimée la plus élevée, finalisant ainsi le processus de classification. Cette méthode est fondamentalement probabiliste et s'appuie sur les fondements de la décision bayésienne.

#### II.5.2.4 Réseau de neurone bayésien

Un réseau neuronal bayésien (BNN) est un réseau de neuronal artificiel stochastique qui repose sur des principes probabilistes, initialement introduits dans les PNN, et qui les développe en intégrant l'inférence bayésienne dans sa structure. Les réseaux neuronaux bayésiens se distinguent des réseaux neuronaux classiques en modélisant les poids et les biais à l'aide de distributions de probabilités au lieu d'estimations ponctuelles [208], comme illustré dans la figure II.16. Les réseaux neuronaux classiques, bien qu'ils soient puissants et capables de faire des prédictions précises, ne parviennent pas à estimer l'incertitude liée à ces prédictions, les rendant ainsi vulnérables au surapprentissage (overfitting), en particulier sur de petits ensembles de données. Ce problème survient lorsque le réseau neuronal apprend à modéliser le bruit des données d'entraînement au lieu de capturer la distribution sous-jacente, ce qui entraîne une mauvaise généralisation aux nouvelles données. Les BNNs surmontent cette limitation en intégrant un cadre probabiliste qui leur permet non seulement de prédire les résultats, mais également d'estimer l'incertitude liée aux processus sous-jacents, offrant ainsi une approche plus précise et fiable de la prise de décision, dans les domaines où les défaillances des systèmes sont particulièrement coûteuses [209].

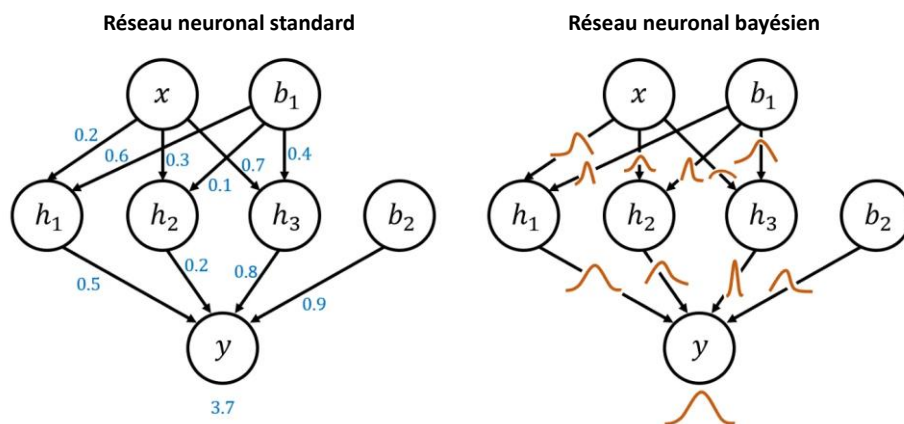


Figure II. 16 Comparaison entre un réseau neuronal standard et un réseau neuronal bayésien.

Les réseaux bayésiens offrent de la transparence et de l'explicabilité, ce qui permet de comprendre et de justifier les prédictions. Leur grande flexibilité permet d'incorporer des données et des connaissances d'experts, et de s'ajuster facilement aux nouvelles informations. En utilisant le raisonnement probabiliste, ils parviennent à traiter l'incertitude et à ajuster leurs croyances en fonction des éléments de preuve disponibles [210].

La conception d'un réseau de neurones bayésien (BNN) commence par le choix d'une architecture fonctionnelle du réseau  $y = \Phi(x)$  et d'un modèle stochastique comprenant une distribution a priori sur les paramètres  $p(\theta)$  ainsi qu'une confiance a priori dans les prédictions  $p(y|x, \theta)$  où  $\theta$  est un paramètre particulier, tandis que l'ensemble d'entraînement  $D$  se compose des données  $D = \{D_x, D_y\}$ , avec  $D_x$  désignant les entrées d'entraînement et  $D_y$  leurs étiquettes respectives. En utilisant le théorème de Bayes, le postérieur bayésien est exprimé en supposant l'indépendance entre les paramètres du modèle et les entrées.

$$p(\theta|D) = \frac{p(D_y|D_x, \theta)p(\theta)}{\int_{\theta} p(D_y|D_x, \theta')p(\theta')d\theta'} \quad (\text{II.7})$$

Le calcul du postérieur bayésien des réseaux de neurones est une tâche complexe en raison de sa dimension élevée et de sa non-convexité, ce qui rend les approches classiques inefficaces. Afin de résoudre ce problème, deux approches principales sont couramment utilisées : les chaînes de Markov Monte Carlo (MCMC) et l'inférence variationnelle. Ces méthodes permettent d'évaluer ces intégrales de diverses manières. La distribution marginale  $p(y|x, D)$ , qui évalue l'incertitude des prédictions du modèle, est dérivée de  $p(\theta|D)$ .

$$p(y|x, D) = \int_{\theta} p(y|x, \theta')p(\theta'|D)d\theta' \quad (\text{II.8})$$

La prédiction finale est synthétisée à partir de statistiques calculées à l'aide d'une méthode Monte Carlo. Un vaste ensemble de poids  $\theta_i$  est échantillonné à partir de la distribution a posteriori afin de calculer une série de sorties potentielles  $y_i$ , tel qu'indiqué dans l'Algorithme 1, représentant ainsi des échantillons de la distribution marginale.

**Algorithme 1** Procédure d'inférence pour un BNN.

```

Define  $p(\theta|D) = \frac{p(D_y|D_x, \theta)p(\theta)}{\int_{\theta} p(D_y|D_x, \theta')p(\theta')d\theta'}$  ;
for  $i=0$  to  $N$  do
    Draw  $\theta_i \sim p(\theta|D)$ ;
     $y_i = \Phi_{\theta_i}(x)$  ;
end for
return  $Y = \{y_i | i \in [0, N]\}$ ,  $\Theta = \{\theta_i | i \in [0, N]\}$ ;
    
```

Dans cet algorithme,  $Y$  désigne un ensemble d'échantillons provenant de la distribution marginale et  $\Theta$  un ensemble d'échantillons provenant de la distribution a posteriori. Ainsi, nous parvenons à estimer les distributions au lieu de se limiter à des estimateurs ponctuels [209], [211].

### II.6 Apprentissage profond

L'apprentissage profond (Deep Learning DL) constitue une branche de l'apprentissage automatique qui vise à doter les machines de capacités de résolution de problèmes et d'intelligence similaire à celles des êtres humains. Ces machines utilisent des réseaux neuronaux comprenant un grand nombre de couches interconnectées, ce qui leur permet de fonctionner, d'apprendre, de penser et d'agir comme des humains. Contrairement aux réseaux neuronaux simples qui peuvent n'avoir qu'une ou deux couches cachées et traitent les données dans une seule direction (feedforward). Plus le nombre de couche de neurone est élevé, plus le réseau est profond et délivre des performances exceptionnelles [212].

Les approches classiques de l'apprentissage automatique exigeaient une étape initiale d'extraction des caractéristiques. Cette étape implique la conversion des données non traitées en une forme utilisable par ces approches. L'extraction des caractéristiques est une opération complexe nécessitant une expertise approfondie dans le domaine ainsi que plusieurs itérations pour atteindre l'optimisation. L'apprentissage profond élimine cette nécessité. Il est capable d'extraire les caractéristiques des échantillons d'entrée de manière progressive en utilisant des réseaux profonds, permettant ainsi une extraction automatique des caractéristiques et une classification grâce aux fonctions d'activation non linéaires présentes à chaque couche. Pendant le processus d'entraînement, ce réseau de neurones cherche à optimiser cette étape pour parvenir à une représentation abstraite optimale des données d'entrée. Cela implique que les modèles d'apprentissage profond éliminent le besoin d'une extraction manuelle et d'une intervention humaine ainsi que des connaissances d'experts pour réaliser et améliorer le processus d'extraction des caractéristiques [213], comme illustré dans la figure II.17.

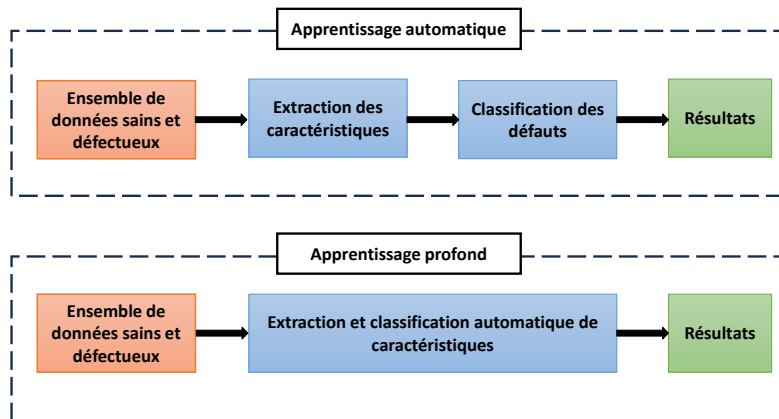


Figure II. 17 Machine Learning vs Deep Learning : Processus comparé.

Selon la figure II.18, la performance représente le principal élément distinctif entre l'apprentissage profond et l'apprentissage automatique [214]. Les modèles classiques d'apprentissage automatique ont tendance à être limités par la quantité de données disponibles et montrent des signes de stagnation une fois qu'ils ont atteint un niveau de saturation. L'apprentissage profond nécessite un vaste ensemble de données en raison de sa structure multicouche complexe, ce qui permet d'éliminer les fluctuations, d'obtenir des interprétations de haute qualité, et de rendre le modèle plus efficace et plus précis [215].




Figure II. 18 L'impact des données sur les performances des modèles d'IA.

Il y'a deux catégories principales de systèmes de l'apprentissage profond qui se distinguent par leurs architectures : les réseaux neuronaux récurrents (RNN) et les réseaux neuronaux convolutifs (CNN).

### II.6.1 Les réseaux de neurones récurrents

Les réseaux de neurones récurrents (RNN) sont une catégorie de réseaux de neurones fréquemment employée dans le domaine du Deep Learning. Les RNN intègrent les sorties antérieures en tant qu'entrées supplémentaires, ce qui les rend particulièrement appropriés pour l'analyse de données séquentielles. Ils exhibent des connexions récurrentes (rétroactifs) tel que montré dans la figure II.19, notamment des boucles de mémoire récurrentes, qui intègrent les couches et les états antérieurs et/ou identiques en entrée. Cela leur offre une opportunité exclusive de modéliser la dimension temporelle ainsi qu'une séquence arbitraire d'événements et d'entrées. Cependant, les réseaux de neurones récurrents rencontrent le défi de la disparition du gradient lorsqu'il s'agit d'apprendre à mémoriser des événements antérieurs [199]. Certaines architectures spécifiques ont été développées pour résoudre ce problème, parmi lesquelles on peut mentionner les réseaux Long Short-Term Memory (LSTM) [216].

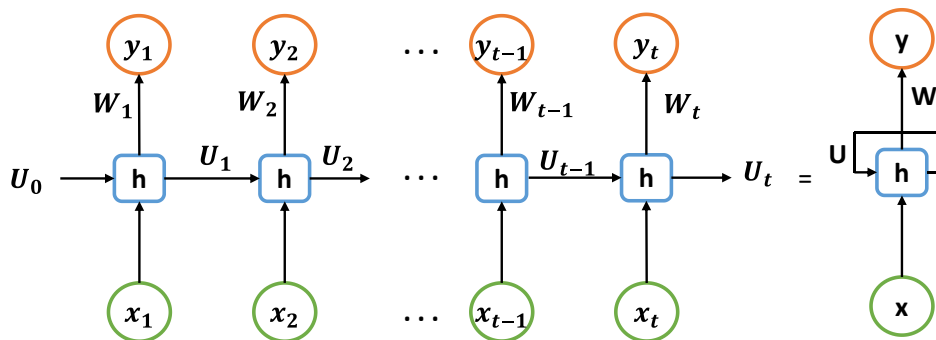


Figure II. 19 RNN et sa version dépliée dans le temps.

Les connexions récurrentes relient les couches cachées du réseau à elles-mêmes et sont caractérisées par des paramètres supplémentaires (poids)  $U$ , en plus des poids des connexions traditionnelles  $W$ . Tout comme les poids  $W$ , les poids  $U$  subissent des mises à jour pendant la phase d'apprentissage. Donc, la valeur de  $U$  est actualisée à chaque itération lorsqu'un

élément de la séquence est traité. En outre, pour prédire un élément  $x_t$ , on utilise des paramètres qui ont été entraînés sur les observations  $x_{t-1}, x_{t-2}, \dots, x_1$ . Une couche cachée avec des connexions récurrentes est désignée sous le nom de couche récurrente. Ainsi, un réseau récurrent exploite la séquentialité des données, ce qui lui permet de générer des prédictions plus précises.

À tout moment  $t$ , la progression vers l'avant est représentée par les équations suivantes [217]:

$$h_t = \sigma_h(W_h x_t + U_h h_{t-1} + b_h) \quad (\text{II.9})$$

$$y_t = \sigma_y(W_y h_t + b_y) \quad (\text{II.10})$$

Où :

- $x_t$  : Représente l'élément de la séquence d'entrée au temps  $t$ .
- $y_t$  : Désigne la prédiction au temps  $t$ .
- $h_t$  : Le vecteur intermédiaire (hidden vector) à l'instant  $t$ .
- $W_h, W_y, U_h, b_h, b_y$  : correspondent aux paramètres du modèle.
- $\sigma_h, \sigma_y$  : Les fonctions d'activation.

### II.6.2 Réseaux neuronaux convolutifs

Les réseaux neuronaux convolutifs (CNN) sont une catégorie remarquable de modèles d'apprentissage profond, se distinguant comme une variante des réseaux neuronaux feedforward. Leur architecture spécifique est conçue pour traiter de manière efficace et interpréter des données structurées sous forme de grille, telles que des images, des vidéos, voire des données séquentielles comportant des hiérarchies spatiales [218]. L'introduction de ces réseaux a été l'une des innovations les plus marquantes dans le domaine de l'informatique, permettant des progrès significatifs dans des domaines clés tels que la reconnaissance d'images, la détection d'objets et la segmentation d'images. Ce succès facilite l'exploration et l'exploitation des réseaux de neurones convolutifs (CNN) pour la résolution de problèmes complexes, ce qui n'était pas possible avec les méthodes traditionnelles. Cette évolution a également impacté et révolutionné le domaine du diagnostic des défaillances en offrant une détection plus précise et plus fiable des anomalies présentes dans différents systèmes [186]. Leur architecture se révèle plus complexe que celle des réseaux neuronaux feedforward classiques, intégrant des couches convolutives, des couches de mise en commun (pooling) et des couches entièrement connectées comme illustré dans la figure II.20. Fondamentalement, ces couches remplissent les rôles d'extracteurs de caractéristiques, de réducteurs de dimensionnalité et de classificateurs, respectivement. Les différentes couches d'un CNN sont superposées afin de constituer une couche de convolution intégrale visant à capturer l'invariance de la translation, c'est-à-dire que les filtres sont conçus de manière à être indépendants de l'emplacement. Ceci améliore l'efficacité de la fonction directe, diminue significativement le nombre de paramètres, ce qui rend le réseau plus simple à optimiser et moins sensible à la taille des données [219].

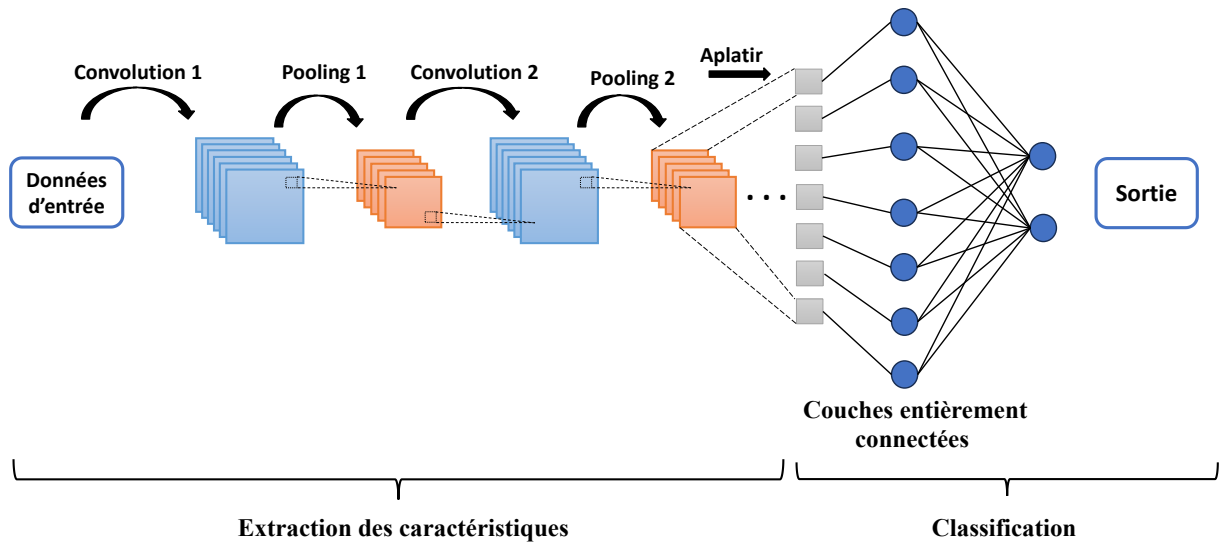


Figure II. 20 Illustration de l'architecture des CNN.

- **Couches convolutives** : La première couche du CNN est systématiquement une couche convolutive servant de premier extracteur de caractéristique. Dans cette couche diverses opérations de convolution sont réalisées sur l'entrée, qui consiste à faire glisser certains filtres (noyaux) afin d'extraire des informations relatives à la texture. La sortie des couches convolutives consiste en un ensemble de cartes de caractéristiques, résultant de la corrélation croisée entre chaque filtre et l'entrée. Les cartes de caractéristiques présentent des données concernant la sémantique de l'image, acquises de façon hiérarchique à travers toute l'architecture. Mathématiquement, on peut décrire l'opération de convolution appliquée à une image d'entrée  $I$  en 2D en se référant à l'équation II.11. Dans cette équation,  $S(i, j)$  représente la valeur située à la position  $(i, j)$  dans la carte de caractéristiques résultante  $S$ , tandis que les indices  $m$  et  $n$  parcourent les dimensions du filtre  $K$ . L'opération réalise une sommation pondérée des valeurs d'entrée en utilisant les poids définis par le filtre. Le résultat obtenu correspond à une nouvelle représentation de l'entrée mettant en évidence des caractéristiques spécifiques comme les arêtes, les coins ou les textures. La convolution, opération fondamentale des CNN, est essentielle pour l'extraction des dépendances locales dans les données, ce qui les rend particulièrement puissants pour les tâches requérant une compréhension spatiale, telles que la reconnaissance d'images [220].

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (\text{II.11})$$

- **Fonction d'activation** : La fonction d'activation, une équation mathématique appliquée à la sortie d'une couche convolutive, est l'un des éléments essentiels d'un réseau neuronal. Elle considère la somme pondérée des entrées pour générer une sortie qui est ensuite transmise à la couche suivante [221]. La sélection adéquate de la fonction d'activation revêt une importance capitale, car elle peut favoriser la convergence rapide d'un modèle et l'atteinte de performances élevées, ou au contraire entraver cette convergence en cas de saturation. Chaque couche convolutive du réseau est liée à une fonction d'activation qui est appliquée à chaque carte de caractéristiques

générée par la couche. L'intégration d'une fonction d'activation améliore le processus d'apprentissage en introduisant une non-linéarité dans les poids du réseau neuronal [220]. Les fonctions d'activation les plus fréquemment employées dans les CNN comprennent l'Unité linéaire rectifiée (ReLU), la fonction Sigmoïde et la tangente hyperbolique (tanh).

- **Couches de mise en commun (Pooling)** : Suite aux couches convolutives, il est courant d'ajouter des couches de pooling dans les réseaux de neurones convolutifs (CNN), ayant pour objectif de progressivement réduire les dimensions spatiales des cartes de caractéristiques. Cette réduction revêt une importance capitale car elle permet de réduire le nombre de paramètres et de calculs dans le réseau, ce qui contribue à limiter l'overfitting et à améliorer l'efficacité du modèle. Diminuant ainsi le coût de calcul et contribue à prévenir le surapprentissage, lequel se manifeste lorsque le modèle s'ajuste excessivement aux données d'entraînement, compromettant ainsi sa capacité à généraliser à de nouvelles données [222]. La couche de pooling partitionne la carte des caractéristiques d'entrée en un ensemble de régions non superposées, connues sous le nom de régions de pooling. Chaque région de mise en commun est ensuite convertie en une valeur de sortie unique, qui indique la présence d'une caractéristique spécifique dans cette région.

Les opérations de mise en commun les plus fréquemment rencontrées sont la mise en commun maximale et la mise en commun moyenne.

En ce qui concerne le pooling max, la sortie correspondant à chaque région de pooling est déterminée par la valeur maximale des entrées situées dans cette région (généralement une fenêtre de taille 2x2 ou 3x3). Ceci permet de conserver les caractéristiques les plus distinctives de chaque région de mise en commun, tout en éliminant les informations moins pertinentes. La technique de pooling maximale est fréquemment employée dans les réseaux de neurones convolutifs pour la reconnaissance d'objets, car elle facilite l'identification des caractéristiques les plus saillants d'un objet, comme ses bords et ses coins, ce qui renforce la capacité du modèle à généraliser à diverses entrées. Cette opération peut être formalisée mathématiquement à l'aide de l'équation II. , dans laquelle  $P(i, j)$  représente la carte des caractéristiques regroupées et  $R(i, j)$  désigne la région de la carte des caractéristiques  $S$  qui est regroupée [223].

$$P(i, j) = \max\{P(m, n)\}, \quad (m, n) \in R(i, j) \quad (\text{II.12})$$

Dans le pooling moyen, la valeur de sortie attribuée à chaque région de pooling correspond à la moyenne des valeurs d'entrée présentes dans cette région. Cette approche permet de conserver un plus nombre d'informations que la mise en commun maximale, cependant elle risque également d'atténuer les caractéristiques les plus distinctives [224].

Malgré la perte d'informations significative due à la couche de mise en commun, celle-ci offre également plusieurs avantages pour le CNN. Elle contribue à la réduction de la complexité, à l'amélioration de l'efficacité et à la limitation du risque de surajustement [225].

- **Les couches entièrement connectées :** Après plusieurs couches de convolution et de pooling, le raisonnement de haut niveau sur les données d'entrée est effectué par des couches entièrement connectées, généralement situées à la fin du CNN. Ces couches fonctionnent de la même façon que celles présentes dans les réseaux feedforward classiques et sont des éléments fondamentaux des modèles de classification. Chaque couche entièrement connectée est reliée de manière complète à la couche précédente et à la couche suivante. Ceci implique que chaque neurone de cette couche reçoit des informations d'entrée de tous les neurones de la couche précédente et transmet des sorties à tous les neurones de la couche suivante. Il réalise une opération de multiplication matrice-vecteur, dans laquelle le vecteur représente l'entrée et les coefficients de la matrice correspondent aux poids de la couche à entraîner pour modéliser la relation de base entre l'entrée et la sortie. En ce qui concerne la classification, la sortie finale consiste en un vecteur de  $k$  dimensions qui reflète la répartition d'appartenance de l'entrée parmi les  $k$  classes de classification [220].

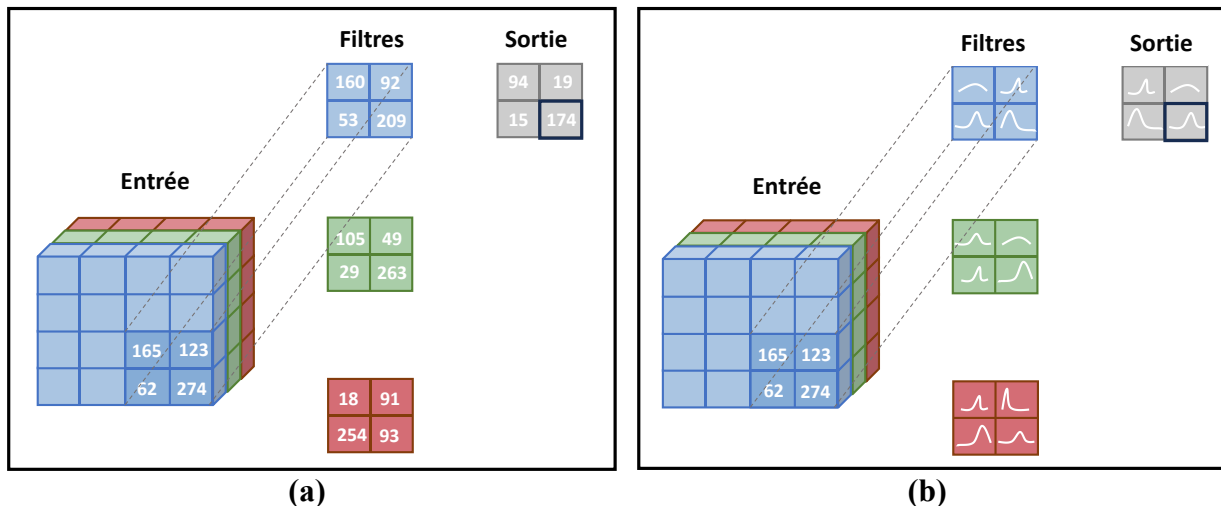
Les réseaux de neurones convolutifs (CNN) présentent plusieurs avantages distincts par rapport aux réseaux feedforward classique, ce qui les rend supérieurs pour diverses tâches. En premier lieu, la technique de partage des paramètres consiste à appliquer des filtres (ou noyaux) à l'ensemble des données d'entrée, ce qui a pour effet de réduire de manière significative le nombre de paramètres requis. Cela conduit à des durées d'apprentissage réduites et à un risque moindre de surapprentissage. En second lieu, la connectivité locale assure que les neurones de chaque couche sont uniquement connectés à une zone locale de la couche précédente, favorisant ainsi l'apprentissage efficace des hiérarchies et des motifs spatiaux présents dans les données. En troisième lieu, la stabilité de la traduction est assurée grâce à l'utilisation d'opérations de pooling et de filtres partagés, conférant ainsi aux CNN une robustesse face aux variations et altérations des données en entrée. Ainsi, les caractéristiques telles que les arêtes ou les textures identifiées par le réseau restent identifiables quelle que soit leur position dans les données d'entrée. En dernier lieu, un avantage clé réside dans l'efficacité des calculs, étant donné que l'architecture des CNN est spécifiquement conçue pour traiter efficacement des données de grande échelle, telles que des images à haute résolution. L'association de couches convolutives, de couches de pooling et de couches entièrement connectées permet aux CNN d'extraire des motifs significatifs à partir de données complexes tout en maintenant des contraintes de calcul gérables.

### II.6.3 Réseau Neuronal Convolutionnel Bayésien (BCNN)

Les réseaux neuronaux convolutionnels (CNN) ont prouvé leur efficacité remarquable dans une variété de tâches de classification et de détection. Toutefois, une contrainte significative des CNN classiques est leur incapacité à évaluer de manière quantitative l'incertitude liée à leurs prédictions et à détecter les fausses alertes dans les systèmes de surveillance industrielle, en particulier en ce qui concerne les défauts combinés. Par conséquent, il est crucial d'employer des modèles capables non seulement de classer de manière précise les états de fonctionnement des machines, mais également de fournir une estimation de confiance pour chaque prédiction. Les BCNN offrent précisément cette possibilité. A la différence des réseaux neuronaux traditionnels qui produisent une prédiction déterministe, les BCNN prennent en compte l'incertitude des paramètres du réseau en les modélisant à l'aide de distributions de probabilité au lieu de valeurs de poids fixes. Cela leur permet de produire des prédictions probabilistes, assorties d'un niveau d'incertitude. En cas de doute, par exemple

lorsque les caractéristiques d'une machine en bon état sont similaires à celles d'une machine défectueuse, le modèle peut indiquer un manque de confiance dans sa décision. La capacité à exprimer l'incertitude permet de diminuer significativement les faux positifs, c'est-à-dire les arrêts injustifiés pour des machines en bon état, tout en maintenant une vigilance élevée envers les réelles défaillances [113].

Les BCNN offrent une structure robuste et adaptée aux environnements industriels où la précision du diagnostic revêt une importance cruciale. Cet algorithme combine des approches bayésiennes avec la puissance des CNN, en prenant en compte non seulement les poids individuels, mais également les filtres, qui peuvent être conceptualisés comme des ensembles de poids formant une unité distincte. Il est courant d'utiliser des distributions de probabilité (souvent gaussiennes) pour modéliser les poids des filtres. La figure II.21 illustre un CNN à gauche avec des poids uniques représentés par des estimations ponctuelles, et à droite un BCNN avec des distributions de probabilité sur les poids, offrant ainsi une comparaison visuelle [226].



**Figure II. 21** Différence entre CNN et BCNN. **(a)** : CNN avec des valeurs fixes des paramètres neuronaux ; **(b)** : BCNN avec des distributions de probabilités indépendantes des paramètres neuronaux.

### II.6.3.1 Architecture typique d'un réseau convolutionnel bayésien

L'architecture d'un réseau convolutionnel bayésien (BCNN) repose sur les fondations des CNNs traditionnels, avec l'ajout fondamental de la modélisation probabiliste des poids. Chaque paramètre appris devient une variable aléatoire décrite par une distribution, ce qui permet au réseau non seulement d'apprendre des représentations hiérarchiques, mais aussi d'estimer l'incertitude associée à ses prédictions. La description suivante détaille chaque composant de cette architecture en insistant sur son rôle dans un cadre bayésien.

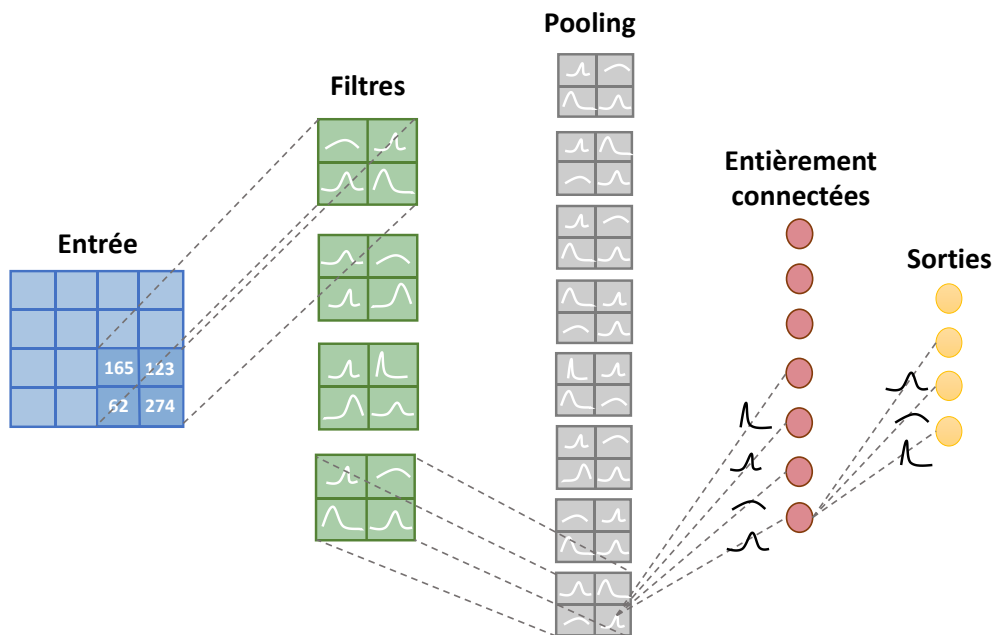


Figure II. 22 L'architecture d'un réseau convolucional bayésien (BCNN).

- **Couches convolutives bayésiennes :** Les couches convolutives bayésiennes constituent le cœur de l'architecture du BCNN. À chaque passage dans le réseau, les poids des filtres ne sont pas fixes, mais échantillonnés depuis des distributions de probabilité apprises pendant l'entraînement, chaque poids  $\theta$  est remplacé par une distribution  $p(\theta)$ . Cette propriété permet de générer des cartes d'activation variables à chaque itération, reflétant l'incertitude sur les caractéristiques extraites. Ces couches permettent d'extraire des motifs locaux à différents niveaux d'abstraction, tout en intégrant une évaluation de la fiabilité de ces motifs. L'échantillonnage stochastique est souvent réalisé à l'aide du trick de reparamétrisation pour permettre une rétropropagation efficace.
- **Couches d'activation non linéaires :** Comme dans les CNNs classiques, chaque couche convolutive est suivie d'une fonction d'activation non linéaire, typiquement ReLU ou LeakyReLU. Ces fonctions introduisent la non-linéarité nécessaire à l'apprentissage de représentations complexes. Dans le cadre bayésien, bien qu'elles ne modélisent pas directement l'incertitude, elles influencent la manière dont cette incertitude est propagée à travers les couches. Des fonctions plus douces comme ELU ou GELU peuvent parfois être préférées pour améliorer la stabilité des activations dans les architectures bayésiennes.
- **Couches de normalisation :** Les couches de normalisation sont essentielles pour réguler la dynamique des activations, en particulier lorsqu'elles sont influencées par la variabilité induite par les poids stochastiques. La Batch Normalization classique peut être utilisée, mais dans certains cas, des variantes bayésiennes sont introduites pour modéliser également l'incertitude sur les statistiques de normalisation. Leur rôle est de stabiliser l'entraînement, d'accélérer la convergence et de maintenir la cohérence des distributions d'activation à travers les différentes couches du réseau.
- **Couches de sous-échantillonnage (pooling) :** Les opérations de pooling, telles que MaxPooling ou AveragePooling, sont utilisées pour réduire les dimensions spatiales

des cartes d'activation. Elles permettent également de renforcer l'invariance translationnelle et de régulariser le modèle en diminuant la sensibilité aux perturbations locales. Bien que déterministes, ces couches influencent indirectement la manière dont l'incertitude locale est agrégée ou conservée à travers le réseau, notamment dans les régions où les activations sont moins stables.

- **Couches entièrement connectées bayésiennes (fully-connected) :** À la fin du réseau, les cartes d'activation sont aplaties et transmises à une ou plusieurs couches entièrement connectées, dont les poids sont eux aussi modélisés de manière probabiliste. Ces couches intègrent les caractéristiques extraites et produisent des vecteurs de sortie variables à chaque échantillonnage. Elles permettent de capter la variabilité globale des représentations et jouent un rôle central dans la prise de décision du réseau. Leur comportement stochastique amplifie ou réduit l'incertitude selon la stabilité des activations précédentes.
- **Couche de sortie stochastique (Softmax ou Sigmoid) :** La couche de sortie applique une fonction d'activation stochastique — généralement une softmax pour la classification multi-classe, ou une sigmoïde pour les tâches binaires. Comme les couches précédentes sont bayésiennes, la sortie finale ne correspond pas à une prédiction unique, mais à une distribution de prédictions. En répétant plusieurs inférences (par exemple, 20 à 100 passes avant), on peut estimer une moyenne prédictive ainsi qu'une variance, fournissant une mesure de la confiance du modèle. Cette approche permet d'identifier les cas ambigus et de limiter les décisions prises avec une confiance artificiellement élevée.

**Éléments supplémentaires dans les architectures avancées :** Selon la complexité de la tâche ou la nature des données, plusieurs couches ou mécanismes supplémentaires peuvent être intégrés. Le Dropout stochastique peut être conservé pour renforcer la régularisation, même dans un cadre bayésien. Des mécanismes d'attention bayésienne peuvent être introduits pour pondérer dynamiquement les régions informatives dans les cartes d'activation. Les architectures profondes peuvent également bénéficier de connexions résiduelles (comme dans ResNet) ou de structures en encodeur-décodeur (par exemple, U-Net bayésien), permettant une meilleure généralisation et une captation hiérarchique plus riche de l'incertitude.

### II.6.3.2 Extension bayésienne des réseaux de neurones convolutifs

Dans les sections précédentes, le fonctionnement détaillé des CNNs a été exposé en profondeur. Ces architectures, largement utilisées pour le traitement des images et des signaux structurés, reposent sur l'empilement de couches convolutives, suivies d'activations non-linéaires (comme ReLU ou LeakyReLU), de sous-échantillonnage spatial (pooling), et se terminent généralement par une ou plusieurs couches entièrement connectées. Chaque couche convolutive applique une opération linéaire locale consistant à filtrer les entrées via des noyaux de convolution appris, permettant d'extraire progressivement des représentations de haut niveau à partir de motifs locaux dans les données. Mathématiquement, la sortie d'une couche convolutive classique peut être exprimée par la relation II.12.

$$y_k^{(l)} = \sum_j (w_{kj}^{(l)} * x_j^{(l)}) + b_k^{(l)} \quad (\text{II.12})$$

Où  $x_j^{(l)}$  représente la carte de caractéristiques  $j$  issue de la couche précédente,  $w_{kj}^{(l)}$  est le noyau convolutif (filtre) reliant cette entrée à la sortie  $k$  de la couche  $l$ , et  $b_k^{(l)}$  est le biais associé. L'opérateur  $*$  désigne ici une convolution discrète (1D, 2D ou 3D selon la nature des données). Les poids  $w$  et les biais  $b$  sont déterministes et optimisés par descente de gradient sur une fonction de perte déterministe, généralement la cross-entropie pour les tâches de classification. Ce formalisme, bien que très puissant, ne permet pas de capturer ou de représenter l'incertitude inhérente aux données ou au modèle.

Dans une perspective bayésienne, cette hypothèse de déterminisme est remplacée par une modélisation probabiliste des paramètres. Ainsi, dans un BCNN, les poids des filtres convolutifs ne sont plus des constantes, mais des **variables aléatoires**. Plus précisément, chaque poids  $w_{kj}^{(l)}$  est considéré comme une variable suivant une distribution de probabilité, généralement une loi normale gaussienne centrée sur une moyenne  $\mu_{kj}^{(l)}$  avec une variance  $(\sigma_{kj}^{(l)})^2$ . Cela s'écrit selon la formule II.13.

$$w_{kj}^{(l)} \sim N\left(\mu_{kj}^{(l)}, (\sigma_{kj}^{(l)})^2\right) \quad (\text{II.13})$$

Ainsi, la sortie de la couche convolutive n'est plus déterminée uniquement par une opération fixe, mais résulte d'une **convolution stochastique** où les poids sont échantillonnés à chaque passe dans le réseau. L'expression du calcul devient alors comme sur l'équation II.14.

$$y_k^{(l)} = \sum_j (\theta_{kj}^{(l)} * x_j^{(l)}) + b_k^{(l)} \quad \text{avec} \quad \theta_{kj}^{(l)} = N\left(\mu_{kj}^{(l)}, (\sigma_{kj}^{(l)})^2\right) \quad (\text{II.14})$$

Ce changement de paradigme transforme chaque passage dans le réseau en une expérience probabiliste, où les sorties varient légèrement selon l'échantillonnage des poids. En réalisant plusieurs passes (par exemple,  $T$  échantillons), on peut obtenir une **distribution prédictive** sur les sorties du réseau, plutôt qu'une seule valeur ponctuelle. Cela permet de quantifier directement l'incertitude de la prédiction. La moyenne prédictive  $\hat{y}$  est estimée par l'équation II.15 et la variance associée, qui mesure l'incertitude épistémique du modèle, est donnée par II.16.

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T f(x, \theta_t) \quad (\text{II.15})$$

$$VAR[y] = \frac{1}{T} \sum_{t=1}^T f(x, \theta_t)^2 - \left( \frac{1}{T} \sum_{t=1}^T f(x, \theta_t) \right)^2 \quad (\text{II.16})$$

Ces deux statistiques sont fondamentales dans l'approche bayésienne. Elles permettent non seulement de fournir une prédiction moyenne (comme dans les CNNs classiques), mais aussi une information sur la fiabilité de cette prédiction, ce qui est crucial dans des contextes industriels sensibles où des décisions de maintenance ou d'arrêt de production peuvent dépendre du diagnostic automatique du système.

Cette estimation conjointe de la moyenne et de la variance permet de disposer à la fois d'une prédiction et d'un degré de confiance, ce qui est essentiel dans des applications à haut risque comme la maintenance prédictive, la surveillance de systèmes mécaniques, ou le contrôle qualité automatisé.

Une autre différence importante entre les BNNs classique et les BCNNs réside dans la structure locale des poids. Dans les BNNs, chaque poids est traité indépendamment et relie deux neurones spécifiques. Dans les BCNNs, les poids sont regroupés par filtre, et partagés spatialement, ce qui permet à la fois une réduction drastique du nombre de paramètres et une meilleure invariance translationnelle. Cette structure impose également des contraintes spécifiques sur la façon dont l'incertitude est propagée dans le réseau : elle n'est pas locale à une connexion, mais diffusée dans toute la carte d'activation.

### II.6.3.3 Méthodes d'inférence approximative en BCNN

La modélisation probabiliste des poids dans les réseaux de neurones bayésiens, et en particulier dans les BCNN, ouvre la voie à une meilleure quantification de l'incertitude et à une plus grande robustesse dans les prédictions. Cependant, cette modélisation pose une difficulté majeure : le calcul exact de la distribution a posteriori des poids conditionnellement aux données d'apprentissage est intractable pour des architectures profondes. En effet, la dimension de l'espace des poids, l'absence de forme fermée de la postérieure, ainsi que la non-linéarité introduite par les fonctions d'activation rendent impossible l'évaluation analytique de l'intégrale bayésienne. Ainsi, il est indispensable de recourir à des méthodes d'inférence approximative pour estimer cette postérieure de manière pratique et exploitable.

Trois approches sont principalement employées dans les BCNNs : l'inférence variationnelle, le Dropout de Monte Carlo et l'optimisation bayésienne par rétropropagation (Bayes by Backprop). Chacune de ces méthodes permet de contourner l'intractabilité du calcul exact de la postérieure tout en s'intégrant de manière cohérente à la dynamique d'apprentissage par gradient. Leur intégration au cadre convolutif nécessite toutefois des ajustements spécifiques, notamment en ce qui concerne la gestion du partage spatial des filtres et l'échantillonnage localisé.

#### 1) Inférence variationnelle (Variational Inference -VI)

L'inférence variationnelle repose sur le principe d'approximer la distribution a posteriori intractable des poids par une distribution paramétrique plus simple, notée  $q(\theta|\phi)$  où  $\phi$  désigne les paramètres libres du modèle approximatif. Le but est de faire en sorte que cette approximation soit aussi proche que possible de la postérieure vraie  $p(\theta|D)$ . Pour cela, on cherche à minimiser la divergence de Kullback-Leibler entre ces deux distributions, ce qui revient à maximiser la borne inférieure de la vraisemblance marginale des données, aussi appelée **Evidence Lower Bound (ELBO)** présenter sur l'équation II.17.

$$\mathcal{L}_{VI} = \mathbb{E}_{q(\theta)}[\log p(D|\theta)] - KL(q(\theta|\phi)||p(\theta)) \quad (\text{II.17})$$

Le premier terme, appelé **terme de vraisemblance espérée**, mesure l'adéquation du modèle aux données. Le second terme agit comme une **régularisation bayésienne**, contraignant la distribution approximative à rester proche de la priorité imposée sur les poids. Cette formulation permet de transformer l'apprentissage bayésien en une optimisation stochastique classique, dans laquelle les paramètres sont ajustés par descente de gradient.

Dans les BCNNs, l'application de l'inférence variationnelle présente des spécificités. Contrairement aux couches fully connected où chaque poids est un paramètre indépendant, les couches convolutives comportent des **filtres partagés spatialement**, ce qui implique que chaque paramètre probabiliste a un impact multiplié sur l'ensemble des activations produites.

Cette propriété introduit une corrélation implicite entre les différentes régions de la carte d'activation, rendant le comportement du réseau plus sensible aux choix faits dans l'approximation variationnelle. De plus, le calcul des gradients des termes variationnels dans les convolutions nécessite des mécanismes efficaces d'échantillonnage différentiable, souvent implémentés via le **reparametrization trick**, afin d'assurer la continuité du flux de gradient à travers les opérations stochastiques.

L'inférence variationnelle est très puissante car elle permet une approximation explicite de la postérieure et offre une flexibilité importante pour incorporer des contraintes, des structures hiérarchiques ou des dépendances complexes entre les paramètres. Toutefois, sa mise en œuvre dans des architectures convolutives profondes peut devenir coûteuse en termes de mémoire et de temps de calcul, surtout lorsque le nombre de filtres est élevé ou lorsque l'on souhaite utiliser des postérieures non factorisées.

### 2) Dropout de Monte Carlo (MC Dropout)

Le Dropout de Monte Carlo constitue une alternative élégante et peu coûteuse à l'inférence variationnelle. Proposé comme une interprétation bayésienne du Dropout standard, il repose sur l'idée d'introduire de la stochasticité directement dans les activations du réseau, en appliquant aléatoirement des masques binaires pendant l'entraînement et **l'inférence**. Contrairement au Dropout classique qui est désactivé à l'inférence, ici, on effectue plusieurs passes avant avec des masques de Dropout différents, ce qui permet de construire une distribution empirique sur les prédictions.

Pour un échantillon donné  $x$ , on effectue  $T$  passes stochastiques à travers le réseau, et on obtient une estimation de la moyenne prédictive et de sa variance comme sur [II.18](#) et [II.19](#).

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T f(x, \theta_t) \quad (\text{II.18})$$

$$\hat{\sigma}^2 = \frac{1}{T} \sum_{t=1}^T f((x, \theta_t) - \hat{y})^2 \quad (\text{II.19})$$

Le MC Dropout est particulièrement bien adapté aux architectures convolutives car il s'intègre naturellement dans les couches déjà existantes : il suffit d'activer le Dropout lors de l'inférence, ce qui est trivial à implémenter dans les frameworks de deep learning comme PyTorch ou TensorFlow. Il permet également de contrôler facilement le niveau de variabilité en ajustant la probabilité de Dropout et le nombre de passes  $T$ .

Cependant, cette méthode repose sur des hypothèses implicites : elle suppose que la distribution induite par le Dropout est une approximation valide de la vraie postérieure, ce qui est difficile à garantir théoriquement. De plus, comme il ne s'agit pas d'un apprentissage explicite des paramètres de distribution, le modèle ne fournit pas de contrôle direct sur la forme de la postérieure, ni sur sa capacité à capturer des incertitudes complexes ou multimodales.

### 3) Bayes par backpropagation

La méthode dite Bayes by Backpropagation (BBB) est une approche variationnelle directe, qui propose une façon unifiée d'entraîner un réseau bayésien par rétropropagation stochastique. Elle se distingue par sa simplicité de mise en œuvre et sa compatibilité avec

l'entraînement par mini-lots. Dans cette approche, les paramètres des distributions (notamment les moyennes et les échelles log-variantes) sont optimisés directement à l'aide de gradients stochastiques. L'idée est de réécrire chaque paramètre du réseau sous la forme l'équation II.20. Puis d'effectuer une propagation avant avec des poids échantillonnés, suivie de l'évaluation de la fonction de coût bayésienne incluant à la fois la vraisemblance et la régularisation KL. Cette méthode a l'avantage d'être plus stable que des méthodes purement échantillonnées et de s'adapter facilement aux couches convolutives. Pour cela, les filtres sont entraînés de la même manière que les poids standards, mais à chaque itération, un nouveau filtre aléatoire est généré à partir des distributions apprises.

$$\theta_i = \mu_i + \sigma_i \cdot \epsilon \text{ avec } \epsilon \sim N(0,1) \quad (\text{II.20})$$

Dans les BCNNs, BBB est souvent préféré à l'inférence variationnelle classique lorsque la taille du réseau est importante, car il permet de mieux équilibrer coût computationnel et expressivité de la postérieure. Il est cependant sensible au choix du prior, et des mécanismes comme la prior tempering ou la mise à l'échelle KL sont souvent nécessaires pour éviter un surajustement de la postérieure sur des zones peu informatives du réseau.

Une fois les distributions de probabilité définies sur les poids des filtres convolutifs, le processus d'apprentissage dans un BCNN se fonde sur l'exécution de propagations avant répétées, avec des poids stochastiques échantillonnés dynamiquement à chaque itération. Contrairement aux réseaux bayésiens fully-connected, où chaque poids d'une connexion neuronale est traité indépendamment, les filtres convolutifs dans les BCNNs sont des entités structurées appliquées de manière spatiale sur l'ensemble de la carte d'activation. Cela confère au modèle une sensibilité particulière aux variations locales des entrées, tout en rendant l'échantillonnage des poids plus cohérent et contextuel.

Concrètement, à chaque passe dans le réseau, un nouvel ensemble de filtres est généré à partir des distributions probabilistes apprises (dont les paramètres ont été décrits précédemment). Ces filtres ne sont donc jamais figés : ils fluctuent légèrement d'une itération à l'autre, reflétant l'incertitude résiduelle dans leur estimation. Cette fluctuation contrôlée est précisément ce qui permet au BCNN de produire non seulement une sortie moyenne, mais aussi une estimation de l'incertitude prédictive sans nécessiter de réentraînement du réseau.

Cette approche s'intègre naturellement dans l'apprentissage par descente de gradient, grâce à l'utilisation de techniques comme la reparamétrisation, permettant à la rétropropagation de mettre à jour directement les paramètres des distributions (typiquement la moyenne et un paramètre lié à la variance). Dans les BCNNs, l'application de cette stratégie à des couches convolutives impose un soin particulier, car les filtres étant partagés sur toute la surface de l'image, un seul paramètre incertain peut influencer un grand nombre d'activations. Cela amplifie la propagation de l'incertitude dans les couches suivantes, ce qui doit être pris en compte dans la calibration du modèle.

Par ailleurs, l'avantage de cette structure est que l'incertitude spatiale devient modélisable : les zones de l'image ou du signal présentant des motifs ambigus ou bruités génèrent des activations plus dispersées, traduisant une incertitude localisée, tandis que les zones où les caractéristiques sont claires activent les filtres avec peu de variance. Cette capacité n'est pas directement accessible dans un BNN classique à couches denses, où l'entrée est déjà vectorisée et la structure spatiale des données est perdue.

Enfin, du point de vue algorithmique, chaque itération d'apprentissage dans un BCNN peut être vue comme une exploration stochastique de l'espace des modèles compatibles avec les données. Les gradients calculés lors de la rétropropagation ne sont plus simplement déterministes, mais reflètent la moyenne de performances sur plusieurs configurations possibles du modèle, ce qui confère à l'apprentissage une forme de régularisation naturelle et permet d'éviter le surajustement aux données bruitées ou déséquilibrées.

### II.7 Conclusion

Ce chapitre a présenté les concepts fondamentaux de l'intelligence artificielle. Nous avons discuté de l'apprentissage automatique, en abordant à la fois l'apprentissage supervisé, non supervisé et par renforcement. Par la suite, nous nous sommes intéressés à l'apprentissage profond, une tendance majeure de l'intelligence artificielle ces dernières années. Plus spécifiquement, dans le domaine du diagnostic intelligent des défauts combiné des systèmes de transmission mécanique, cette approche repose généralement sur deux étapes essentielles : l'extraction d'indicateurs et la classification des défauts. Ensuite, nous avons examiné la méthode des réseaux neuronaux convolutionnels bayésiens (BCNN), qui joue un rôle essentiel dans la résolution des défis liés à la détection et la classification des défauts combinés dans le secteur industriel. Cette approche se caractérise par sa capacité à prendre en compte l'incertitude dans les prédictions. En associant la capacité des CNN dans le traitement des signaux ou des images avec l'approche bayésienne, les BCNN offrent la possibilité d'atteindre des performances de haut niveau tout en permettant une estimation de la fiabilité des résultats. Cette caractéristique revêt une importance capitale dans les domaines où la fiabilité et l'interprétabilité des décisions sont primordiales, notamment dans le cadre de la surveillance des défaillances des systèmes industriels, domaine dans lequel l'application de cette méthode sera abordée dans le chapitre suivant.

# **Chapitre III :**

## **Vers un diagnostic interprétable :**

### **l'utilisation de CEEMDAN avec les réseaux neuronaux bayésiens.**

### **III.1 Introduction**

Après avoir posé les bases fondamentales dans les deux premiers chapitres en explorant d'une part les mécanismes de défaillance typiques rencontrés dans les systèmes de transmission mécanique, et d'autre part les approches analytiques et algorithmiques possible pour leur détection, ce troisième chapitre marque une transition décisive. Il vise à concrétiser une solution technique avancée, robuste et adaptée aux environnements industriels réels, où les défauts apparaissent souvent sous forme combinée.

Face à la complexité des signaux vibratoires et à la nécessité d'une interprétation fiable et contextualisée des données, ce troisième chapitre introduit deux outils méthodologiques avancés, dont la complémentarité est particulièrement pertinente : la Décomposition en Modes Empiriques (EMD) avec ses dérivés et les Réseaux de Neurones Convolutifs Bayésiens (Bayesian CNNs). Ces deux approches, bien que issues de domaines différents, partagent une finalité commune : extraire et modéliser des informations discriminantes dans un cadre incertain, à partir de données brutes complexes.

La décomposition en modes empiriques (EMD) est une technique innovante, totalement data-driven, conçue pour l'analyse de signaux non stationnaires et non linéaires — caractéristiques omniprésentes dans les systèmes rotatifs soumis à des régimes variables, comme les moteurs électriques ou les piles à combustible. Contrairement aux transformées classiques (Fourier, ondelettes), qui imposent une base fréquentielle ou temporelle fixée à l'avance, l'EMD extrait dynamiquement des composantes appelées fonctions de modes intrinsèques (IMFs), qui reflètent les oscillations locales du signal. Ce processus adaptatif offre une représentation temps-fréquence fine et interprétable, tout en conservant la signification physique des composantes analysées. Néanmoins, certaines limitations, telles que le mélange de modes ou la sensibilité au bruit, ont conduit au développement de variantes améliorées comme l'EEMD, le CEEMD et le CEEMDAN, qui seront également explorées dans ce chapitre.

Parallèlement, les réseaux de neurones convolutifs bayésiens (BCNNs) prolongent les architectures classiques de CNN en introduisant une modélisation probabiliste des poids et des activations du réseau. Ce cadre probabiliste, fondé sur l'inférence variationnelle ou le Monte Carlo dropout, permet non seulement d'obtenir des prédictions précises en classification, mais aussi d'évaluer l'incertitude épistémique liée aux décisions du modèle — une propriété cruciale dans les applications critiques où la confiance accordée à une prédiction doit être mesurable et justifiable. Les BCNNs offrent également de meilleures capacités de généralisation en présence de données bruitées ou en faible volume, grâce à un effet régularisateur intrinsèque. Cette capacité à apprendre tout en restant conscient de ses propres limites rend les BCNNs particulièrement attractifs pour les systèmes de maintenance prédictive. L'objectif de ce chapitre est donc triple :

1. Présenter de manière approfondie les fondements théoriques, les principes de fonctionnement et les variantes avancées de la méthode EMD.
2. Détailler les bases mathématiques et les propriétés des réseaux bayésiens convolutifs, avec un accent particulier sur l'estimation d'incertitude et l'inférence variationnelle.

3. Montrer comment ces deux outils peuvent être intégrés dans une architecture conjointe, combinant la puissance descriptive de la décomposition CEEMDAN avec les capacités décisionnelles calibrées des BCNNs.

Ce chapitre marque ainsi une transition décisive entre l'état des connaissances établi dans les chapitres précédents et la mise en œuvre d'une solution originale, hybride et robuste, pour le diagnostic automatique de défauts dans des conditions industrielles complexes. Il constitue la base méthodologique à partir de laquelle des approches avancées de l'apprentissage automatique, de la classification probabiliste et de la mise en œuvre expérimentale sur des ensembles de données réels seront développées dans les chapitres suivants.

### **III.2 Décomposition en mode empirique (EMD) : un outil de décomposition adaptatif aux signaux**

La décomposition en modes empiriques (EMD) est une méthode novatrice de traitement du signal, conçue spécifiquement pour l'analyse de signaux non linéaires et non stationnaires. Introduite par Huang et al. [30] à la fin des années 1990, elle se distingue des approches classiques telles que la transformée de Fourier ou la transformée en ondelettes par son caractère entièrement adaptatif et piloté par les données. Contrairement aux méthodes basées sur des fonctions de base prédéfinies, l'EMD décompose un signal en un ensemble de fonctions appelées fonctions de modes intrinsèques (IMFs – Intrinsic Mode Functions), qui représentent les oscillations locales contenues dans le signal original comme montrée dans par la Figure III.1.

#### **III.2.1 Bases mathématiques**

La méthode EMD est basée sur une série d'étapes itératives permettant d'extraire successivement les composantes oscillatoires les plus rapides du signal, tout en respectant des conditions spécifiques :

- **Définition d'un mode intrinsèque :**

Une fonction est considérée comme IMF si elle répond à deux critères fondamentaux :

- 1) Le nombre de zéros et le nombre d'extrema doivent être égaux ou différer d'au plus une unité.
- 2) À tout moment, la moyenne des enveloppes supérieure et inférieure (définies par les maxima et minima locaux) doit être égale à zéro.

- **Processus de tamisage (Sifting) :**

Ce processus est au cœur de la méthode EMD. Il consiste à :

- 1) Identifier tous les maxima et minima locaux du signal.
- 2) Interpoler les maxima (enveloppe supérieure) et les minima (enveloppe inférieure) à l'aide de splines cubiques.
- 3) Calculer la moyenne locale de ces deux enveloppes.
- 4) Soustraire cette moyenne du signal original pour isoler une première version de l'IMF.
- 5) Répétez l'opération jusqu'à ce que les conditions d'un IMF soient remplies (c'est-à-dire que la fonction obtenue est symétrique par rapport à zéro, avec des oscillations régulières).

- **Résidu et reconstruction du signal :**

Une fois un IMF extrait, on le soustrait du signal original. Ce résidu devient alors le nouveau signal à décomposer. Le processus est répété jusqu'à ce que le résidu soit une tendance monotone ou une composante sans oscillation significative. Au final, le signal original est reconstruit comme la somme de tous les IMFs extraits et du résidu final.

Formellement, si un signal  $x(t)$  est décomposé en  $n$  IMFs notés  $c_i(t)$ , et un résidu  $r_n(t)$ , on a :

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (\text{III.1})$$

Chaque IMF représente un mode oscillatoire propre au signal, souvent associé à une bande de fréquence ou un phénomène physique particulier.

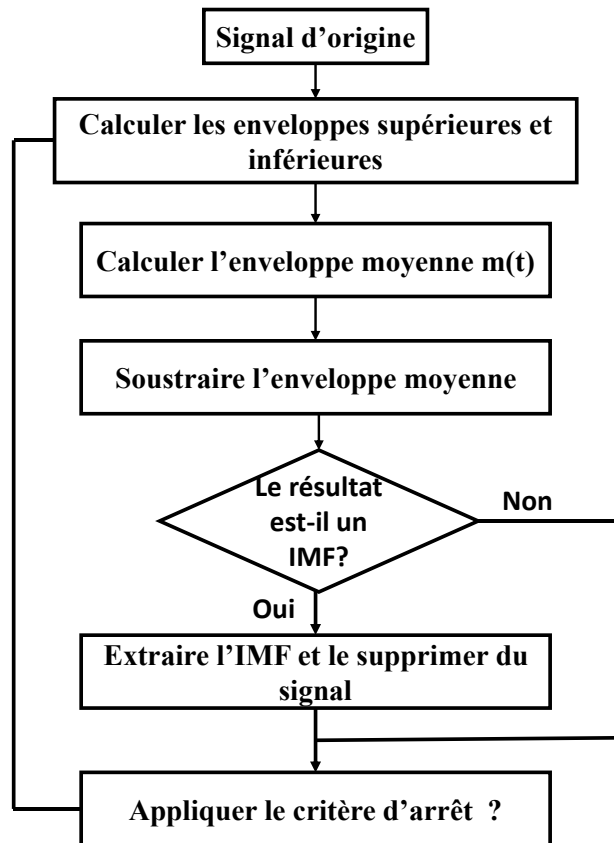


Figure III. 1 Illustration de l'algorithme de l'EMD.

### III.3 Décomposition en Mode Empirique par Ensemble (EEMD) : Une amélioration robuste contre le mélange de modes

La décomposition en modes empiriques par ensemble (EEMD) est une évolution de la méthode EMD classique, conçue pour résoudre l'un de ses problèmes majeurs : le mélange de modes. Introduite par Wu et Huang en 2009 [47], l'EEMD propose une approche novatrice basée sur l'introduction de bruit blanc contrôlé dans le signal. Cette méthode s'inscrit dans la continuité de l'EMD en conservant son caractère entièrement adaptatif tout en améliorant significativement la séparation des composantes fréquentielles.

Contrairement à l'EMD classique, qui peut souffrir de la superposition d'informations de différentes échelles dans un même IMF, l'EEMD exploite les propriétés statistiques du bruit blanc pour mieux isoler les dynamiques propres à chaque échelle du signal.

### III.3.1 Bases mathématiques

La méthode EEMD repose sur une stratégie simple mais puissante : ajouter un bruit blanc de faible amplitude au signal original, puis appliquer l'EMD classique sur un grand nombre de réalisations bruitées. Les IMFs obtenues pour chaque réalisation sont ensuite moyennées rang par rang pour produire les IMFs finales.

Le processus peut être décrit comme suit :

- 1) **Ajout de bruit blanc** : À chaque itération, un bruit blanc  $\xi_i(t)$  est ajouté au signal original  $x(t)$ , créant ainsi une version bruitée :

$$x_i(t) = x(t) + \xi_i(t) \quad (\text{III.2})$$

- 2) **Décomposition par EMD** : Chaque version bruitée  $x_i(t)$  est ensuite décomposée par EMD classique, produisant une série d'IMFs :

$$\{c_{i,1}(t), c_{i,2}(t), \dots, c_{i,n}(t)\} \quad (\text{III.3})$$

- 3) **Moyennage des IMFs** : Après  $N$  réalisations, les IMFs finales sont obtenues en faisant la moyenne des IMFs correspondantes :

$$c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{i,j}(t) \text{ pour chaque } j = \{1, 2, \dots, n\} \quad (\text{III.4})$$

- 4) **Résidu et reconstruction du signal** : Comme pour l'EMD classique, une fois toutes les IMFs obtenues, la somme des IMFs et du résidu reconstruit approchera le signal original :

$$x(t) \approx \sum_{j=1}^n c_j(t) + r_n(t) \quad (\text{III.5})$$

Cependant, contrairement à l'EMD, cette somme n'est pas strictement identique à  $x(t)$ , en raison de la présence résiduelle du bruit.

### III.3.2 Les avantages

**Réduction significative du mélange de modes** : L'ajout de bruit blanc perturbe le signal de manière contrôlée, favorisant la séparation naturelle des composantes fréquentielles dans les IMFs.

**Meilleure robustesse face à des signaux complexes** : L'EEMD est particulièrement efficace pour les signaux contenant des phénomènes transitoires ou multi-échelles, courants dans les systèmes électromécaniques et les applications de surveillance prédictive.

**Conservation de la nature adaptative** : Comme l'EMD, l'EEMD n'impose aucune base fonctionnelle prédéfinie et reste entièrement guidée par les caractéristiques locales du signal.

### III.3.3 Les limites

**Erreur de reconstruction** : Contrairement à l'EMD classique, l'EEMD ne garantit pas que la somme des IMFs reconstruit exactement le signal original, ce qui peut entraîner une légère perte d'information.

**Coût computationnel élevé** : Le processus nécessite l'exécution de l'EMD sur un grand nombre de réalisations (parfois plusieurs centaines), ce qui accroît significativement le temps de calcul.

**Dépendance aux paramètres du bruit** : Le choix de l'amplitude du bruit blanc et du nombre de réalisations est crucial : des paramètres mal ajustés peuvent soit ne pas résoudre le mélange de modes, soit dégrader la qualité des IMFs obtenues.

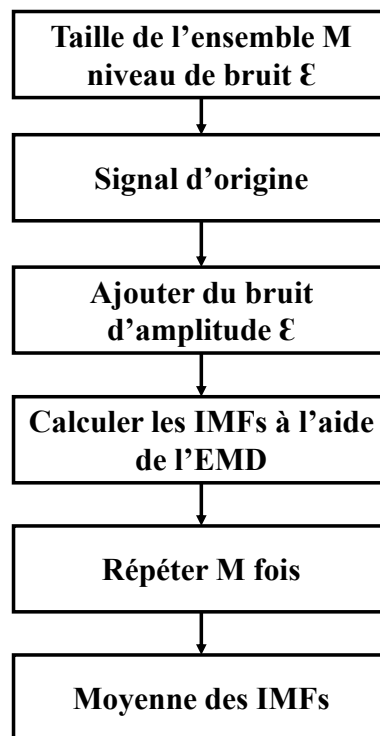


Figure III. 2 Illustration de l'algorithme de l'EEMD.

### III.4 Décomposition Complète en Mode Empirique par Ensemble (CEEMD) : Vers une reconstruction fidèle du signal

La décomposition complète en modes empiriques par ensemble (CEEMD) est une amélioration directe de l'EEMD, introduite par Yeh et al. [56] en 2010. Si l'EEMD permettait de réduire significativement le mélange de modes, elle laissait néanmoins subsister un problème fondamental : l'impossibilité de reconstruire exactement le signal d'origine en sommant les IMFs extraites. Le CEEMD a été développé spécifiquement pour résoudre ce défaut tout en conservant les avantages de la stratégie de bruit blanc.

Cette méthode repose sur une idée élégante : injecter du bruit et son opposé de manière structurée lors de la décomposition pour compenser rigoureusement les contributions aléatoires du bruit et obtenir une décomposition complète, c'est-à-dire une reconstruction exacte du signal par la somme des IMFs et du résidu.

### III.4.1 Bases mathématiques

Le processus de CEEMD suit des étapes analogues à l'EEMD, mais avec des raffinements essentiels :

- 1) **Génération de paires bruit/anti-bruit** : À chaque itération, deux signaux sont générés

$$x_i^+(t) = x(t) + \xi_i(t) \text{ et } x_i^-(t) = x(t) - \xi_i(t) \quad (\text{III.6})$$

- 2) **Décomposition par EMD** : L'EMD est appliquée séparément à  $x_i^+(t)$  et  $x_i^-(t)$ , produisant deux ensembles d'IMFs :

$$\{c_{i,1}^+(t), c_{i,2}^+(t), \dots, c_{i,n}^+(t)\} \text{ et } \{c_{i,1}^-(t), c_{i,2}^-(t), \dots, c_{i,n}^-(t)\} \quad (\text{III.7})$$

- 3) **Moyennage symétrique** : Les IMFs correspondantes sont moyennées sur l'ensemble des réalisations :

$$c_j(t) = \frac{1}{2N} \sum_{i=1}^N (c_{i,j}^+(t) + c_{i,j}^-(t)) \text{ pour chaque } j = \{1, 2, \dots, n\} \quad (\text{III.8})$$

- 4) **Résidu et reconstruction** : Grâce à cette symétrie, la somme des IMFs obtenues est exactement égale au signal original :

$$x(t) = \sum_{j=1}^n c_j(t) \quad (\text{III.9})$$

La nécessité d'introduire un résidu explicite disparaît dans la théorie, bien que dans la pratique, un résidu de très basse fréquence puisse être conservé si nécessaire.

### III.4.2 Les avantages

**Reconstruction exacte du signal** : Contrairement à l'EEMD, la méthode CEEMD garantit que la somme des IMFs reconstitue fidèlement le signal original sans résidu de bruit non contrôlé.

**Réduction renforcée du mélange de modes** : L'introduction équilibrée de bruit et d'anti-bruit permet de maintenir la séparation des composantes fréquentielles tout en neutralisant les effets aléatoires du bruit.

**Robustesse en conditions bruitées** : Le CEEMD conserve les qualités d'adaptation de l'EEMD tout en assurant une robustesse supplémentaire contre les perturbations aléatoires.

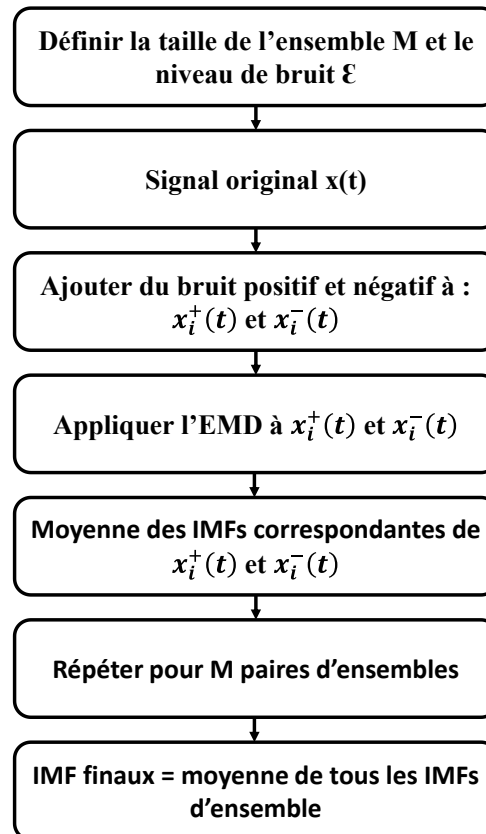
**Amélioration de l'interprétabilité** : Les IMFs obtenues sont souvent plus propres et physiquement interprétables, ce qui facilite l'analyse de défauts spécifiques dans des systèmes complexes.

### III.4.3 Les limites

**Coût computationnel élevé** : L'exigence de doubler le nombre de décompositions par rapport à l'EEMD (bruit + anti-bruit) accroît considérablement le temps de calcul.

**Sensibilité aux paramètres de bruit :** Comme pour l'EEMD, le choix de l'amplitude du bruit et du nombre de réalisations est crucial. Un mauvais paramétrage peut réduire l'efficacité de la séparation fréquentielle.

**Complexité de mise en œuvre :** La nécessité de gérer systématiquement le bruit et son opposé rend l'algorithme légèrement plus complexe à implémenter que l'EEMD.



**Figure III. 3** Illustration de l'algorithme de l'CEEMD.

### **III.5 CEEMDAN – Décomposition Complète par Ensemble avec Bruit Adaptatif : Précision et stabilité dans la séparation fréquentielle**

La Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) représente l'évolution la plus avancée des méthodes de décomposition par ensemble. Proposée par Torres et al. [66] en 2011, elle combine les avantages des approches précédentes (EEMD et CEEMD) tout en introduisant un mécanisme crucial : l'injection adaptative de bruit à chaque étape de la décomposition. Cette amélioration permet une séparation encore plus précise des composantes fréquentielles tout en réduisant la dépendance au nombre de réalisations.

Le CEEMDAN s'impose aujourd'hui comme l'une des méthodes les plus robustes et précises pour l'analyse de signaux non linéaires et non stationnaires dans des contextes réels, bruités et dynamiquement complexes.

### III.5.1 Bases mathématiques

Le CEEMDAN repose sur une décomposition récursive contrôlée, où le bruit est injecté de manière adaptative à chaque étape pour calculer chaque IMF successivement. Le procédé peut se résumer ainsi :

- 1) **Première IMF ( $c_1$ )** : Un bruit blanc  $\xi_i(t)$  est ajouté au signal d'origine  $x(t)$ . Pour chaque réalisation bruitée  $x_i(t) = x(t) + \xi_i(t)$  l'IMF principale est extraite par EMD :

$$c_1(t) = \frac{1}{N} \sum_{i=1}^N IMF_1[x_i(t)] \quad (III.10)$$

- 2) **Calcul du premier résidu ( $r_1$ )** : Le résidu est ensuite calculé :

$$r_1(t) = x(t) - c_1(t) \quad (III.11)$$

- 3) **IMFs suivantes ( $c_2, c_3, \dots$ )** : Pour chaque étape suivante, le bruit injecté est adapté au résidu courant  $r_k(t)$ , et l'IMF est estimée par :

$$c_{k+1}(t) = \frac{1}{N} \sum_{i=1}^N IMF_1[r_k(t) + \xi_i^{(k)}(t)] \quad (III.12)$$

- 4) **Reconstruction** : Le signal original est approché comme la somme des IMFs extraites et du dernier résidu :

$$x(t) \approx \sum_{k=1}^n c_k(t) + r_n(t) \quad (III.13)$$

### III.5.2 Les avantages

**Précision accrue dans la séparation fréquentielle** : Le bruit injecté étant ajusté dynamiquement à chaque résidu, les IMFs extraites sont mieux localisées dans l'espace-temps-fréquence, avec une contamination minimale entre les bandes.

**Réduction maximale du mélange de modes** : CEEMDAN est la méthode la plus efficace parmi toutes les variantes EMD pour limiter la superposition de composantes distinctes dans un même IMF.

**Reconnaissance complète du signal** : Comme CEEMD, la somme des IMFs et du résidu permet une reconstruction fidèle du signal d'origine.

**Moins de dépendance au nombre de réalisations** : Le CEEMDAN converge plus rapidement que l'EEMD ou le CEEMD, permettant de réduire le coût computationnel sans dégrader la qualité de la décomposition.

**Bonne robustesse au bruit réel** : La méthode montre une performance stable même en présence de bruit de mesure non artificiel, ce qui la rend très adaptée aux signaux expérimentaux issus de capteurs.

### III.5.3 Les limites

**Complexité algorithmique plus élevée :** Le CEEMDAN nécessite une gestion rigoureuse des résidus, du bruit adaptatif, et des reconstructions successives, ce qui le rend plus difficile à implémenter que ses prédécesseurs.

**Sensibilité aux paramètres de bruit :** Bien que moins dépendant du nombre de réalisations, le choix de l'amplitude du bruit reste crucial et doit être adapté au type de signal étudié.

**Temps de calcul non négligeable :** Même s'il est plus rapide que CEEMD, le CEEMDAN reste plus coûteux que l'EMD simple. Il convient donc d'optimiser sa mise en œuvre en fonction de la taille des jeux de données.

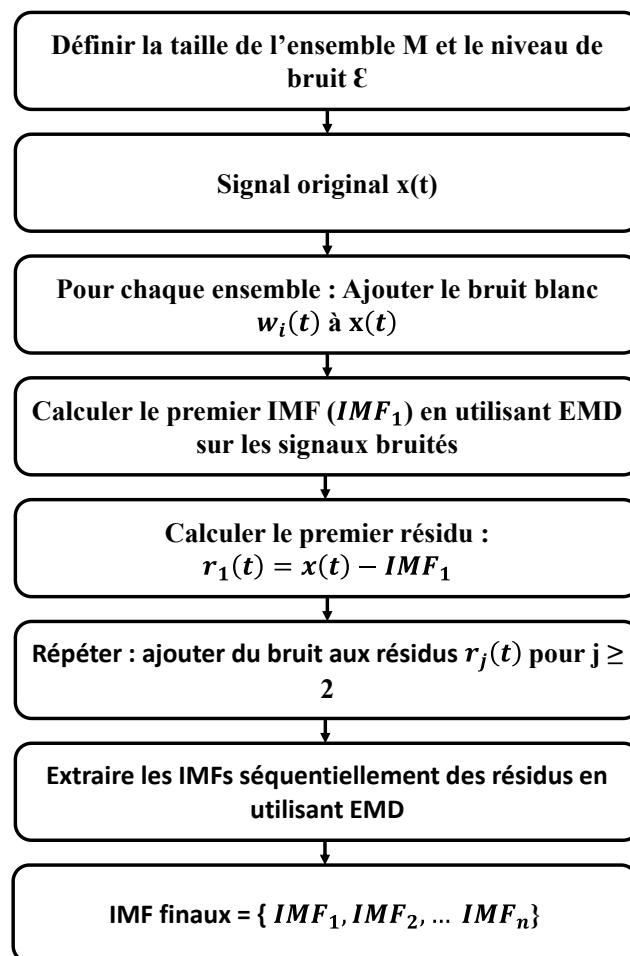


Figure III. 4 Illustration de l'algorithme de l'CEEMDAN.

### III.6 Comparaison théorique des méthodes EMD et dérivées

Depuis sa proposition par Huang et al., la EMD a suscité un vif intérêt en raison de sa capacité à analyser des signaux non stationnaires et non linéaires sans hypothèse préalable sur leur contenu fréquentiel. Son principe repose sur l'extraction séquentielle de IMFs, représentant des composantes oscillatoires locales. Toutefois, malgré ses qualités d'adaptabilité et d'intuition physique, l'EMD souffre de limitations structurelles qui ont motivé le développement de plusieurs variantes : l'EEMD, le CEEMD, et le CEEMDAN. Ces

extensions visent à pallier les faiblesses de la méthode initiale, notamment en matière de séparation fréquentielle, de robustesse au bruit, de reconstruction du signal et de stabilité des résultats.

Un critère fondamental de comparaison réside dans la capacité de séparation fréquentielle des différentes méthodes. L'EMD classique est connue pour présenter un phénomène de mélange de modes, où plusieurs composantes spectrales se retrouvent dans un même IMF ou, inversement, une même composante est dispersée entre plusieurs IMFs. Ce défaut compromet la clarté de l'analyse. L'EEMD améliore cette séparation en introduisant un bruit blanc qui, en perturbant légèrement le signal, permet de stabiliser les extrémités et d'améliorer la convergence des enveloppes. Le CEEMD va plus loin en ajoutant systématiquement des paires de bruit/anti-bruit, ce qui élimine les interférences résiduelles dues au bruit ajouté. Enfin, le CEEMDAN affine ce processus en injectant du bruit de façon adaptative à chaque étape de la décomposition, ce qui conduit à une séparation fréquentielle plus nette et à une meilleure orthogonalité entre les IMFs.

La capacité de reconstruction du signal constitue un autre point de distinction essentiel. La méthode EMD, tout comme l'EEMD, ne garantit pas une reconstruction exacte du signal original à partir des IMFs extraites, en raison des distorsions introduites par l'algorithme de tamisage ou du bruit résiduel. À l'inverse, le CEEMD, en utilisant une approche symétrique de bruit/anti-bruit, assure que la somme des IMFs reconstitue exactement le signal original. Le CEEMDAN conserve cette propriété, tout en nécessitant moins de réalisations, grâce à son mécanisme adaptatif. Cette fidélité de reconstruction est cruciale dans les contextes où l'énergie ou la forme du signal portent des informations diagnostiques clés.

La robustesse au bruit réel, inhérent aux mesures industrielles, est également un critère central. L'EMD se montre très sensible aux perturbations, ce qui affecte la qualité des IMFs. L'EEMD, en injectant du bruit artificiel, permet de compenser certaines instabilités, mais introduit un résidu qui peut biaiser l'interprétation. Le CEEMD améliore cette robustesse grâce à une suppression plus rigoureuse du bruit, mais au prix d'une complexité accrue. Le CEEMDAN se distingue par une stabilité exceptionnelle en environnement bruité, notamment grâce à son injection de bruit calibrée étape par étape, ce qui le rend particulièrement adapté aux signaux expérimentaux complexes.

Concernant la complexité algorithmique et le coût computationnel, l'EMD reste la méthode la plus simple et la plus rapide à exécuter, mais aussi la moins fiable. L'EEMD requiert généralement plusieurs centaines de réalisations pour atteindre une bonne stabilité statistique, ce qui le rend coûteux en temps de calcul. Le CEEMD double cette exigence en raison de l'utilisation de paires de bruit, tandis que le CEEMDAN, bien que plus complexe à implémenter, réduit le nombre d'itérations nécessaires tout en maintenant une haute qualité de décomposition. En pratique, le choix de la méthode dépendra donc du compromis acceptable entre précision, robustesse et temps de traitement.

Ces différences sont synthétisées dans le tableau III.1 comparatif présenté ci-dessous, mais elles peuvent être brièvement résumées ainsi : l'EMD est rapide mais peu fiable, l'EEMD améliore la stabilité au prix d'une reconstruction partielle, le CEEMD combine stabilité et reconstruction exacte avec un coût élevé, tandis que le CEEMDAN offre une solution optimale en termes de séparation, fidélité et efficacité computationnelle.

Cette analyse théorique pose les fondations d'une comparaison expérimentale qui sera développée dans la section suivante. Afin d'évaluer les performances réelles de chaque méthode, celles-ci seront appliquées à un même signal de vibration mesuré sur un système tournant simulant un défaut progressif. L'objectif sera de comparer les IMFs extraites, les représentations temps-fréquence, la capacité à isoler les signatures de défauts, et la fidélité de reconstruction. Cette démarche permettra de confronter les propriétés théoriques des méthodes à leur comportement pratique, en condition réaliste, et de justifier le choix final de la méthode à intégrer dans un système de diagnostic automatique.

Critère	EMD	EEMD	CEEMD	CEEMDAN
Nature	Décomposition adaptative	Décomposition avec bruit blanc	Décomposition avec anti-bruit	Bruit adaptatif par IMF
Reconstruction exacte du signal	✗	✗	✓	✓
Mélange de modes (mode mixing)	Élevé	Réduit	Faible	Très faible
Sensibilité au bruit	Élevée	Modérée	Réduite	Très faible
Coût computationnel	Faible	Élevé	Élevé	Modéré à élevé
Complexité algorithmique	Faible	Moyenne	Élevée	Très élevée
Robustesse temps-fréquence	Moyenne	Moyenne à bonne	Bonne	Excellente

**Tableau III. 1** Comparaison théorique des méthodes empiriques.

### III.7 Étude comparative des méthodes EMD, EEMD, CEEMD et CEEMDAN pour le diagnostic de défauts

Afin d'évaluer l'efficacité de différentes techniques de décomposition de signaux dans le cadre du diagnostic de défauts en machinerie tournante, cette section présente une analyse comparative détaillée de quatre méthodes basées sur l'EMD : l'EEMD, le CEEMD et le CEEMDAN. Chaque méthode est appliquée à un signal vibratoire synthétique conçu pour simuler des conditions typiques de défauts moteurs et roulements, combinant des fréquences de base périodiques, des modulations induites par défaut et une contamination bruitée. Les performances de chaque approche sont évaluées à la fois qualitativement, à travers l'analyse des IMFs extraites et de leurs caractéristiques temps-fréquence, et quantitativement via le calcul de l'erreur quadratique moyenne de reconstruction (RMSE) et du temps de calcul.

#### III.7.1 Description du Signal

Le signal vibratoire utilisé dans cette étude a été généré synthétiquement afin de reproduire au plus près le comportement réel d'un système électromécanique. Il est constitué :

- D'une oscillation de base à 150 Hz représentant la fréquence fondamentale du moteur,
- D'une composante harmonique à 300 Hz liée à des phénomènes mécaniques,

- Ainsi que d'une fréquence évolutive à 600 Hz, simulant la croissance d'un défaut de roulement.

À cela s'ajoute un bruit blanc gaussien (écart-type de 5 %) afin de simuler les perturbations extérieures et le bruit de mesure des capteurs. La fréquence d'échantillonnage est fixée à 12 kHz, ce qui est conforme aux dispositifs d'acquisition industriels standards. Avant la décomposition, le signal a été normalisé (moyenne nulle et variance unitaire) pour assurer des conditions de traitement homogènes.

### **III.7.2 Résultats de Décomposition et Observations Qualitatives**

#### **a) Analyse des IMFs extraites**

La Figure III.5 présente les cinq premiers IMFs extraits par chacune des méthodes de décomposition. L'EMD classique révèle des limitations majeures. Les IMFs extraites souffrent d'un fort mélange de modes : plusieurs composantes fréquentielles coexistent dans un même mode, et les signatures des défauts haute fréquence ne sont pas correctement isolées. De plus, des artefacts de bruit sont nettement visibles dans les modes d'ordre supérieur, soulignant la sensibilité de l'EMD aux signaux bruités et non stationnaires. L'EEMD, grâce à son approche par moyenne d'ensembles bruités, parvient à réduire le mélange de modes. La composante haute fréquence liée au défaut est mieux isolée dans le premier IMF, et les harmoniques apparaissent plus distinctement dans les IMFs suivants. Cependant, certaines fluctuations d'amplitude et un bruit résiduel persistent, particulièrement au-delà du quatrième IMF, illustrant l'importance du paramétrage précis du bruit ajouté et du nombre de réalisations. Le CEEMD marque une avancée notable par rapport à l'EEMD. En utilisant des paires bruit/anti-bruit, cette méthode permet une meilleure annulation du bruit ajouté, produisant des IMFs plus propres avec une séparation plus nette des bandes de fréquences.

Le premier IMF capture fidèlement la fréquence de défaut, avec très peu de fuites d'énergie vers les modes voisins. Enfin, le CEEMDAN atteint le plus haut niveau de qualité de décomposition.

Chaque IMF est parfaitement localisée en fréquence et en temps, isolant sans ambiguïté les composantes du défaut et des harmoniques. Le processus est remarquablement stable, et les effets du bruit aléatoire sont quasiment inexistantes.

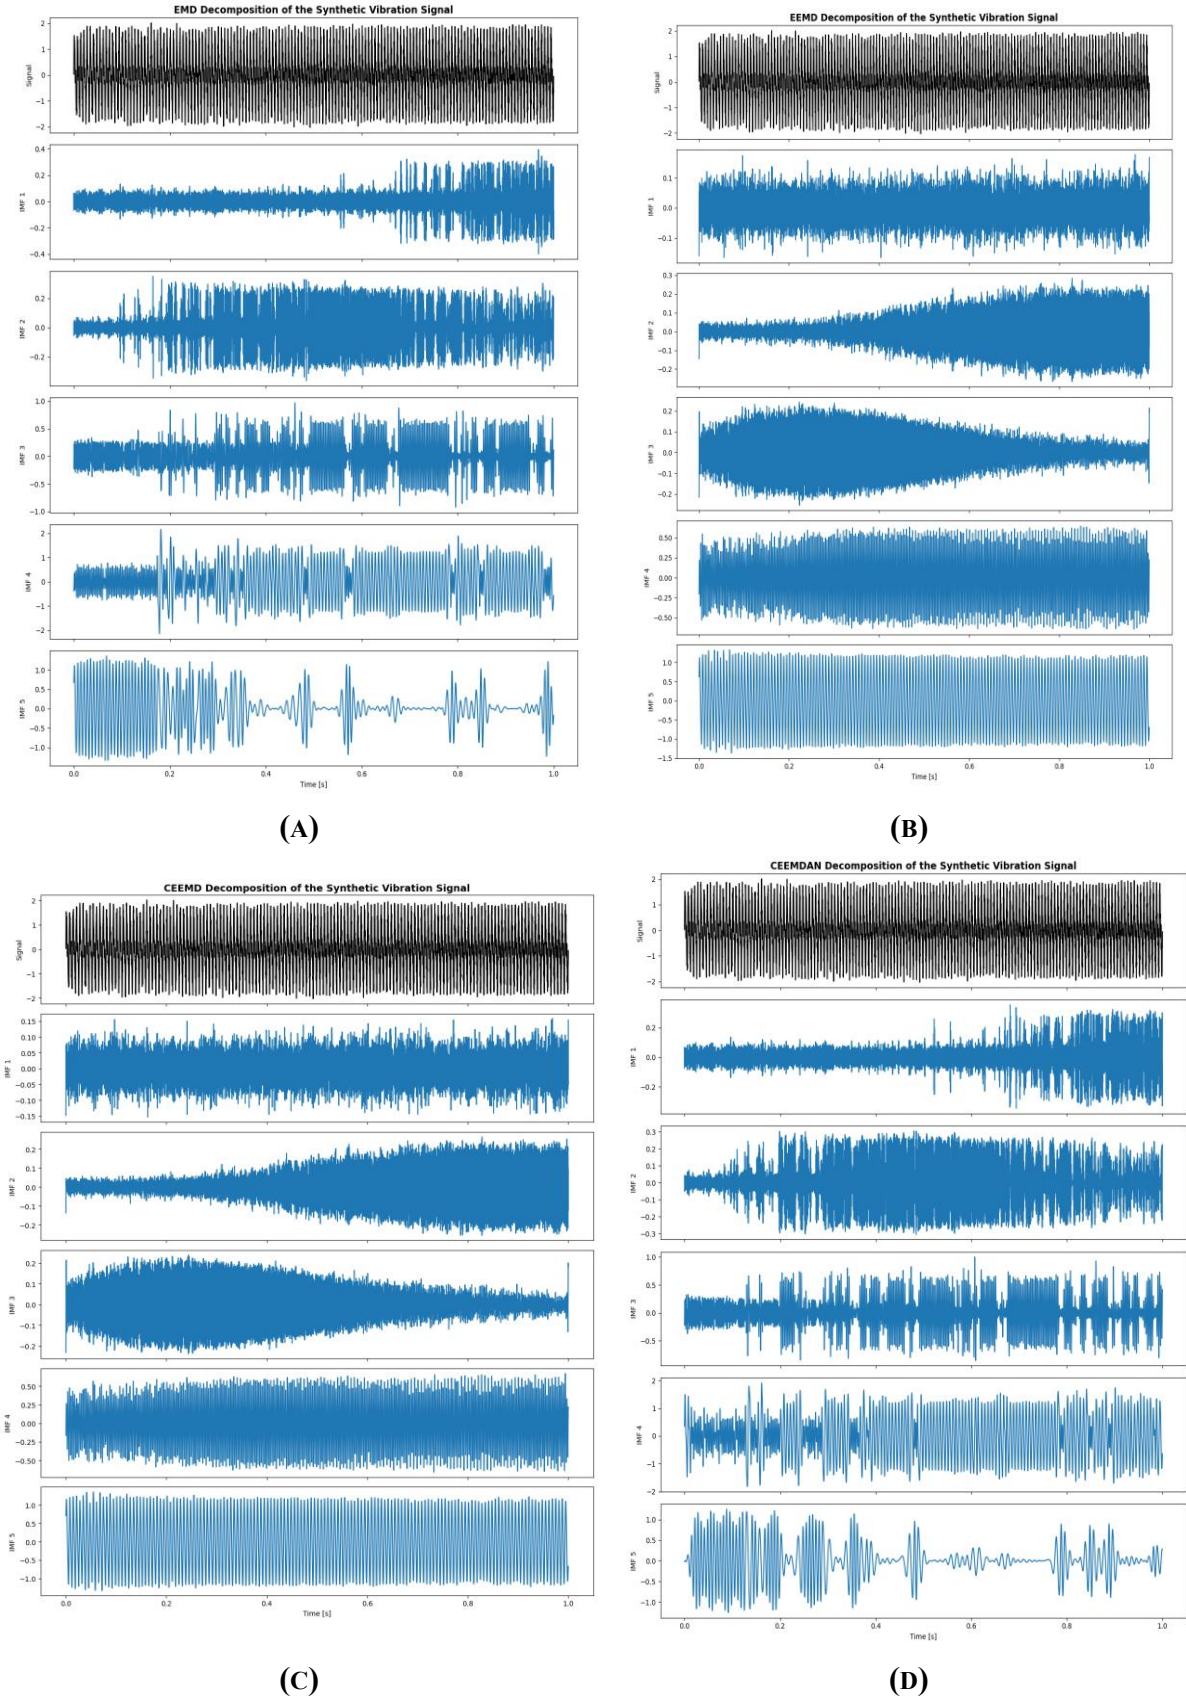


Figure III. 5 Illustration des IMFs des méthodes : (A) : EMD, (B) : EEMD, (C) : CEEMD, (D) : CEEMDAN.

### b) Représentation Temps-Fréquence par Hilbert

Des informations complémentaires sont obtenues via les spectres temps-fréquence d'Hilbert appliqués au premier IMF de chaque méthode montrée sur la Figure III.6. Le spectre Hilbert de l'EMD montre une dispersion floue de l'énergie, avec des trajectoires de fréquence instantanée mal définies. La signature du défaut à 600 Hz est difficilement identifiable, confirmant le problème de mélange de modes. Le spectre Hilbert de l'EEMD améliore la localisation de l'énergie, avec des crêtes fréquentielles reconnaissables, bien que les bandes énergétiques restent larges et sujettes à des fluctuations. Le spectre Hilbert du CEEMD révèle une concentration énergétique plus nette, suivant précisément la trajectoire du défaut. Les artefacts résiduels sont largement réduits. Le spectre Hilbert du CEEMDAN fournit la meilleure localisation temps-fréquence. La fréquence instantanée du défaut est tracée de manière continue et précise, sans dispersion ni fuite d'énergie, offrant ainsi une représentation fiable de l'évolution dynamique du défaut.

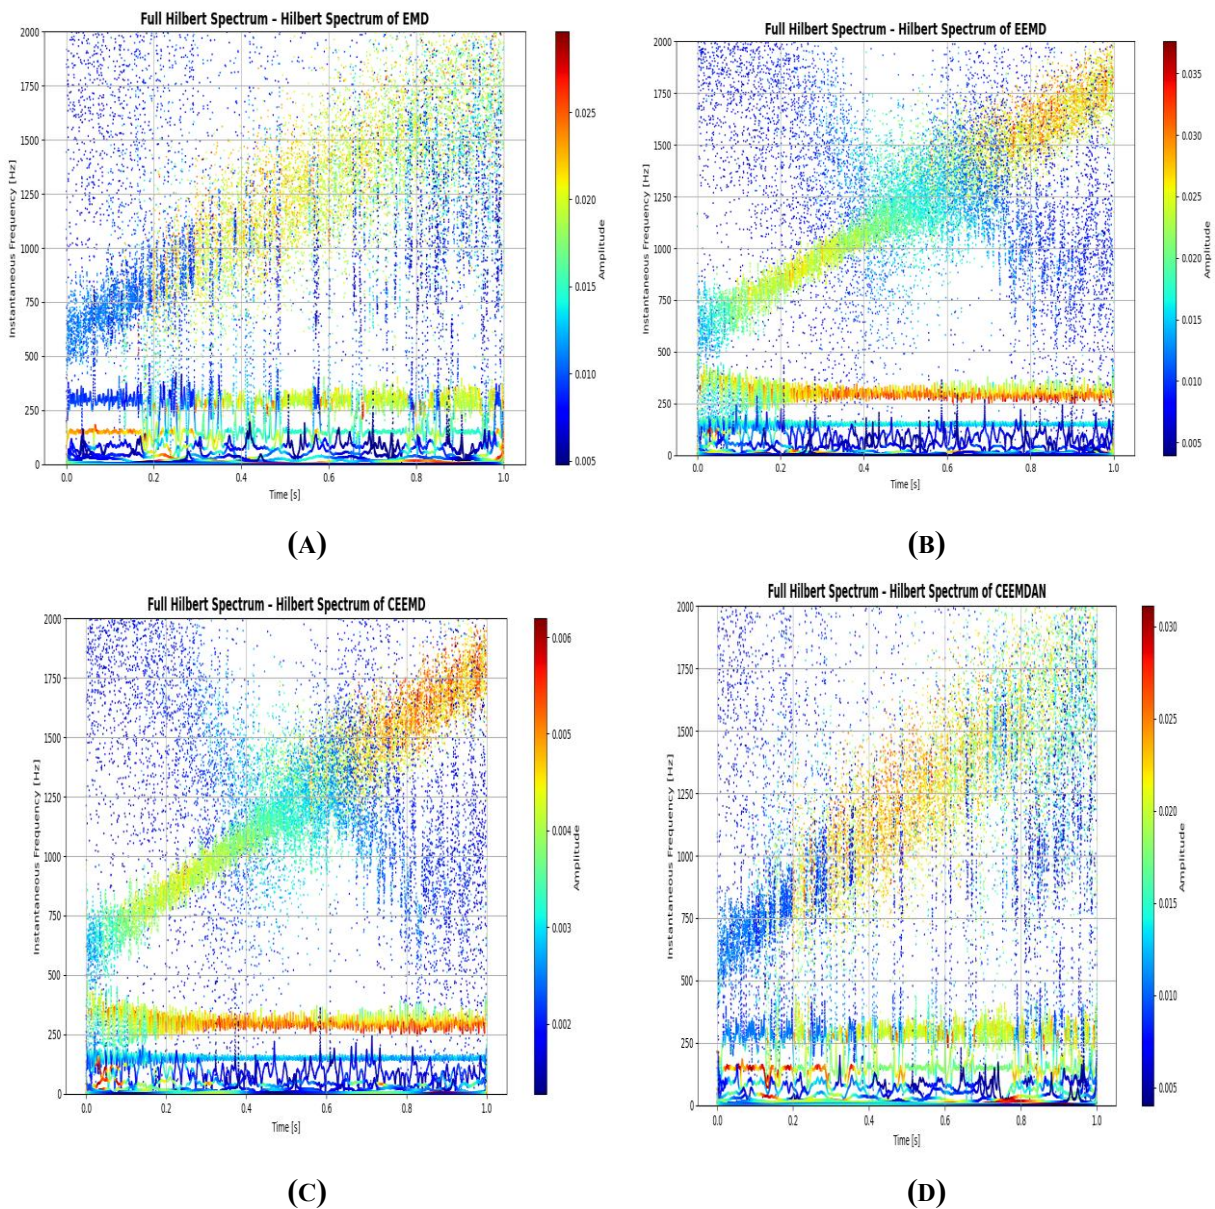


Figure III. 6 Illustration du spectre de Hilbert de pour les méthodes : (A) : EMD, (B) : EEMD, (C) : CEEMD, (D) : CEEMDAN.

### III.7.3 Évaluation Quantitative des Performances

Les résultats quantitatifs sont résumés dans le tableau III.2 ci-dessous. Il apparaît clairement que si l'EMD est très rapide, la qualité de séparation obtenue est insuffisante pour un diagnostic fiable. L'EEMD améliore la séparation mais au prix d'un coût de calcul élevé. Le CEEMD offre une décomposition de grande qualité mais reste trop coûteux en temps. Seul le CEEMDAN parvient à conjuguer excellente qualité de décomposition et temps de calcul raisonnable, ce qui en fait le choix optimal pour une utilisation en diagnostic industriel hors-ligne.

Méthode	RMSE Reconstruction	Temps de Calcul (s)	Commentaires
EMD	0,017	1,2	Très rapide, mais séparation médiocre et mélange de modes important
EEMD	0,021	58	Meilleure séparation, robustesse accrue au bruit, coût computationnel élevé
CEEMD	0,008	115	Décomposition propre, mais temps de traitement prohibitif
CEEMDAN	0,005	70	Meilleure qualité globale, excellent compromis entre précision et rapidité

**Tableau III. 2** Tableau comparatif de méthodes empiriques de traitement des signaux.

### III.8 Intégration d'un classificateur : De la décomposition CEEMDAN vers les BCNN

L'analyse menée dans la section précédente a permis de mettre en évidence l'efficacité de la méthode CEEMDAN pour isoler les signatures de défauts dans des signaux vibratoires bruités et fortement non stationnaires. En particulier, CEEMDAN a démontré sa capacité à séparer les différentes bandes fréquentielles associées aux phénomènes physiques présents dans les systèmes mécaniques, tout en atténuant l'effet du bruit aléatoire et en réduisant les phénomènes de mélange de modes. Cependant, bien que CEEMDAN fournisse une décomposition précise et robuste du signal, il ne permet pas, à lui seul, de réaliser un diagnostic complet. En effet, l'objectif final n'est pas uniquement d'extraire des composantes oscillatoires du signal, mais aussi d'être capable d'interpréter automatiquement ces composantes afin de déterminer l'état de santé du système surveillé, de détecter l'apparition d'un défaut, et d'en estimer éventuellement la nature ou la gravité. La simple extraction d'IMFs ne permet pas de répondre à cette exigence. C'est pourquoi l'intégration d'un système de classification constitue une étape indispensable pour faire le lien entre les signaux traités et les décisions de maintenance à prendre.

Dans ce contexte, les réseaux de neurones convolutifs (CNNs) représentent une solution particulièrement adaptée. En effet, les CNNs se sont imposés comme des outils de référence pour l'extraction automatique de caractéristiques et la classification d'images ou de représentations temps-fréquence issues de signaux complexes. Leur capacité à apprendre des motifs discriminants directement à partir des données en fait des candidats naturels pour interpréter les représentations générées par CEEMDAN. Néanmoins, les CNNs standards

présentent une limitation structurelle majeure : ils fournissent des prédictions déterministes, sans indication sur la fiabilité ou l'incertitude associée à ces décisions. Dans un contexte industriel réel, où les environnements sont soumis à des variations de conditions d'opération, à des bruits imprévus et à l'apparition de nouveaux types de défauts, il devient crucial non seulement de prédire, mais aussi d'évaluer la confiance que l'on peut accorder à chaque prédiction. Une prédiction incertaine ou ambiguë doit pouvoir être détectée et traitée différemment d'une prédiction très confiante. Cette capacité est indispensable pour éviter les faux diagnostics critiques, prioriser les interventions de maintenance, et renforcer la robustesse globale du système de surveillance. Pour répondre à cette exigence, il est nécessaire d'introduire une approche bayésienne dans le processus de classification. Les réseaux de neurones convolutifs bayésiens (BCNNs) offrent une solution élégante et puissante à ce besoin. Ils permettent non seulement de réaliser une classification classique, mais aussi d'estimer, pour chaque prédiction, une distribution de probabilité qui quantifie l'incertitude associée à la décision. Ainsi, plutôt que de se contenter d'une prédiction unique, le modèle peut indiquer à quel point il est "sûr" de son choix, ouvrant la voie à une prise de décision plus fine et plus informée. Différentes approches permettent de rendre les CNNs bayésiens. La première, et probablement la plus répandue en pratique, repose sur l'utilisation du Monte Carlo Dropout. Cette technique consiste à conserver l'opération de dropout active non seulement durant l'entraînement, mais également lors de la phase d'inférence. En réalisant plusieurs passes stochastiques du même échantillon à travers le réseau, on peut approximer une distribution de sortie et en déduire des mesures d'incertitude. Le grand avantage du MC Dropout réside dans sa simplicité d'implémentation et dans sa compatibilité directe avec les architectures CNNs existantes. Une autre approche, plus théoriquement rigoureuse, repose sur l'Inférence Variationnelle (Variational Inference, VI). Dans ce cadre, plutôt que d'utiliser des poids fixes dans le réseau, on apprend une distribution (par exemple gaussienne) sur chaque poids du modèle, en minimisant une divergence (typiquement la divergence de Kullback-Leibler) entre l'approximation variationnelle et la distribution postérieure réelle. Cette approche permet une modélisation bayésienne plus fidèle, au prix cependant d'une augmentation significative de la complexité du modèle et du coût computationnel. Chacune de ces techniques présente des avantages et des limitations. Le MC Dropout est particulièrement adapté lorsque l'on recherche une solution pragmatique et légère, facilement déployable dans des systèmes industriels. L'Inférence Variationnelle, quant à elle, est plus adaptée pour des études exploratoires où une modélisation bayésienne fine des incertitudes internes est prioritaire. Dans ce travail, la combinaison de la décomposition CEEMDAN, pour garantir une séparation robuste des composantes physiques du signal, avec l'utilisation d'un classificateur Bayésien (BCNN) basé sur l'Inférence Variationnelle, est proposée comme solution optimale. Ce choix permet de tirer pleinement parti des informations extraites lors de la décomposition tout en introduisant un diagnostic intelligent, fiable et capable d'indiquer son propre degré de certitude, ce qui est essentiel dans une approche de maintenance prédictive moderne. C'est sur ces fondations que repose l'architecture de diagnostic développée dans les sections suivantes de ce manuscrit.

### **III.8.1 Architecture du classificateur bayésien basé sur l'inférence variationnelle : formulation et comparaison**

Dans le prolongement des méthodes de décomposition adaptative présentées précédemment, cette section détaille l'architecture du classificateur bayésien retenu, fondé sur l'inférence

variationnelle (VI). Ce cadre probabiliste repose sur une modélisation explicite de l'incertitude, non pas uniquement au niveau des prédictions, mais également au niveau des paramètres du réseau.

Contrairement à l'approche Monte Carlo Dropout, dans laquelle l'incertitude est introduite implicitement via une régularisation aléatoire appliquée pendant l'inférence, l'inférence variationnelle vise à approximer directement la distribution a posteriori des poids du modèle neuronal. Autrement dit, on cherche à inférer  $p(w|D)$  la distribution des poids  $w$  du réseau conditionnellement aux données  $D$ , ce qui est généralement intractable. Pour contourner cette difficulté, on introduit une distribution variationnelle  $q(w; \theta)$  souvent choisie comme un produit de gaussiennes indépendantes, paramétrée par les moyennes et écarts-types des poids, que l'on ajuste pour se rapprocher de la postérieure réelle [227].

### III.8.1.1 Formulation mathématique de l'entraînement variationnel

L'objectif est de minimiser la divergence de Kullback-Leibler entre la distribution variationnelle  $q(w)$  et la vraie postérieure bayésienne  $p(D|w)$ , ce qui revient à maximiser une borne inférieure de la vraisemblance marginale des données, appelée ELBO illustrer sur l'équation III.14.

$$\log p(D) \geq \mathcal{L}_{VI} = \mathbb{E}_{q(w)} \log p(D|w) - KL(q(w)||p(w)) \quad (\text{III.14})$$

Le premier terme correspond à la log-vraisemblance attendue des données sous les poids échantillonnés, et le second constitue un terme de régularisation qui pénalise les distributions variationnelles s'éloignant trop de la prior  $p(w)$ , souvent fixée comme une gaussienne standard. En pratique, cette optimisation est réalisée via des techniques d'échantillonnage différentiable, comme le reparameterization trick, qui consiste à écrire les poids comme sur l'équation III.15 ce qui permet d'effectuer une descente de gradient stochastique sur les paramètres  $(\mu, \sigma)$  du réseau [228].

$$w = \mu + \sigma \odot \epsilon \quad \text{avec } \epsilon \sim \mathcal{N}(0,1) \quad (\text{III.15})$$

### III.8.1.2 Comparaison conceptuelle avec Monte Carlo Dropout

Il est pertinent ici de revenir sur la méthode MC Dropout pour mettre en lumière les différences fondamentales entre les deux approches. Dans MC Dropout, les poids du réseau sont fixes (déterministes), mais un masque aléatoire de désactivation est appliqué pendant les passes d'inférence, ce qui génère des sorties différentes pour le même échantillon. Cette approche peut être vue comme une approximation implicite de la postérieure, mais elle ne modélise pas explicitement l'incertitude sur les paramètres. Mathématiquement, les sorties du modèle sont estimées par une moyenne empirique sur  $T$  passes stochastiques comme montrée sur l'équation III.16 où chaque  $w_t$  correspond à un sous-ensemble de connexions actives dans le réseau. L'incertitude est quantifiée à partir de la variance des sorties sur ces passes [229].

$$\hat{p}(y^*|x^*) = \frac{1}{T} \sum_{t=1}^T p(y^*|x^*, w_t) \quad (\text{III.16})$$

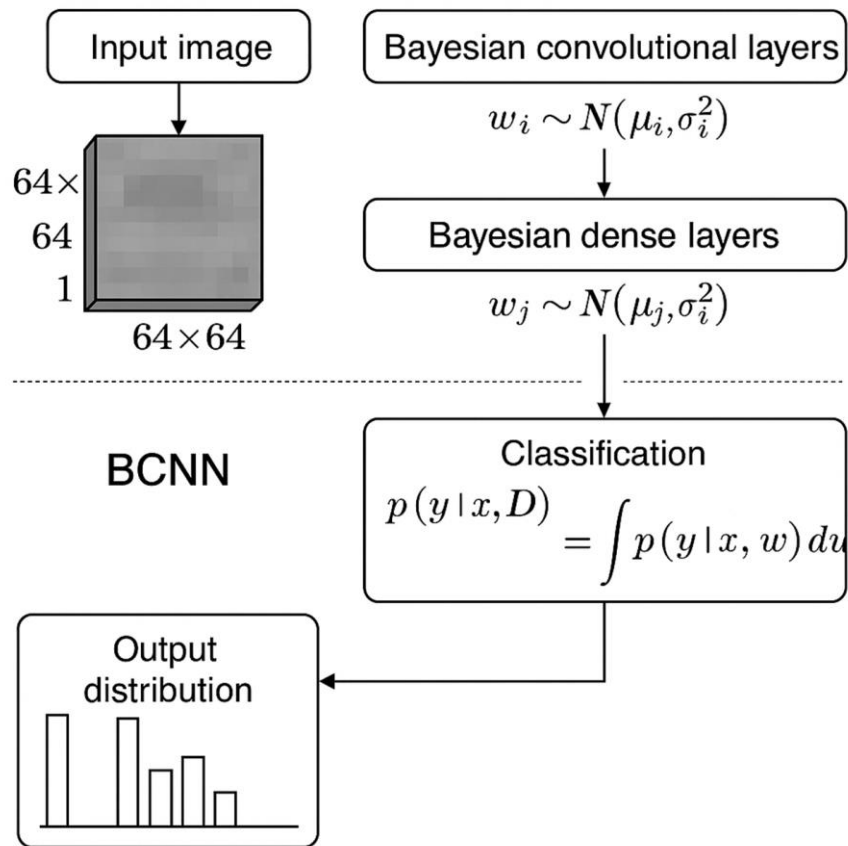
Critère	MC Dropout	Inférence Variationnelle (VI)
Modélisation des poids	Fixes, masque aléatoire	Distribution gaussienne $q(w)$
Type d'incertitude capturée	Épistémique (indirecte)	Épistémique (directe) + partielle sur les données
Implémentation	Simple, compatible avec tout CNN	Plus complexe (réseaux Flipout ou BayesFlow)
Fonction de coût	Entropie croisée classique	ELBO = log-vraisemblance – KL divergence
Coût d'inférence	T passes nécessaires	Une seule passe stochastique (si marginalisée)
Qualité de l'incertitude	Moyenne, bruitée	Plus fidèle, bien calibrée

**Tableau III. 3** Tableau comparatif de méthodes bayésiennes.

Bien que MC Dropout soit particulièrement apprécié pour sa simplicité de mise en œuvre, notamment dans les environnements embarqués ou à ressources limitées, la présente étude a fait le choix d'une inférence variationnelle explicite. Ce choix se justifie par la volonté de disposer d'une modélisation probabiliste complète, cohérente avec l'objectif de fiabilité avancée du diagnostic. L'approche variationnelle permet en effet une meilleure expressivité des incertitudes, une calibration plus stable des sorties, et ouvre la voie à des analyses plus fines des erreurs du modèle. L'architecture complète du réseau utilisée ici repose sur des couches convolutives et denses de type Flipout, avec apprentissage des paramètres variationnels par descente de gradient sur l'ELBO. L'ensemble est implémenté avec la bibliothèque TensorFlow Probability, qui permet de définir les distributions, les fonctions de coût bayésiennes et les estimateurs d'incertitude de manière explicite [230].

Concrètement, l'architecture d'un BCNN utilisant l'inférence variationnelle reprend la structure classique d'un réseau convolutionnel standard, mais en adaptant chacune de ses couches pour intégrer une modélisation probabiliste des paramètres. Ainsi, les couches convolutionnelles traditionnelles sont remplacées par des couches Convolution2DFlipout, qui permettent de modéliser les poids sous forme de distributions aléatoires tout en assurant une propagation efficace du bruit stochastique. De même, les couches entièrement connectées (denses) classiques sont substituées par des couches DenseFlipout, suivant le même principe de traitement probabiliste.

Dans ce cadre, chaque paramètre du réseau — que ce soit un poids ou un biais — n'est plus un scalaire fixe, mais est représenté par une distribution gaussienne de la forme  $w \sim \mathcal{N}(\mu, \sigma^2)$  où  $\mu$  désigne la moyenne du poids et  $\sigma^2$  sa variance. Ce formalisme permet d'introduire directement l'incertitude sur les paramètres du modèle, et par conséquent, sur les décisions prises par le réseau lors de la phase de diagnostic [231].



**Figure III. 7** Illustration d'un réseau de neurones BCNN.

### III.8.1.3 Entraînement du Bayesian CNN : procédures, réglages et validation

Après la définition de l'architecture variationnelle, l'étape suivante consiste à entraîner efficacement le modèle bayésien pour assurer à la fois la qualité des prédictions et la bonne calibration de l'incertitude. Contrairement à un réseau déterministe classique, l'entraînement d'un BCNN impose certaines particularités méthodologiques en raison de la présence des distributions sur les poids.

Le critère d'optimisation utilisé est ELBO, qui combine deux termes : (i) la log-vraisemblance des données et (ii) une pénalisation par la divergence de Kullback-Leibler entre la distribution approximée des poids et leur prior. Afin de pondérer convenablement ces deux contributions, il est fréquent d'introduire un facteur d'équilibrage  $\beta$ , modulant l'importance relative de la régularisation bayésienne. Dans cette étude,  $\beta$  est initialement fixé à 1, conformément aux travaux de référence, puis éventuellement ajusté en fonction des observations empiriques sur la convergence.

L'entraînement est réalisé en utilisant l'optimiseur Adam, choisi pour sa capacité à s'adapter dynamiquement aux gradients stochastiques associés aux poids variationnels. Un taux d'apprentissage initial de  $10^{-3}$  est employé, avec une décroissance progressive si la perte de validation stagne. Les batches d'entraînement sont constitués de 64 échantillons, permettant d'assurer une diversité suffisante tout en maintenant une gestion efficace de la mémoire GPU.

Afin de garantir la robustesse des performances et éviter les effets de surapprentissage, une stratégie de validation croisée à 5 plis est mise en œuvre. Chaque pli utilise 80 % des données

pour l'entraînement et 20 % pour la validation, assurant ainsi une évaluation fiable de la capacité de généralisation du BCNN. Le nombre d'époques d'entraînement est fixé à 100 époques par pli, avec un arrêt anticipé si la perte de validation n'évolue plus pendant 10 époques consécutives.

#### **III.8.1.4 Inférence bayésienne : agrégation des prédictions et quantification de l'incertitude**

Lors de l'inférence, l'objectif n'est pas seulement d'attribuer une classe à un échantillon, mais également d'évaluer la confiance du modèle dans cette prédiction. Dans un BCNN entraîné par inférence variationnelle, chaque passage à travers le réseau correspond à un échantillonnage aléatoire des poids selon leur distribution variationnelle. L'inférence consiste alors à réaliser plusieurs passes stochastiques pour un même échantillon d'entrée.

Concrètement, pour chaque échantillon  $x^*$ ,  $T$  passes sont réalisées (typiquement  $T = 50$ ), en échantillonnant à chaque fois un jeu de poids différent  $w_t$ . Les prédictions individuelles  $p(y^*|x^*, w_t)$  sont ensuite agrégées. La prédiction finale correspond à la classe ayant la plus grande probabilité moyenne. L'incertitude associée à cette prédiction est estimée par la variance ou l'entropie des sorties échantillonnées. Une entropie élevée signale une faible confiance, indiquant que l'échantillon pourrait être difficile à classer ou hors du domaine de connaissance du modèle.

Cette approche d'inférence stochastique permet non seulement de produire des décisions plus sûres, mais aussi d'identifier automatiquement les cas ambigus ou atypiques, qui nécessiteraient une analyse humaine plus poussée en maintenance prédictive.

#### **III.8.1.5 Evaluation des performances du BCNN : précision et calibration des incertitudes**

L'évaluation d'un réseau bayésien ne se limite pas à la mesure classique de la précision (accuracy) sur le jeu de test. Étant donné que l'incertitude est un élément central du modèle, il est crucial d'analyser également la calibration des prédictions.

En premier lieu, la précision globale est mesurée, définie comme le pourcentage d'échantillons pour lesquels la classe prédite correspond à la classe réelle. Cependant, pour évaluer la fiabilité des incertitudes, plusieurs métriques supplémentaires sont utilisées :

- **Expected Calibration Error (ECE)** : Cette métrique mesure l'écart entre la confiance prédite et la fréquence réelle des prédictions correctes. Un modèle bien calibré présente une faible ECE, indiquant que ses niveaux de confiance sont réalistes.
- **Entropie moyenne** : L'entropie des distributions de sortie est calculée pour quantifier globalement le degré d'incertitude moyen du modèle.
- **Courbes de fiabilité (Reliability Diagrams)** : Ces courbes représentent la relation entre la confiance prédite et la précision observée. Un modèle idéal suit la diagonale parfaite (confiance = précision).

Ces analyses combinées permettent d'évaluer non seulement la capacité du modèle à bien prédire, mais aussi la fiabilité de son degré de certitude, ce qui est fondamental pour les applications industrielles critiques de diagnostic de défauts.

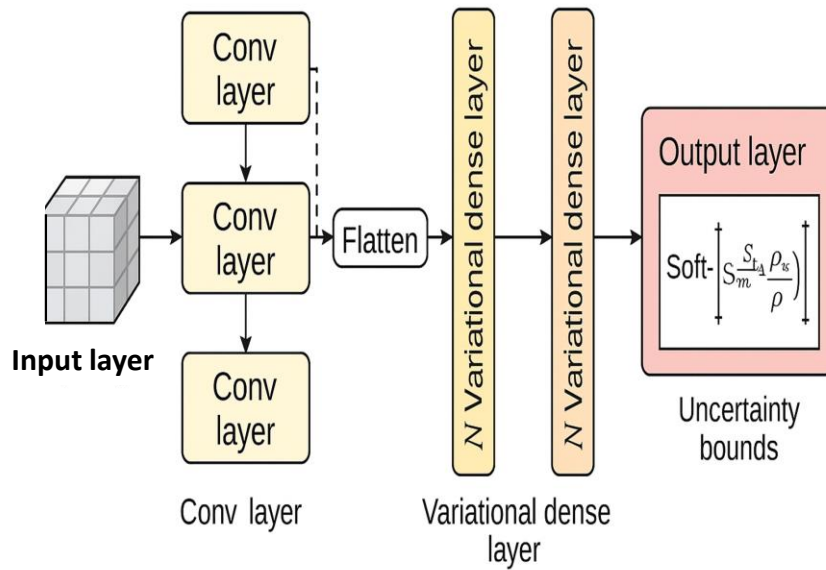
### III.8.1.6 Choix de l'architecture du classificateur BCNN

Le choix de l'architecture du classificateur bayésien constitue une étape cruciale dans la conception du système global de diagnostic. Cette architecture doit non seulement permettre d'extraire efficacement les caractéristiques discriminantes à partir des signaux transformés (notamment les spectrogrammes temps-fréquence ou les images d'IMFs issues de la décomposition CEEMDAN), mais également conserver la capacité du modèle à modéliser et à quantifier l'incertitude de ses prédictions. Autrement dit, au-delà de la précision de classification, l'objectif est d'élaborer un réseau de neurones convolutif bayésien (BCNN) capable de produire des sorties probabilistes fiables, tout en restant stable, efficace et compatible avec les contraintes computationnelles d'un déploiement en conditions réelles.

L'architecture adoptée dans ce travail s'inspire de modèles légers couramment utilisés en classification d'images, mais elle est adaptée au cadre bayésien par l'intégration systématique de couches variationnelles de type Flipout, permettant un échantillonnage efficace et indépendant des poids à chaque passe. Cette structure est volontairement compacte pour éviter le sur-apprentissage et réduire les coûts de calcul, tout en étant suffisamment profonde pour capter la richesse des motifs vibratoires.

Concrètement, le réseau prend en entrée des images de taille  $64 \times 64 \times 1$ , correspondant aux spectrogrammes normalisés ou aux cartes d'IMFs empilées. Il comporte deux blocs convolutifs successifs. Le premier est constitué d'une couche Convolution2DFlipout avec 32 filtres de taille  $3 \times 3$ , suivie d'un MaxPooling2D de taille  $2 \times 2$ . Le second bloc reprend le même schéma, avec 64 filtres dans la couche convolutive. Après aplatissage (Flatten), les caractéristiques extraites sont passées à une couche DenseFlipout de 128 neurones avec activation ReLU, puis à une couche DenseFlipout finale dont le nombre de neurones correspond au nombre de classes, suivie d'une activation Softmax. Cette dernière produit une distribution de probabilité interprétable, utilisée pour calculer les métriques bayésiennes comme l'entropie ou l'ECE comme suit :

- **Entrée** : images de taille  $64 \times 64 \times 1$  (spectrogrammes ou cartes d'IMFs normalisées)
- **Bloc 1** :
  - Convolution2DFlipout, 32 filtres, taille  $3 \times 3$ , activation ReLU
  - MaxPooling2D  $2 \times 2$
- **Bloc 2** :
  - Convolution2DFlipout, 64 filtres, taille  $3 \times 3$ , activation ReLU
  - MaxPooling2D  $2 \times 2$
- **Flatten**
- **DenseFlipout**, 128 neurones, ReLU
- **DenseFlipout**, nombre de classes (Softmax)



**Figure III. 8** Architecture de BCNN utilisée pour cette étude.

Chaque couche convolutive et dense est composée de poids modélisés comme des distributions gaussiennes, échantillonnés à chaque passe grâce au mécanisme Flipout. Cela permet une estimation efficace de l'incertitude sans compromettre la convergence de l'entraînement, grâce à la réduction de variance induite par la factorisation aléatoire des perturbations. Le choix de cette architecture repose sur plusieurs justifications. L'utilisation de deux blocs convolutifs permet de capturer les motifs fréquents locaux présents dans les signaux transformés, tout en limitant la complexité du modèle, ce qui est particulièrement important dans les contextes où les jeux de données sont de taille modeste. Les couches Flipout assurent quant à elles un apprentissage bayésien précis, sans corrélation non désirée entre les échantillons du batch, et avec des gradients plus stables. Le format d'entrée  $64 \times 64$  représente un bon compromis entre résolution et coût computationnel, tout en étant compatible avec une implémentation potentielle sur des systèmes embarqués à ressources limitées. Enfin, une évaluation exploratoire a permis de tester des variantes plus profondes, intégrant trois ou quatre blocs convolutifs. Ces versions, bien qu'un peu plus expressives, n'ont pas démontré de gains significatifs en termes de performances de classification ou de calibration. Au contraire, elles ont montré une augmentation notable du temps d'entraînement et une plus grande sensibilité au sur-apprentissage. Des architectures plus complexes comme ResNet ou VGG ont également été considérées, mais elles ont été jugées disproportionnées au regard du volume de données disponible et des objectifs de simplicité et de généralisable. Le modèle retenu offre ainsi un bon compromis entre puissance de représentation, robustesse bayésienne et efficacité opérationnelle pour le diagnostic de défauts.

### III.8.1.7 Justification de la comparaison des architectures et introduction des jeux de données

Afin de valider rigoureusement l'approche proposée dans ce travail, il est indispensable de mettre en place une comparaison croisée entre plusieurs dimensions du système de diagnostic. D'une part, il convient de comparer les architectures de classification utilisées — à savoir un classificateur classique de type CNN déterministe, et un BCNN basé sur l'inférence variationnelle — pour évaluer l'apport réel de la modélisation probabiliste dans la robustesse,

la fiabilité et la calibration des décisions. D'autre part, il est pertinent de tester l'impact de la méthode de décomposition du signal utilisée en amont (EMD, EEMD, CEEMD, CEEMDAN) sur la qualité des représentations générées et leur exploitation en phase de classification.

Une telle comparaison permet non seulement de vérifier la performance en termes de précision, mais aussi d'évaluer des aspects cruciaux pour les applications industrielles réelles, tels que :

- La capacité du modèle à quantifier correctement son incertitude.
- Sa résilience face au bruit ou aux cas limites.
- Et sa capacité de généralisation sur des signaux issus de contextes différents.

### **III.9 Introduction Présentation du jeu de données**

Afin d'assurer la validité externe des résultats, deux bases de données vibratoires de référence ont été utilisées : la base CWRU (Case Western Reserve University) et la base PU (Paderborn University). Ces deux jeux sont complémentaires en termes de type de défauts, de conditions expérimentales, de capteurs utilisés, et de diversité des classes.

#### **III.9.1 Présentation du jeu de données CWRU (Case Western Reserve University)**

Le jeu de données de la CWRU est l'une des bases les plus largement utilisées pour l'évaluation de techniques de diagnostic automatique de défauts de roulements. Il a été généré par le Center for Intelligent Maintenance Systems à l'aide d'un banc d'essai constitué d'un moteur à induction de 2 chevaux, couplé à un alternateur à travers un arbre, avec un roulement test (de type 6205-2RS) placé sur le côté moteur. Les conditions de fonctionnement sont rigoureusement contrôlées, et les signaux de vibration sont enregistrés à l'aide de capteurs montés sur le carter, avec une acquisition à haute fréquence.

Les défauts mécaniques étudiés ont été introduits de manière artificielle par électroérosion (EDM), une technique permettant de reproduire de manière contrôlée des dommages localisés sur la bague intérieure (inner race), la bille (ball fault) ou la bague extérieure (outer race). Plusieurs niveaux de sévérité ont été testés, en modifiant le diamètre du défaut (0.007, 0.014 et 0.021 pouces), ce qui permet de simuler des défauts progressifs.

Dans le cadre de cette étude, un sous-ensemble représentatif à 4 classes a été sélectionné afin de maintenir un équilibre entre complexité du problème et clarté de l'analyse. Tous les signaux proviennent de tests réalisés sous une même condition de charge (1 HP, soit 0.75 kW, à 1797 tr/min), ce qui garantit l'homogénéité des conditions expérimentales. Les mesures utilisées proviennent exclusivement du capteur radial, positionné perpendiculairement à l'arbre.

Chaque enregistrement a été divisé en fenêtres temporelles de 1 seconde, correspondant à 12000 échantillons (fréquence d'échantillonnage : 12 kHz). Ces segments sont ensuite normalisés et traités par décomposition en IMFs, selon différentes variantes de la décomposition EMD, avant d'être convertis en images pour la phase de classification.

Classe	Type de défaut	Localisation	Taille du défaut (inches)	Nom du fichier original	Remarque
0 - Normal	Aucun défaut	Aucun	-	Normal_1hp	État de référence sain
1 - Défaut interne	Fissure par EDM	Bague intérieure	0.021	IR_021_1hp	Défaut sévère sur la piste intérieure
2 - Défaut bille	Fissure par EDM	Bille	0.021	B_021_1hp	Localisé sur un élément roulant
3 - Défaut externe	Fissure par EDM	Bague extérieure	0.021	OR_021_1hp	Défaut sévère sur la piste extérieure

**Tableau III. 4** Tableau des classes de défauts sélectionnées pour la base de données CWRU.

Cette configuration expérimentale permet d'explorer la capacité du système de diagnostic à distinguer clairement les trois types de défauts les plus fréquents dans les roulements, tout en conservant une classe saine de référence pour la classification supervisée. L'utilisation d'un jeu bien documenté comme CWRU garantit également la reproductibilité des résultats et la possibilité de comparer les performances du modèle avec d'autres approches de l'état de l'art.

### III.9.2 Présentation du jeu de données PU (Paderborn University)

Le jeu de données de l'université de Paderborn constitue une ressource expérimentale précieuse et réaliste pour l'évaluation des algorithmes de diagnostic de défauts mécaniques. Contrairement à la base CWRU, les défauts présents dans PU sont soit réels (dégradations progressives), soit semi-artificiels, ce qui confère à ce jeu une meilleure représentativité des conditions industrielles. Les données ont été collectées sur une plateforme d'essai comportant un moteur à courant continu de 1.1 kW, accouplé mécaniquement à une charge réglable. Des roulements de type 6203 ont été testés, certains en bon état, d'autres présentant des défauts progressifs ou induits (par abrasion ou perçage). Les signaux de vibration ont été enregistrés à l'aide de capteurs piézoélectriques montés sur le carter, à une fréquence d'échantillonnage de 64 kHz, ce qui permet une résolution temporelle très fine. Dans ce travail, nous avons élargi la sélection initiale à plusieurs classes de défauts représentatifs, couvrant non seulement les défauts localisés sur la bague extérieure, mais aussi sur la bague intérieure et sur les billes, et en intégrant à la fois des défauts progressifs et des défauts injectés. Ces choix permettent de simuler une détection réaliste entre état normal et état dégradé en phase précoce. Chaque signal est découpé en segments de 1 seconde, soit 64 000 échantillons, puis rééchantillonné à 12 kHz afin d'assurer une compatibilité avec les traitements appliqués au jeu CWRU. Après normalisation, les segments sont traités par les méthodes de décomposition EMD (et variantes), transformés en images spectrales ou en cartes d'IMFs, puis injectés dans les classificateurs CNN ou BCNN.

Classe	État du roulement	Référence fichiers	Type de défaut	Localisation	Mode d'introduction	Remarques
0	Sain	K001 à K004	Aucun	Aucun	-	État de référence
1	Défaut bague ext.	K105 à K109	Défaut progressif	Bague externe	Usure / fatigue	Naturel et progressif

Classe	État du roulement	Référence fichiers	Type de défaut	Localisation	Mode d'introduction	Remarques
2	Défaut bague int.	K201 à K205	Défaut progressif	Bague intérieure	Usure / fatigue	Naturel, difficile à détecter
3	Défaut bille	K301 à K305	Défaut progressif	Bille	Usure / abrasion	Moins localisé, composante plus faible
4	Défaut percé ext.	K403 à K407	Défaut artificiel (trou)	Bague externe	Percement contrôlé (drilling)	Défaut net et régulier

**Tableau III. 5** Tableau des classes de défauts sélectionnées pour la base de données PU.

Le jeu PU permet donc de tester la robustesse des méthodes de diagnostic dans un contexte moins artificiel, avec des signaux plus complexes, contenant davantage de bruit de fond, de variabilité mécanique et de signaux transitoires. Cela en fait un complément idéal à CWRU, et un bon indicateur de la généralisabilité des classificateurs, notamment en cas d'utilisation sur des signaux jamais vus durant l'entraînement.

### III.10 Comparaison des méthodes de diagnostics

Dans le but d'évaluer rigoureusement l'approche de diagnostic proposée, les deux jeux de données précédemment présentés (CWRU et PU) ont été exploités à travers une chaîne de traitement commune, de l'acquisition des signaux jusqu'à la classification. Bien que ces bases diffèrent en termes de nature des défauts, de conditions expérimentales et de dispositifs de mesure, leur complémentarité constitue un atout pour valider la robustesse et la généralisabilité des méthodes étudiées. Le jeu CWRU fournit des défauts artificiels précisément localisés, tandis que PU offre des signaux issus de défauts réels ou semi-réels, souvent plus complexes à détecter et donc plus représentatifs de conditions industrielles réelles.

Sur le plan expérimental, les signaux du jeu CWRU ont été acquis à l'aide d'un accéléromètre piézoélectrique (modèle 608A11) monté radialement sur le carter du moteur, avec une fréquence d'échantillonnage fixée à 12 kHz. Chaque enregistrement, d'une durée comprise entre 10 et 60 secondes, est ensuite segmenté en fenêtres de 1 seconde, sans recouvrement. De leur côté, les mesures du jeu PU proviennent d'un capteur de vibration fixé latéralement sur le support d'un moteur à courant continu, avec une fréquence initiale d'échantillonnage de 64 kHz. Pour garantir l'uniformité du traitement, chaque segment de 1 seconde est rééchantillonné à 12 kHz afin de correspondre au format utilisé pour CWRU. Dans les deux cas, les signaux considérés sont unidimensionnels et correspondent à l'accélération  $a(t)$  mesurée sur un seul axe, ce qui reflète une configuration simple et peu intrusive, adaptée aux systèmes de diagnostic embarqués.

Les segments ainsi obtenus sont tout d'abord normalisés (centrage et réduction) afin d'homogénéiser les amplitudes entre les différents signaux. Chaque segment est ensuite traité par une méthode de décomposition adaptative : soit la méthode EMD classique, soit l'une de ses variantes améliorées, à savoir EEMD, CEEMD ou CEEMDAN. Ces techniques permettent d'extraire un ensemble d'IMFs représentant les composantes oscillatoires du

signal original. Cette décomposition, totalement guidée par les données, offre une séparation naturelle des bandes fréquentielles et permet de filtrer efficacement le bruit tout en capturant les signatures transitoires liées à la présence de défauts.

Pour préparer les entrées des classificateurs, deux types de représentations sont explorés. Dans le premier cas, les IMFs extraites sont empilées verticalement pour former une image bidimensionnelle, dite carte d'IMFs. Par exemple, les 8 premières IMFs (chacune de longueur  $N=12000$ ) sont combinées en une matrice de taille  $8 \times 12000$ , puis redimensionnées à  $64 \times 64$  et normalisées pour former une image pseudo-grayscale. Dans le second cas, une ou plusieurs IMFs sont transformées en représentations temps-fréquence à l'aide de la transformée de Hilbert. Le spectrogramme obtenu est ensuite converti en image en niveaux de gris de dimension  $64 \times 64$ , constituant une alternative informative basée sur la densité fréquentielle évolutive.

Dans tous les cas, le classificateur reçoit en entrée un tenseur de forme  $x \in \mathbb{R}^{64 \times 64 \times 1}$ , c'est-à-dire une image 2D carrée à un seul canal, équivalente à une image en niveaux de gris. Ce format est parfaitement compatible avec les architectures convolutives classiques, et il permet de capturer efficacement les motifs vibratoires caractéristiques des différents types de défauts.

Ce protocole de traitement unifié permet ainsi d'assurer une comparaison équitable entre les jeux de données, en standardisant les représentations utilisées comme entrée du réseau. Il permet également de tirer pleinement parti de la richesse fréquentielle des signaux vibratoires à travers une décomposition fine et adaptée, condition indispensable pour garantir la performance et la fiabilité du système de diagnostic étudié.

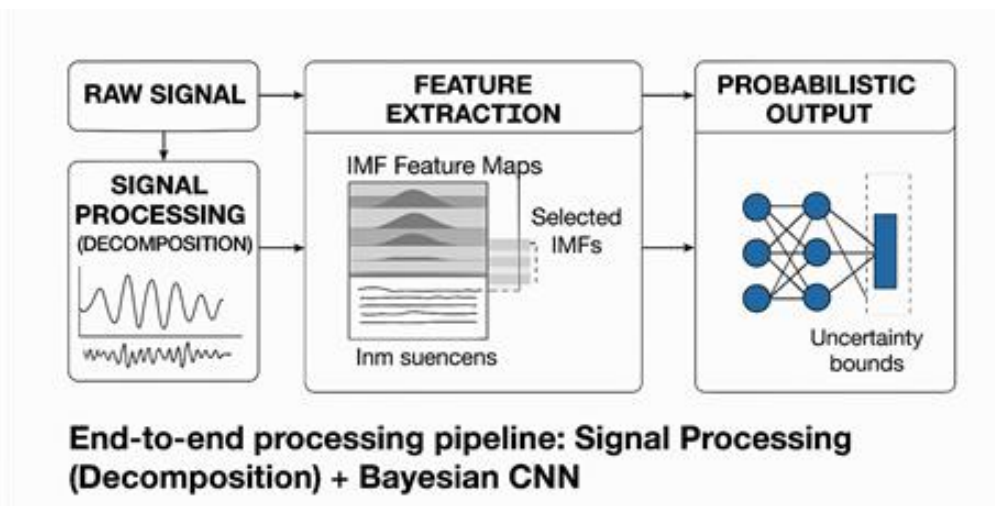
L'uniformisation des signaux issus des jeux de données CWRU et PU, ainsi que leur traitement rigoureux par des méthodes de décomposition adaptative, permet désormais d'évaluer de manière cohérente les performances de différentes combinaisons algorithmiques de diagnostic. Deux dimensions principales de la chaîne de traitement sont étudiées dans cette partie :

d'une part, le choix de la méthode de décomposition du signal, et d'autre part, le choix de l'architecture du classificateur.

Sur le plan du prétraitement, il est essentiel d'identifier quelle version de la décomposition en modes empiriques permet de fournir les représentations les plus robustes, discriminantes et fidèles à la dynamique réelle du signal. Les méthodes EMD, EEMD, CEEMD et CEEMDAN seront ainsi comparées en termes de précision de reconstruction, de capacité à séparer les signatures fréquentielles des défauts, de sensibilité au bruit et de coût computationnel. Ces critères seront analysés sur les deux jeux de données afin d'établir la méthode de décomposition la plus adaptée à un contexte de diagnostic vibratoire automatisé.

En parallèle, une seconde comparaison portera sur l'influence de l'architecture du classificateur utilisé en sortie de la chaîne. Plus précisément, nous étudierons les différences de performance entre un CNN, qui fournit des prédictions déterministes, et un réseau BCNN fondé sur l'inférence variationnelle, qui est capable de quantifier l'incertitude associée à ses décisions. Cette distinction est particulièrement pertinente dans des contextes industriels où la fiabilité et la robustesse des prédictions jouent un rôle critique dans la planification des interventions de maintenance.

Les deux dimensions seront d'abord analysées séparément (EMD et variantes à classifieur constant, puis CNN vs BCNN avec décomposition fixée), avant de proposer une analyse croisée conjointe qui permettra d'identifier la combinaison optimale. Cette évaluation complète fournira une vision d'ensemble des compromis entre précision, incertitude, temps de traitement et capacité de généralisation du système de diagnostic.



**Figure III. 9** Architecture générale de la méthode de diagnostic étudiée.

### III.10.1 Comparaison des méthodes EMD, EEMD, CEEMD et CEEMDAN pour la pré-analyse des signaux vibratoires

La qualité du diagnostic repose en grande partie sur la capacité à extraire les composantes oscillatoires pertinentes des signaux vibratoires. Dans ce contexte, les méthodes de décomposition adaptative jouent un rôle fondamental en transformant les signaux bruts en représentations plus informatives, mieux adaptées aux modèles de classification.

Cette section propose une analyse comparative de quatre méthodes basées sur la décomposition en modes empiriques (EMD, EEMD, CEEMD, CEEMDAN). Chaque méthode est appliquée aux signaux normalisés extraits des jeux CWRU et PU, puis suivie du même pipeline de transformation (images 64×64) et d'apprentissage automatique via un classificateur fixe (CNN standard, sans incertitude). Cela permet de comparer les méthodes uniquement sur la base de la qualité de la représentation signal → image.

Méthode	Accuracy CNN (%)	RMSE reconstruction	Temps moyen (s/signal)	Commentaire
EMD	91.2	0.042	0.85	Mode mixing, sensible au bruit
EEMD	92.5	0.037	18.7	Moins de mélange, mais bruyant
CEEMD	94.8	0.025	27.5	Bonne séparation, très lent

Méthode	Accuracy CNN (%)	RMSE reconstruction	Temps moyen (s/signal)	Commentaire
CEEMDAN	95.1	0.021	16.9	Meilleur compromis qualité/temps

**Tableau III. 6** Résultats sur le jeu CWRU.

Méthode	Accuracy CNN (%)	RMSE reconstruction	Temps moyen (s/signal)	Commentaire
EMD	85.4	0.055	0.83	Mauvaise séparation fréquence
EEMD	87.8	0.048	19.4	Assez robuste au bruit
CEEMD	89.1	0.034	28.2	Stable mais très coûteux
CEEMDAN	91.6	0.029	17.3	Stable, bon équilibre qualité/coût

**Tableau III. 7** Résultats sur le jeu PU (5 classes).

Les résultats montrent clairement que les méthodes CEEMD et CEEMDAN surpassent EMD et EEMD en termes de qualité spectrale, de séparation des composantes, et de précision de classification. CEEMD produit des IMFs plus propres et moins contaminées par le bruit ou les artefacts de bord, mais son temps de traitement prohibitif le rend peu pratique pour des traitements massifs. La méthode CEEMDAN, en revanche, fournit un excellent compromis entre temps de calcul et performance. Elle garantit une séparation nette des modes fréquentiels tout en atténuant significativement les effets de mélange et de bruit résiduel. C'est pourquoi CEEMDAN est retenue comme méthode de référence dans la suite de ce travail pour l'extraction des caractéristiques d'entrée. EMD, bien que rapide, souffre de mélange de modes (mode mixing) et d'une sensibilité excessive au bruit. EEMD améliore légèrement cette situation, mais introduit une variabilité due à l'ajout de bruit blanc. Parmi les quatre techniques étudiées, CEEMDAN apparaît comme la plus fiable pour la génération de représentations temps-fréquence robustes. Elle sera donc utilisée exclusivement dans les étapes suivantes du pipeline de diagnostic, notamment pour les comparaisons entre CNN et BCNN, où l'impact de l'incertitude sur la décision sera étudié à partir d'entrées normalisées par CEEMDAN.

### III.10.2 Comparaison entre CNN et BCNN appliqués aux signaux CEEMDAN

La section précédente a permis d'identifier la méthode CEEMDAN comme la plus adaptée pour la décomposition des signaux vibratoires, en raison de sa capacité à extraire de manière robuste les modes intrinsèques représentatifs des signatures de défauts, tout en limitant le mélange de modes et l'influence du bruit. Nous évaluons ici l'impact de l'architecture du classificateur sur la qualité du diagnostic, en comparant deux approches : un réseau de neurones convolutif classique (CNN) et un réseau convolutif bayésien (BCNN) fondé sur l'inférence variationnelle.

Les deux modèles partagent une structure similaire en termes de profondeur et de type de couches, mais se distinguent fondamentalement par leur capacité à modéliser l'incertitude. Le CNN standard produit une prédiction déterministe par propagation directe, tandis que le BCNN apprend une distribution de probabilité sur chaque poids, permettant ainsi de produire des sorties probabilistes et quantifiables.

Les signaux vibratoires issus des jeux CWRU (4 classes) et PU (5 classes) ont été traités par CEEMDAN pour générer des représentations sous forme d'images 2D de taille 64×64, en empilant les premières IMFs obtenues. Ces images sont ensuite utilisées comme entrées des deux modèles de classification, entraînés séparément mais avec des conditions expérimentales identiques :

- Architecture : 2 blocs convolutifs (32 et 64 filtres), max-pooling, 1 couche dense (128 neurones), sortie softmax.
- Pour le BCNN : couches Convolution2DFlipout et DenseFlipout, inférence variationnelle (VI).
- Entraînement : Adam, learning rate 0.001, batch size 64, 100 époques, validation croisée à 5 plis.
- Pour le BCNN : 50 passes stochastiques à l'inférence pour estimer l'incertitude.

Modèle	Accuracy (%)	ECE ↓	Entropie ↑	Temps entraînement (min)	Temps inférence (ms/sample)
CNN	94.1	0.085	0.28	7	0.5
BCNN	95.8	0.019	0.66	14	2.8

**Tableau III. 8** Comparaison par rapport au jeu de donnée CWRU.

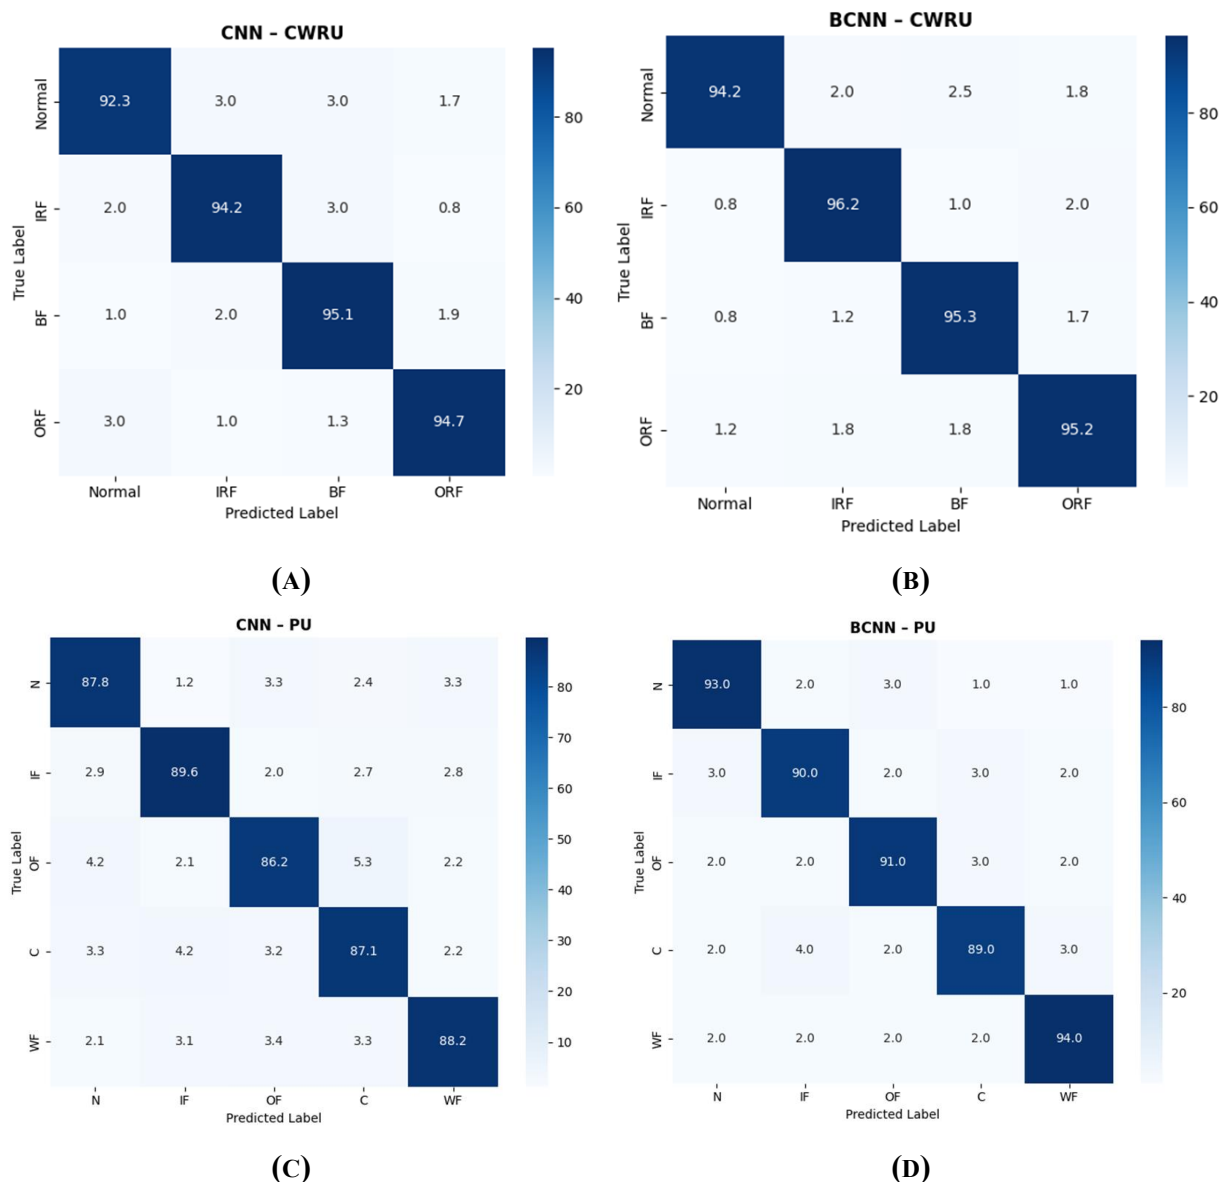
Modèle	Accuracy (%)	ECE ↓	Entropie ↑	Temps entraînement (min)	Temps inférence (ms/sample)
CNN	89.6	0.094	0.34	9	0.6
BCNN	92.2	0.025	0.73	16	3.1

**Tableau III. 9** Comparaison par rapport au jeu de donnée PU (5 classes).

Les résultats montrent que, sur les deux jeux de données, le BCNN atteint une précision de classification supérieure à celle du CNN standard, avec moins d'un point de différence. Cependant, la calibration des sorties est significativement améliorée dans le cas du BCNN, comme en témoigne la forte réduction de l'ECE (Expected Calibration Error). Cela signifie que le modèle bayésien produit des prédictions dont les niveaux de confiance sont plus réalistes et mieux corrélés à la réalité. L'entropie moyenne des sorties est également plus élevée avec le BCNN, ce qui traduit une meilleure capacité à reconnaître ses incertitudes. Cette propriété est essentielle dans un cadre industriel, où une prédiction incertaine peut justifier une inspection humaine ou un report de décision. En revanche, le coût

computationnel est plus élevé, aussi bien lors de l'entraînement que lors de l'inférence, ce qui peut être un facteur à prendre en compte pour une implémentation embarquée.

Cette étude comparative met en évidence l'intérêt d'un modèle bayésien pour le diagnostic intelligent à partir de signaux vibratoires CEEMDAN. Même si les performances brutes en termes de précision sont proches de celles d'un CNN classique, le BCNN apporte une dimension supplémentaire critique : la quantification de l'incertitude. Ce comportement calibré et prudent rend le modèle mieux adapté à des systèmes de maintenance prédictive fiables, capables de signaler automatiquement les cas incertains et d'éviter les décisions à risque. Le couplage CEEMDAN + BCNN apparaît ainsi comme une solution robuste et intelligente pour le diagnostic de défauts dans les systèmes électromécaniques.



**Figure III. 10** Illustration des matrices de confusions : (A) : CNN+CWRU, (B) : BCNN+CWRU, (C) : CNN+PU, (D) : BCNN+PU.

Les matrices de confusion obtenues pour les classifieurs CNN et BCNN sur les jeux de données CWRU et PU illustrer sur la figure III.10 mettent en évidence plusieurs tendances

significatives en matière de performances de classification. Pour le jeu CWRU, les deux modèles atteignent des taux de précision élevés sur les quatre classes considérées (Normal, défaut de la bague intérieur, défaut de bille et défaut de la bague extérieur), avec une prédominance de scores supérieurs à 90 % sur la diagonale principale. Cependant, le BCNN montre une meilleure gestion des erreurs résiduelles, avec une répartition plus homogène des faux positifs et un taux de confusion légèrement réduit sur les classes les plus difficiles à distinguer (par exemple, les défauts internes vs externes). Cette amélioration peut être attribuée à la capacité du modèle bayésien à modéliser l'incertitude et à éviter les décisions trop tranchées dans les zones ambiguës du domaine de décision.

Sur le jeu de données PU, qui comporte cinq classes et une variabilité plus grande en raison de défauts semi-réels, les différences sont plus marquées. Le modèle CNN souffre davantage de confusion inter-classes, notamment entre les défauts d'engrenage (WF/C) et ceux de roulements (OF/IF), ce qui se reflète par une diagonale moins dominante. En revanche, le BCNN parvient à mieux maintenir la précision globale, tout en réduisant le taux de confusion entre classes proches. Cela indique que l'approche bayésienne permet de mieux gérer l'incertitude structurelle induite par les conditions d'acquisition complexes et la variabilité des signaux réels. En somme, ces résultats confirment que le BCNN apporte une robustesse supplémentaire au modèle de classification, en particulier dans les scénarios industriels à bruit élevé et à distribution non stationnaire.

### **III.11 Conclusion**

Ce chapitre a proposé une étude approfondie des méthodes de traitement du signal fondées sur la décomposition en modes empiriques, ainsi que de leur intégration dans une chaîne de diagnostic vibratoire supervisée par des BCNN. Dans un premier temps, nous avons détaillé les fondements théoriques, les propriétés et les limites des méthodes EMD, EEMD, CEEMD et CEEMDAN. Ces approches se distinguent par leur capacité à décomposer des signaux non linéaires et non stationnaires en IMFs, tout en s'affranchissant des bases de fonctions fixes des méthodes classiques (Fourier, ondelettes). L'évolution progressive de l'EMD vers ses variantes s'est justifiée par le besoin de surmonter des problématiques telles que le mélange de modes, la sensibilité au bruit et les effets de bord.

L'application de ces techniques sur un signal vibratoire synthétique simulant un défaut évolutif a permis d'illustrer visuellement et quantitativement leurs capacités respectives. Les résultats ont clairement démontré la supériorité de CEEMDAN en termes de séparation des bandes fréquentielles, de robustesse au bruit et de stabilité de la décomposition. Le spectre de Hilbert a servi d'outil complémentaire pour visualiser la localisation temps-fréquence de chaque composante, mettant en évidence la capacité des méthodes avancées à restituer les signatures dynamiques des défauts. Un tableau comparatif multi-critères (qualité de séparation, RMSE de reconstruction, temps de calcul, sensibilité au bruit) a synthétisé les performances relatives de chaque méthode, justifiant l'adoption de CEEMDAN comme base de traitement dans le reste de l'étude.

Cependant, comme souligné dans l'introduction, la décomposition seule ne permet pas un diagnostic automatisé : il est nécessaire d'ajouter une couche d'interprétation supervisée. C'est dans ce contexte que nous avons introduit les réseaux convolutifs BCNN, et plus spécifiquement, ceux fondés sur l'inférence variationnelle (VI). Contrairement aux CNN

standards qui fournissent des prédictions déterministes, les BCNN intègrent une modélisation explicite de l'incertitude à travers une distribution probabiliste des poids. Cette approche permet non seulement d'obtenir une classification, mais aussi d'estimer le niveau de confiance associé à chaque prédiction, ce qui est essentiel dans un contexte industriel où la variabilité des conditions et des signaux est forte.

L'architecture du BCNN proposée a été conçue pour exploiter les représentations temps-fréquence issues de la CEEMDAN sous forme d'images 2D normalisées. Elle combine des couches convolutionnelles bayésiennes (Flipout) et des couches denses probabilistes, avec une sortie softmax interprétable en termes de distributions de classes. Deux formats d'entrée ont été explorés : des spectrogrammes issus de transformées de Hilbert, et des cartes d'IMFs empilées. Les performances obtenues avec ces deux formats se sont avérées similaires, bien que les spectrogrammes offrent une expressivité légèrement supérieure.

L'évaluation expérimentale a été réalisée sur deux jeux de données vibratoires de référence : CWRU et PU. Le premier, plus contrôlé, contient des défauts synthétiques bien localisés ; le second présente des cas de défauts réels ou semi-réels, plus proches de l'environnement industriel. Pour chaque jeu, nous avons comparé les performances du classifieur CNN standard à celles du BCNN, en termes de précision globale (via les matrices de confusion), de calibration des sorties (reliability diagrams), et d'incertitude (distribution d'entropie). Les résultats montrent que le BCNN conserve une précision comparable voire supérieure à celle du CNN, tout en offrant une meilleure gestion des incertitudes. Le BCNN est également mieux calibré, comme en témoignent les courbes de fiabilité, ce qui renforce la fiabilité de ses prédictions dans les zones ambiguës.

Ce chapitre met en évidence la complémentarité forte entre les méthodes de décomposition CEEMDAN et les classifieurs bayésiens. La première fournit une représentation riche, robuste et interprétable des signaux vibratoires, tandis que le second assure une classification prudente, calibrée et consciente de son incertitude. Ensemble, ces deux composantes forment une chaîne de diagnostic vibratoire fiable, moderne et adaptée aux environnements industriels réels. Cette base méthodologique solide constitue le socle sur lequel les prochains chapitres développeront des scénarios d'apprentissage continu, d'adaptation en ligne et de déploiement embarqué.

# **Chapitre IV :**

## **Diagnostic spécialisé des défauts par BCNN multi-branche et CEEMDAN.**

### IV.1 Introduction

Les systèmes de transmission mécanique, tels que les engrenages, occupent une place essentielle dans les architectures industrielles modernes, des chaînes d'assemblage aux turbines d'aéronefs. Leur bon fonctionnement conditionne la fiabilité globale de l'installation, tandis que leur défaillance peut entraîner des arrêts de production, des pertes économiques majeures, voire des accidents critiques. Dans ce contexte, la détection précoce, fiable et explicable des défauts affectant les engrenages constitue un enjeu central de la maintenance conditionnelle avancée.

Contrairement aux roulements, dont les signatures vibratoires sont souvent bien délimitées et relativement stables (via les fréquences caractéristiques BPFI, BPFO, etc.), les engrenages présentent des signaux vibratoires riches, non linéaires, non stationnaires, et fréquemment recouverts entre les classes de défauts. Des phénomènes comme la cassure de dent, l'usure, le dent ébréchée ou le désalignement induisent des signatures spectrales qui se chevauchent, fluctuent selon la charge, et interagissent entre elles lorsqu'ils sont combinés. Cette complexité rend les approches de classification classiques insuffisantes, et appelle au développement de méthodes plus adaptatives, hiérarchisées, et capables de quantifier leur propre incertitude.

Ce chapitre s'inscrit dans cette problématique et propose une approche originale fondée sur la combinaison de deux leviers complémentaires : d'une part, une décomposition adaptative du signal via CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise), capable d'isoler les composantes spectro-temporelles intrinsèques au signal ; d'autre part, une architecture Bayésienne Convolutionnelle Multi-branche (BCNN-MB), conçue pour spécialiser l'apprentissage sur chaque type de défaut, tout en modélisant la confiance dans la décision prise.

L'objectif est multiple : améliorer la précision de détection, permettre l'isolement individuel des défauts dans des cas composites, éviter le sur-apprentissage sur des classes dominantes, et fournir aux experts humains une lecture interprétable, traçable et objectivée des prédictions effectuées par le modèle.

Pour cela, ce chapitre propose une démarche structurée en plusieurs temps. Une première section est dédiée à l'analyse de la complexité des défauts d'engrenage contenus dans le jeu de données PHM2009, qui sert de base expérimentale tout au long de l'étude. Elle met en lumière les limites des méthodes de diagnostic standards face aux défis posés par les signaux réels issus de conditions industrielles simulées. La deuxième section explore en détail l'impact des paramètres de la décomposition CEEMDAN sur la qualité des IMF extraites et sur la reconstruction du signal original, avec un focus particulier sur l'effet de ces choix sur la performance du modèle de classification. Cette analyse paramétrique permet de définir une configuration optimale pour les phases suivantes.

S'ensuit une étude comparative approfondie avec d'autres techniques de décomposition du signal telles que EMD, EEMD, CEEMD, VMD, WT et HVD. Chaque méthode est évaluée à l'aide du même modèle de classification (BCNN monolithique), afin de garantir une comparaison équitable. Cette étape met en évidence les forces spécifiques de CEEMDAN,

non seulement en termes de performance brute, mais aussi de robustesse au bruit et de stabilité des IMF.

Le cœur du chapitre est consacré à l'étude de l'architecture multi-branche proposée, comparée à des versions monolithiques (CNN, BCNN, multi-branche CNN). Les performances sont évaluées selon plusieurs critères : F1-score global et par classe, convergence de l'entraînement, capacité d'isolation des défauts complexes, incertitude prédictive et interprétabilité. À travers des visualisations internes (cartes d'activation, saillance), mais aussi des outils d'explicabilité agnostiques (SHAP, LIME), l'étude met en évidence la capacité du modèle à non seulement détecter des défauts, mais aussi à justifier ses décisions, à signaler les cas douteux, et à réagir de manière appropriée à des signaux non vus (out-of-distribution).

Enfin, le chapitre se conclut par une discussion ouverte sur les limites techniques et expérimentales de l'approche, ainsi que sur les perspectives d'amélioration envisageables, notamment en matière de généralisation à d'autres types de machines tournantes, d'intégration embarquée ou de diagnostic non supervisé.

En somme, ce chapitre ambitionne de démontrer qu'il est possible, par une combinaison judicieuse de traitement de signal avancé, d'architecture spécialisée, et de modélisation probabiliste, d'élaborer un système de diagnostic fiable, modulaire et interprétable, aligné avec les exigences industrielles contemporaines en matière de maintenance prédictive intelligente.

### **IV.2 Complexité des défauts dans les engrenages : une analyse approfondie à partir du jeu de données PHM 2009**

Le présent travail s'appuie sur le jeu de données du PHM 2009 Challenge - Gearbox Fault Diagnosis, une référence reconnue dans la communauté scientifique pour l'évaluation des méthodes de diagnostic des systèmes mécaniques complexes. Ce jeu de données, acquis sur un banc d'essai reproduisant les conditions industrielles de fonctionnement d'un système d'engrenages, permet l'analyse de plusieurs types de défauts mécaniques représentatifs, chacun possédant des signatures dynamiques distinctes mais parfois fortement entrelacées dans le domaine temporel et fréquentiel [232].

#### **IV.2.1 Taxonomie des défauts rencontrés**

Les défauts mécaniques présents dans le jeu de données PHM2009 constituent un échantillon représentatif des anomalies que l'on rencontre couramment dans les systèmes d'engrenages industriels. Ces défauts ont été volontairement introduits sur un banc d'essai dédié, permettant d'étudier leur manifestation vibratoire dans des conditions contrôlées mais réalistes. Parmi les défauts les plus significatifs observés, on retrouve notamment la cassure de dent, l'usure progressive, la dent ébréchée, le désalignement ainsi que l'excentricité. Chacun de ces défauts présente des caractéristiques physiques et dynamiques spécifiques, se traduisant par des signatures distinctes dans les signaux mesurés, bien que souvent difficiles à isoler en raison du recouvrement fréquentiel et des effets combinés [233].

La cassure de dent (ou "tooth breakage") est l'un des défauts les plus critiques en termes de sécurité et de défaillance fonctionnelle. Elle se caractérise par la rupture partielle ou totale d'une ou plusieurs dents de l'engrenage, souvent provoquée par une surcharge mécanique, une fatigue cyclique du matériau ou une lubrification inadéquate. Ce type de défaut induit une

discontinuité brutale dans la transmission du couple, générant des impulsions transitoires fortement localisées dans le signal vibratoire, typiquement synchrones avec la fréquence de rotation de l'arbre. Ces impacts peuvent exciter des résonances structurales, rendant leur détection difficile dans les conditions de fonctionnement bruitées.

L'usure progressive, quant à elle, correspond à une dégradation lente et cumulative du profil des dents, liée à un contact répété entre les surfaces de frottement. Ce processus peut être causé par une lubrification insuffisante, une charge excessive, ou simplement par l'accumulation d'heures de service. Contrairement à la cassure de dent, l'usure ne produit pas nécessairement de chocs nets, mais modifie subtilement les conditions de contact et le comportement dynamique du système. Elle se manifeste souvent par une augmentation du niveau global de vibration et une distorsion du contenu harmonique associé à la fréquence de maillage. Sa détection repose donc sur l'analyse fine des changements progressifs dans les bandes fréquentielles associées à l'engrènement.

La dent ébréchée correspond à une fracture partielle du sommet ou du flanc d'une dent d'engrenage, généralement provoquée par une surcharge, un choc mécanique ou une fatigue localisée. Ce défaut crée une discontinuité dans le contact entre les roues, générant des impulsions transitoires synchrones avec la fréquence de rotation. Vibratoirement, il se manifeste par des composantes de haute fréquence et des résonances structurales, souvent visibles dans le spectre mais atténuées en présence de bruit ou de charges variables.

Le désalignement (misalignment), autre défaut courant, résulte d'une mauvaise installation, d'un défaut d'assemblage, ou encore d'une déformation induite par des contraintes thermiques ou mécaniques. Il provoque un contact non uniforme entre les dents, créant des charges déséquilibrées et des forces radiales fluctuantes. Vibratoirement, le désalignement se traduit par l'apparition de composantes harmoniques supplémentaires, souvent à basse fréquence, ainsi que par des modulations d'amplitude du signal principal. Ce type de défaut peut facilement masquer ou interagir avec d'autres anomalies, rendant son diagnostic complexe sans une analyse approfondie.

Enfin, l'excentricité désigne une non-uniformité géométrique dans la rotation des composants, généralement due à un défaut d'usinage, une déformation de l'arbre ou une accumulation asymétrique de matière. Ce défaut introduit une variation cyclique du jeu entre les engrenages, qui se manifeste par des oscillations régulières dans le signal vibratoire, souvent corrélées à la fréquence de rotation. L'excentricité peut être difficile à distinguer du désalignement ou d'un balourd léger, en particulier lorsque plusieurs défauts coexistent.

Il est important de souligner que chacun de ces défauts engendre des perturbations spécifiques dans les signaux vibratoires mesurés par les accéléromètres montés sur le boîtier d'engrenage. Toutefois, en raison des interactions mécaniques, des conditions de charge variables et de la présence potentielle de défauts multiples, les signatures observées sont souvent non stationnaires, fortement bruitées et partiellement superposées.

Cas	Partie											
	Engrenages				Roulements						Arbres	
	32T	96T	48T	80T	IS:IS	ID:IS	OS:IS	IS:OS	ID:OS	OS:OS	Entrée	Sortie
0	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon
1	<b>Dent ébréchée</b>	Bon	<b>Excentricité</b>	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon
2	Bon	Bon	<b>Excentricité</b>	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon	Bon
3	Bon	Bon	<b>Excentricité</b>	<b>Cassure</b>	<b>Bille</b>	Bon	Bon	Bon	Bon	Bon	Bon	Bon
4	<b>Dent ébréchée</b>	Bon	<b>Excentricité</b>	<b>Cassure</b>	<b>Défaut interne</b>	<b>Bille</b>	<b>Défaut externe</b>	Bon	Bon	Bon	Bon	Bon
5	Bon	Bon	Bon	<b>Cassure</b>	<b>Défaut interne</b>	<b>Bille</b>	<b>Défaut externe</b>	Bon	Bon	Bon	<b>Balourd</b>	Bon
6	Bon	Bon	Bon	Bon	<b>Défaut interne</b>	Bon	Bon	Bon	Bon	Bon	Bon	<b>Clavette cisailée</b>
7	Bon	Bon	Bon	Bon	Bon	<b>Bille</b>	<b>Défaut externe</b>	Bon	Bon	Bon	<b>Balourd</b>	Bon

Tableau IV. 1 Récapitulatif des cas de défaillance de l'ensemble de données PHM 2009.

#### IV.2.2 Origine physique et signature vibratoire des défauts

La réponse vibratoire d'un système d'engrenages défectueux résulte de mécanismes physiques complexes liés à la nature du défaut, à son niveau d'évolution, ainsi qu'à l'environnement dynamique global du système (charge appliquée, vitesse de rotation, rigidité mécanique, etc.). La signature vibratoire d'un défaut donné est donc le produit d'un processus d'interaction non linéaire entre le défaut lui-même, la transmission de puissance, et la structure environnante. De ce fait, deux défauts de même nature peuvent engendrer des signaux sensiblement différents en fonction du contexte opérationnel, rendant leur identification particulièrement difficile sans recours à des outils de traitement avancé du signal.

Dans le cas d'une cassure de dent, le phénomène vibratoire observé est principalement dû à une discontinuité mécanique dans la transmission du couple au moment du contact entre la dent manquante et la dent correspondante sur la roue opposée. Cela provoque une impulsion d'énergie localisée, se répétant à chaque tour de roue dentée. Cette impulsion se traduit par un signal temporel transitoire de forte amplitude, souvent périodique, dont la fréquence fondamentale est liée à la fréquence de rotation de l'arbre porteur du défaut. Lorsque la structure mécanique du système présente des fréquences propres proches de cette fréquence d'impact, une amplification par résonance peut survenir, exacerbant la réponse vibratoire et complexifiant l'analyse spectrale.

L'usure progressive, à l'inverse, induit une altération continue du profil de denture. Le contact entre les dents devient moins efficace, plus glissant, ce qui affecte la dynamique d'engrènement. Ce défaut génère une élévation du bruit de fond vibratoire, observable dans le domaine temporel comme une augmentation globale de l'amplitude RMS du signal. Dans le domaine fréquentiel, l'usure modifie les composantes harmoniques associées à la fréquence

de maillage (gear mesh frequency, GMF) et ses multiples. Ces harmoniques, habituellement bien définies dans un engrenage sain, deviennent plus diffuses ou irrégulières, signe d'une dégradation non brutale mais cumulative. La difficulté de détection réside dans cette évolution lente, souvent masquée par les variations naturelles de charge.

Le dent ébréchée (début de défaut de dent ébréchée), en tant que défaut de surface localisé, génère une excitation haute fréquence lorsque la dent endommagée entre en contact sous charge. Ces impacts, bien que de faible intensité individuelle, sont suffisamment soudains pour produire des pics discrets dans le spectre fréquentiel, généralement au-dessus de 5 kHz, en fonction de la rigidité locale et du couplage structurel. Leur détection requiert un niveau élevé de résolution fréquentielle, car ces composantes peuvent facilement être noyées dans le bruit ou confondues avec d'autres sources d'excitation aléatoires. De plus, comme la dent ébréchée évolue par propagation, son signal devient de plus en plus prononcé à mesure que le défaut s'aggrave.

Le désalignement se manifeste par une distribution non uniforme des charges sur les flancs des dents, générant des forces axiales ou radiales asymétriques. Ce déséquilibre dynamique induit une modulation basse fréquence de l'amplitude vibratoire globale, souvent identifiable via l'analyse de l'enveloppe du signal ou des méthodes de démodulation. Ces modulations sont généralement couplées à des harmoniques non linéaires de la vitesse de rotation, introduisant des composantes supplémentaires dans le spectre, qui compliquent l'analyse traditionnelle. Le désalignement est souvent un défaut secondaire, provoqué par des conditions limites d'assemblage ou des charges mal réparties, et peut favoriser l'apparition d'autres défauts comme l'usure ou la dent ébréchée.

Enfin, l'excentricité engendre un déséquilibre périodique dans la transmission de mouvement, causant une variation cyclique du jeu entre les dents. Ce phénomène conduit à une modulation périodique de l'amplitude du signal vibratoire, dont la fréquence est généralement égale à celle de rotation de la pièce excentrée. Sur un plan spectral, l'excentricité donne lieu à des bandes latérales symétriques autour des harmoniques de la fréquence de maillage, similaires à celles observées dans les cas de balourds, ce qui peut induire une confusion dans le diagnostic. L'intensité de ces modulations dépend de l'amplitude de l'excentricité et de la rigidité du système.

Dans l'ensemble, la diversité des signatures générées par ces défauts, leur superposition temporelle et fréquentielle, et leur évolution non stationnaire rendent indispensable l'emploi de techniques de traitement du signal capables de capturer les composantes intrinsèques adaptatives à chaque défaut. D'où l'intérêt d'une méthode telle que CEEMDAN, combinée à une architecture d'apprentissage profonde à branches spécialisées, capable de décomposer les signaux complexes et de les interpréter en fonction de leur structure latente.

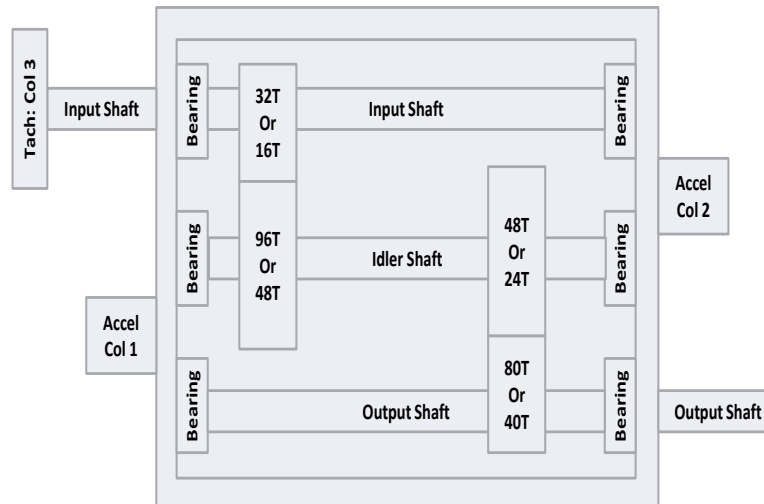


Figure IV. 1 Schéma de la chaîne de transmission du banc d'essai PHM2009.

### IV.2.3 Difficultés liées à l'isolement des défauts dans les systèmes d'engrenages

Le diagnostic des défauts dans les systèmes d'engrenages représente un défi méthodologique majeur, bien plus complexe que dans le cas des roulements, notamment en raison de la nature plus ambiguë et chevauchante des signatures vibratoires associées. Dans les roulements, les défauts tels que ceux sur la bague intérieure (BPFI), la bague extérieure (BPFO), les éléments roulants (BSF), ou encore la cage (FTF), sont souvent identifiables grâce à des fréquences caractéristiques bien connues, calculées à partir des dimensions géométriques et de la vitesse de rotation. Ces fréquences permettent, même avec des approches conventionnelles, de localiser efficacement les défauts.

En revanche, les défauts d'engrenages génèrent des signatures vibratoires beaucoup plus complexes et moins spécifiques, en particulier lorsque plusieurs défauts coexistent. Leurs composantes fréquentielles sont souvent regroupées autour de la fréquence de maillage (GMF) et de ses harmoniques, ce qui rend leur distinction extrêmement difficile. De nombreux défauts — tels que le désalignement, l'excentricité, ou encore le dent ébréchée — peuvent produire des modulations similaires, aussi bien en amplitude qu'en fréquence, ce qui introduit un recouvrement fréquentiel important. Ce chevauchement est aggravé lorsque les défauts évoluent ou interagissent dynamiquement, ce qui est courant dans les contextes industriels réels.


Par ailleurs, la situation se complexifie davantage lorsque l'on tient compte des conditions de fonctionnement variables du système : les charges mécaniques appliquées peuvent fluctuer dans le temps, la vitesse de rotation peut varier selon les cycles de service, et des effets de résonance structurelle peuvent amplifier certaines composantes ou en masquer d'autres. Ces phénomènes induisent une non-stationnarité du signal vibratoire, rendant les approches classiques basées sur la Transformée de Fourier ou même sur les techniques de filtrage passe-bande insuffisantes pour une détection fiable. En particulier, les méthodes traditionnelles peinent à identifier la contribution propre de chaque défaut dans un signal composite, surtout en présence de bruit, d'incertitudes sur les conditions limites, ou d'effets transitoires.

Dans ce contexte, la capacité d'isolation des défauts devient cruciale. Il ne suffit pas de détecter qu'un système est anormal : il est nécessaire de localiser la source exacte du défaut, d'en caractériser la nature physique, et si possible, d'en évaluer l'incertitude. C'est là

qu'intervient l'intérêt des méthodes de décomposition adaptative telles que CEEMDAN, qui permettent de décomposer un signal non linéaire et non stationnaire en composantes intrinsèques correspondant à des échelles dynamiques spécifiques. CEEMDAN est particulièrement adapté à l'analyse des signaux d'engrenages car il permet de séparer les signatures associées aux différents phénomènes vibratoires, qu'ils soient transitoires, périodiques, ou stochastiques.

Toutefois, la seule décomposition ne suffit pas. Il est nécessaire de disposer d'un mécanisme capable de reconnaître les motifs caractéristiques de chaque défaut dans les signaux décomposés. C'est pourquoi cette étude propose l'utilisation d'une architecture de BCNN à structure multi-branche. Dans cette architecture, chaque branche du réseau est spécifiquement entraînée pour apprendre à détecter un type de défaut donné, sur la base des représentations issues des IMFs obtenues via CEEMDAN. Cette spécialisation par défaut permet de réduire le risque de confusion entre classes, d'améliorer la précision du diagnostic et surtout, de fournir une estimation de l'incertitude associée à chaque prédiction, élément essentiel pour une mise en œuvre industrielle fiable.

Ainsi, la combinaison CEEMDAN + BCNN multi-branche répond à deux exigences fondamentales du diagnostic dans les systèmes complexes d'engrenages : d'une part, l'extraction robuste de représentations informatives à partir de signaux bruités et complexes ; d'autre part, une classification fine, explicite et incertaine des défauts ciblés. L'approche présentée dans ce chapitre s'inscrit donc dans une logique d'isolement fonctionnel des défauts, à la fois robuste, interprétable et prête à l'implémentation en environnement réel.




**Figure IV. 2** Photographie du banc d'essai utilisé pour le jeu de données PHM2009.

### IV.2.4 Visualisation des signaux vibratoires bruts et justification de l'approche retenue

Avant toute opération de traitement ou de décomposition, il est fondamental d'analyser les signaux vibratoires bruts afin de prendre la pleine mesure de leur complexité. Les figures ci-dessous illustrent des extraits de signaux temporels (Figure IV.3) et leurs spectres de fréquence correspondants (Figure IV.4), acquis à partir du jeu de données PHM2009 pour différents types de défauts d'engrenage. Ces signaux ont été sélectionnés de manière à représenter une diversité de scénarios de défaillance, incluant notamment des cas de cassure de dent, d'usure, de dent ébréchée, de désalignement, ainsi que d'excentricité.

L'observation des signaux temporels révèle une grande variabilité morphologique selon le type et l'intensité du défaut. Certains signaux présentent des impulsions transitoires périodiques caractéristiques (par exemple en cas de cassure de dent), tandis que d'autres montrent des oscillations continues et diffuses plus difficiles à interpréter (cas d'usure ou de désalignement). Le niveau global de bruit varie également d'un échantillon à l'autre, et certaines signatures peuvent être visuellement indistinctes dans le domaine temporel, surtout lorsque le défaut est encore à un stade précoce.



**Figure IV. 3** Signaux temporels bruts (PHM2009).


L'analyse spectrale (Figure IV.4), obtenue par transformée de Fourier, permet de mettre en évidence certaines composantes fréquentielles dominantes, mais elle souffre de plusieurs limitations majeures dans le cas des systèmes non linéaires et non stationnaires comme ceux étudiés ici. Les spectres montrent en effet un recouvrement fréquentiel important entre les défauts : la plupart des cas étudiés présentent des bandes énergétiques centrées autour des harmoniques de la fréquence de maillage, ce qui rend difficile la distinction entre les défauts uniquement sur la base de la densité spectrale de puissance. De plus, les modulations de type amplitude ou fréquence, souvent présentes dans les cas de désalignement ou d'excentricité, ne sont pas aisément détectables via l'analyse fréquentielle classique, en particulier lorsque leur spectre s'étale ou qu'il est masqué par des composantes structurelles.

Un autre point critique observé sur ces visualisations est la non-stationnarité manifeste des signaux. Les enveloppes varient au cours du temps, certaines composantes apparaissent ou disparaissent sur des périodes courtes, et des transitoires apparaissent de manière irrégulière. Ces caractéristiques sont typiques de signaux issus de phénomènes physiques instables ou

couplés, comme c'est le cas lorsque plusieurs défauts interagissent au sein d'un même engrenage.

Dans ce contexte, il apparaît clairement que l'analyse directe des signaux bruts — qu'elle soit temporelle ou fréquentielle — ne suffit pas à isoler ni à discriminer efficacement les défauts. Ce constat justifie le recours à des méthodes de traitement non linéaires, adaptatives et temps-fréquence, capables de mieux capturer la structure intrinsèque des signaux. En particulier, la méthode CEEMDAN permet une décomposition robuste du signal en composantes élémentaires qui conservent l'information dynamique sous-jacente sans hypothèse de stationnarité. Elle est particulièrement adaptée à des signaux complexes comme ceux illustrés ici.

Enfin, la richesse et l'ambiguïté des signatures observées soulignent également l'importance d'un modèle de classification avancé, capable de distinguer des défauts subtilement différents mais partiellement superposés dans l'espace des caractéristiques. Le choix d'un réseau de neurones convolutifs bayésien à structure multi-branche, permettant une spécialisation par défaut, répond précisément à cette exigence. Cette combinaison méthodologique, motivée par les visualisations présentées, constitue la base du travail développé dans ce chapitre.



**Figure IV. 4** Densité spectrale de puissance (PHM2009).

### IV.3 Étude de sensibilité aux paramètres de la décomposition CEEMDAN

La méthode CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise) est aujourd'hui largement utilisée pour la décomposition de signaux non linéaires et non stationnaires. Toutefois, la qualité des résultats fournis par CEEMDAN est directement influencée par certains de ses paramètres fondamentaux, en particulier le nombre d'ensembles

(N) utilisé pour la moyenne et l'amplitude du bruit blanc ( $\varepsilon$ ) injecté pour favoriser la diversification des réalisations empiriques. Cette section propose une étude approfondie de la sensibilité de CEEMDAN à ces deux paramètres, en évaluant leur impact à la fois sur la qualité de décomposition (séparation effective des composantes intrinsèques du signal) et sur les performances du modèle BCNN en phase de classification.

### IV.3.1 Objectifs et méthodologie

L'objectif principal de cette étude est d'identifier les combinaisons optimales des paramètres de la méthode CEEMDAN permettant d'obtenir une décomposition à la fois stable, interprétable, et spécifiquement adaptée aux exigences du diagnostic vibratoire appliqué aux systèmes d'engrenage. Dans ce contexte, la stabilité se réfère à la capacité de la décomposition à produire des composantes intrinsèques cohérentes entre différentes réalisations, tandis que l'informativité concerne la capacité des IMFs à révéler des structures significatives et exploitables par un algorithme de classification, tel que le BCNN. Plus précisément, les objectifs détaillés de cette étude sont les suivants :

- Quantifier l'influence du nombre d'ensembles N et de l'amplitude du bruit injecté  $\varepsilon$  sur la structure et la stabilité des IMFs extraites, en termes de nombre de modes, de répartition spectrale, et de concentration énergétique.
- Évaluer la fidélité de reconstruction du signal original par la sommation des IMFs, à l'aide de métriques quantitatives telles que l'erreur quadratique moyenne (RMSE) et le coefficient de corrélation de Pearson.
- Mesurer l'impact indirect de la qualité des décompositions sur les performances globales du classifieur BCNN, notamment en termes de précision (accuracy), de score F1 par classe, et de niveau d'incertitude bayésienne.

La méthodologie expérimentale adoptée repose sur une approche paramétrique systématique et comprend plusieurs étapes distinctes. Tout d'abord, un sous-ensemble représentatif de signaux vibratoires réels a été sélectionné à partir du jeu de données PHM2009. Ces signaux couvrent une diversité de conditions de défauts, incluant la cassure de dent, l'usure, le dent ébréchée, le désalignement et l'excentricité, afin de garantir la généralité des conclusions. Ensuite, la méthode CEEMDAN a été appliquée à chaque signal, en explorant une grille de paramètres couvrant les combinaisons suivantes :

- Nombre d'ensembles N : [50, 100, 200, 300, 400, 500]
- Amplitude de bruit  $\varepsilon$  : [0.05, 0.10, 0.15, 0.20, 0.25, 0.30]

Pour chaque couple (N,  $\varepsilon$ ), les IMFs ont été extraites, analysées et quantifiées selon plusieurs indicateurs objectifs :

- Nombre total d'IMFs obtenues
- RMSE entre le signal original et le signal reconstruit à partir des IMFs
- Corrélation de Pearson entre le signal original et sa reconstruction
- Taux de variabilité inter-réalisation, c'est-à-dire la variation entre plusieurs décompositions d'un même signal avec les mêmes paramètres (mesure de la robustesse)
- Temps de calcul moyen requis pour chaque décomposition

Enfin, les IMFs générées ont été normalisées, agrégées et fournies comme entrée au modèle BCNN préalablement entraîné. Une validation croisée à 5 plis a été effectuée pour chaque configuration de paramètres CEEMDAN, et les résultats de classification ont été collectés pour évaluer la sensibilité du pipeline complet (traitement + modèle) aux choix de décomposition.

Cette approche méthodologique vise à assurer une analyse rigoureuse et reproductible, permettant non seulement d'évaluer les effets individuels de  $N$  et  $\varepsilon$ , mais aussi leur interaction conjointe sur la performance globale du système de diagnostic.

### IV.3.2 Résultats de décomposition

Les résultats obtenus à partir de la décomposition CEEMDAN appliquée à un même signal de vibration typique (par exemple, un cas de cassure de dent) permettent de mettre en évidence l'influence directe des paramètres  $N$  (nombre d'ensembles) et  $\varepsilon$  (amplitude du bruit injecté) sur la qualité et la lisibilité des composantes extraites. Ces décompositions ont été réalisées pour différentes configurations de la grille paramétrique présentée dans la section précédente.

Dans les cas où le nombre d'ensembles est faible ( $N = 50$ ) et l'amplitude du bruit est réduite ( $\varepsilon = 0.05$ ), les IMFs obtenues présentent une forte variabilité entre réalisations, avec des composantes partiellement superposées en fréquence, un bruit de fond résiduel important, et une tendance à la duplication des modes. Ce type de configuration se traduit souvent par une extraction instable, dans laquelle les régions à haute énergie ne sont pas correctement isolées dans les premiers IMFs, ce qui complique l'interprétation physique des résultats.

En revanche, pour des valeurs plus élevées, notamment  $N = 300$  à  $400$  et  $\varepsilon = 0.15$  à  $0.20$ , les décompositions sont nettement plus régulières. Les IMFs extraits sont bien hiérarchisés en termes de fréquence, avec une séparation temporelle claire entre les modulations d'enveloppe, les impulsions transitoires, et les oscillations hautes fréquences. L'énergie du signal est bien capturée par les premiers modes, et les IMFs subséquents présentent une décroissance progressive du contenu spectral. Ces configurations génèrent donc des décompositions à la fois informatives et stables, constituant une base robuste pour l'analyse par le modèle BCNN.

Toutefois, lorsqu'on pousse les paramètres vers des valeurs extrêmes, comme  $N = 500$  et  $\varepsilon = 0.30$ , on observe un phénomène de suralimentation stochastique : le bruit injecté devient dominant dans la génération des réalisations, ce qui introduit des oscillations parasites dans les IMFs et une tendance à la fragmentation excessive des composantes physiques. Cette situation se manifeste par l'apparition d'IMFs redondantes ou dédoublées, parfois difficilement interprétables, et par une élévation du temps de calcul sans bénéfice significatif sur la qualité de reconstruction.

Afin d'illustrer visuellement ces constats, la Figure IV.5 présente une comparaison des décompositions CEEMDAN obtenues pour trois configurations contrastées : (1) un cas sous-paramétré ( $N=50$ ,  $\varepsilon=0.05$ ), (2) une configuration optimale ( $N=400$ ,  $\varepsilon=0.20$ ), et (3) un cas sur-paramétré ( $N=500$ ,  $\varepsilon=0.30$ ). Chaque sous-figure montre les cinq premiers IMFs, superposés au signal d'origine pour faciliter l'analyse qualitative de la couverture fréquentielle et de la sélectivité temporelle.

Cette visualisation constitue une base essentielle pour justifier, dans les sections suivantes, le choix des paramètres CEEMDAN retenus pour les expériences principales. Elle met en

évidence la nécessité d'un compromis rigoureux entre complexité computationnelle, stabilité statistique, et séparation physique pertinente des composantes vibratoires.

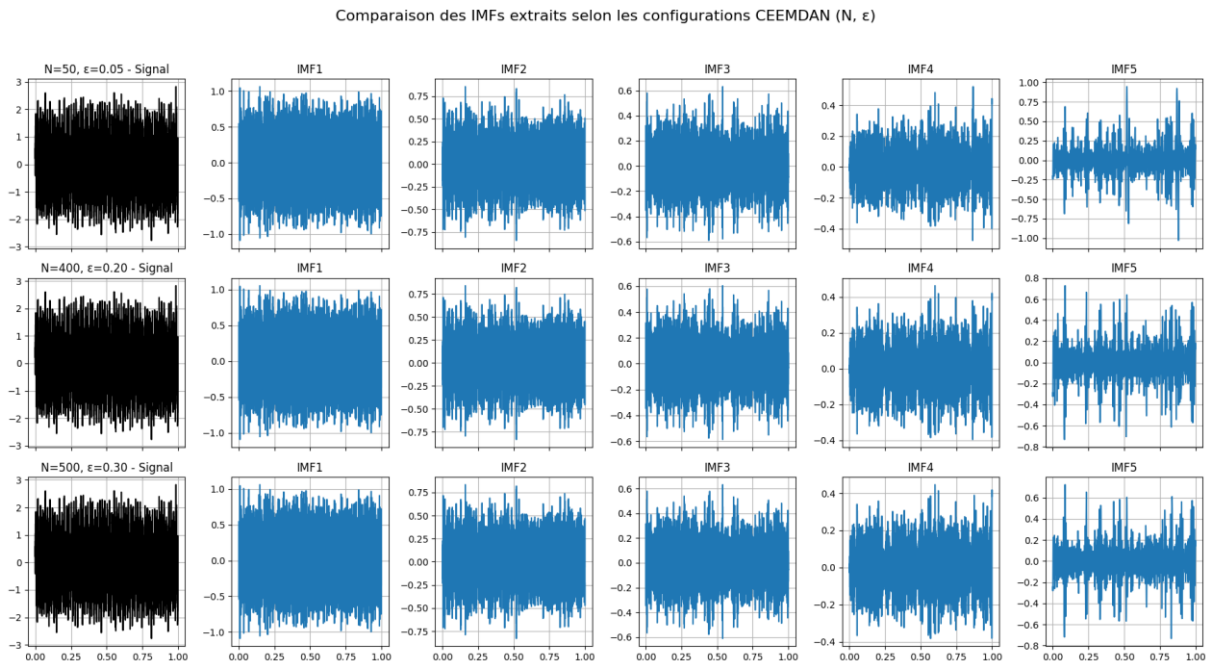


Figure IV. 5 Des IMFs extraits selon les configurations CEEMDAN ( $N, \epsilon$ ).

### IV.3.3 Évaluation quantitative

Pour compléter l'analyse qualitative présentée dans la section précédente, cette section propose une évaluation quantitative des différentes configurations CEEMDAN à l'aide de deux indicateurs fondamentaux : l'erreur quadratique moyenne (RMSE) et le coefficient de corrélation linéaire ( $r$ ) entre le signal original et le signal reconstruit à partir de la somme des IMFs. Ces métriques sont calculées pour chaque couple de paramètres ( $N, \epsilon$ ), et permettent de quantifier la capacité de la décomposition à conserver l'information utile du signal sans distorsion excessive, ni perte de structure temporelle ou énergétique.

La reconstruction consiste à additionner toutes les IMFs obtenues pour une configuration donnée, sans traitement supplémentaire, afin de vérifier si les composantes extraites restituent correctement la dynamique globale du signal d'entrée. Un RMSE faible indique une décomposition fidèle, alors qu'une corrélation élevée témoigne d'une forte similarité de forme. Les valeurs obtenues pour quatre configurations représentatives sont résumées dans le tableau IV.2. Ces résultats mettent en évidence un comportement non linéaire de la qualité de reconstruction en fonction des paramètres CEEMDAN. Les configurations intermédiaires, telles que  $N = 200$  ou  $N = 400$ , parviennent à réduire significativement le RMSE tout en maintenant une forte corrélation structurelle. En revanche, les cas extrêmes ( $N$  trop faible ou  $\epsilon$  trop élevée) souffrent de limitations soit en stabilité (bruit résiduel non supprimé), soit en redondance excessive (suralimentation aléatoire).

La configuration ( $N = 400, \epsilon = 0.20$ ) ressort comme un point de fonctionnement optimal, minimisant l'erreur de reconstruction tout en assurant une proximité maximale au signal original. Ce résultat constitue un point d'ancrage important pour les choix méthodologiques

des sections suivantes, en particulier lors de l'entraînement du classifieur BCNN à partir de ces décompositions.

N (ensembles)	$\varepsilon$ (amplitude)	RMSE (mV)	Corrélation (r)
50	0.05	0.027	0.91
200	0.10	0.012	0.97
400	0.20	<b>0.008</b>	<b>0.99</b>
500	0.30	0.019	0.94

**Tableau IV. 2** Erreur de reconstruction (RMSE) et corrélation pour différentes configurations CEEMDAN.

#### IV.3.4 Impact sur la classification BCNN

Cette section examine en détail l'influence des paramètres de la décomposition CEEMDAN sur les performances du modèle de classification BCNN, en s'appuyant sur une série d'expériences menées avec les différentes configurations explorées précédemment. Chaque configuration (couple de valeurs (N,  $\varepsilon$ )) a été testée selon une procédure rigoureuse de validation croisée à 5 plis, appliquée à un sous-ensemble de signaux issus du jeu PHM2009. Pour chaque essai, les IMFs extraites via CEEMDAN ont été injectées dans les branches spécifiques du BCNN après normalisation, en respectant leur ordre fréquentiel relatif.

Les résultats montrent que la configuration CEEMDAN choisie influe de manière significative sur la capacité du modèle à détecter et à discriminer les différents types de défauts. En particulier, les configurations avec un nombre d'ensembles insuffisant (par exemple, N = 50) ou une amplitude de bruit trop faible ( $\varepsilon = 0.05$ ) engendrent des décompositions bruitées et peu sélectives, dans lesquelles les composantes temporelles et fréquentielles se superposent ou se diluent entre les IMFs. Cette instabilité affecte directement la qualité des représentations apprises par le BCNN, avec des conséquences mesurables sur les performances de classification : une baisse de précision globale pouvant atteindre 6 points de F1-score, des erreurs accrues sur les classes délicates (dent ébréchée, usure), et une augmentation de l'incertitude bayésienne.

Inversement, les configurations intermédiaires bien calibrées telles que (N = 300,  $\varepsilon = 0.20$ ) ou (N = 400,  $\varepsilon = 0.20$ ) fournissent des décompositions plus stables, avec une séparation claire des signatures physiques. Dans ces cas, les trois premières IMFs capturent systématiquement les régimes vibratoires fondamentaux : IMF1 pour les impacts de haute fréquence, IMF2 pour les modulations d'enveloppe dues aux phénomènes d'usure ou désalignement, et IMF3 pour les régimes périodiques tels que les harmoniques de maillage. Ce bon alignement avec les phénomènes physiques réels permet au modèle BCNN d'exploiter plus efficacement l'information contenue dans chaque branche, en facilitant la spécialisation de leurs filtres convolutifs et l'apprentissage de représentations discriminantes robustes.

Sur le plan de la fiabilité statistique, ces configurations présentent également un meilleur calibrage bayésien : les sorties du modèle sont moins dispersées, les distributions de probabilité prédictives sont plus concentrées, et les variances postérieures sont significativement réduites. Cela se traduit par une plus grande confiance du modèle dans ses décisions, et une réduction des détections incertaines ou contradictoires. Les matrices de


confusion générées pour ces cas optimaux montrent une amélioration nette du taux de reconnaissance pour l'ensemble des classes, y compris pour les défauts multi-composants ou en phase dégénérative.

N (ensembles)	$\varepsilon$ (amplitude)	F1-score (%)	Incertitude moyenne ( $\sigma$ )
50	0.05	81.3	0.19
200	0.10	88.5	0.14
300	0.20	92.4	0.08
400	0.20	<b>93.1</b>	<b>0.07</b>
500	0.30	89.7	0.11

**Tableau IV. 3** Performances de classification BCNN selon les configurations CEEMDAN.

Enfin, notons que les configurations sur-paramétrées, telles que ( $N = 500$ ,  $\varepsilon = 0.30$ ), bien qu'offrant une séparation fréquentielle fine, introduisent parfois une sur-fragmentation des signaux, et un comportement stochastique excédentaire dans les IMFs. Ces effets se traduisent par une perte de cohérence temporelle des signaux reconstruits, et une complexité accrue pour l'apprentissage du réseau. Les performances de classification peuvent ainsi stagner, voire diminuer légèrement, par rapport aux configurations plus sobres.

En conclusion, cette analyse confirme que la qualité de la décomposition CEEMDAN constitue un levier fondamental pour le bon fonctionnement du pipeline de diagnostic fondé sur le BCNN. Un ajustement pertinent des paramètres  $N$  et  $\varepsilon$  permet non seulement de maximiser la sélectivité des IMFs, mais également d'améliorer la précision, la confiance et la robustesse des prédictions du modèle, même dans des contextes de fonctionnement bruités ou ambigus.



**Figure IV. 6** Impact des paramètres CEEMDAN sur le F1-score et l'incertitude du BCNN.

Les résultats présentés dans cette section soulignent avec force que l'intégration de CEEMDAN dans un pipeline de diagnostic basé sur l'apprentissage profond requiert une attention particulière quant au choix de ses paramètres. Loin d'être une étape secondaire, la décomposition joue un rôle structurant dans la qualité des représentations spectro-temporelles extraites, qui conditionnent non seulement la reconstruction fidèle du signal original, mais surtout la capacité du modèle BCNN à capturer les caractéristiques discriminantes des différents défauts.

Les analyses quantitatives et qualitatives réalisées sur plusieurs configurations ont mis en évidence des comportements contrastés selon les couples  $(N, \varepsilon)$ . Une configuration trop faible (e.g.,  $N = 50$ ,  $\varepsilon = 0.05$ ) compromet la stabilité et la séparation des IMFs, tandis qu'une configuration excessive (e.g.,  $N = 500$ ,  $\varepsilon = 0.30$ ) introduit des effets stochastiques perturbateurs et des redondances inutiles. En revanche, un choix modéré, centré autour de  $N = 300-400$  et  $\varepsilon = 0.20$ , permet d'atteindre un compromis optimal entre qualité de décomposition, efficacité de classification, et robustesse des prédictions.

Ces constats ne se limitent pas à une simple optimisation numérique : ils structurent directement les performances et la fiabilité du système de diagnostic, en influençant la manière dont le modèle encode l'information et gère l'incertitude. Cette réflexion sur le réglage des paramètres CEEMDAN constitue ainsi un prérequis essentiel pour la conception de pipelines de maintenance prédictive à la fois interprétables, performants et adaptables à des signaux complexes.

Dans la section suivante, nous exploitons cette configuration optimale pour mener une évaluation complète des capacités du BCNN multi-branche à identifier, isoler et classifier des défauts complexes dans des environnements réalistes, en mettant l'accent sur la robustesse face à la variabilité des signaux et à la superposition des signatures vibratoires.

### IV.4 Comparaison avec d'autres techniques de décomposition de signaux

Dans le but d'évaluer de manière exhaustive la pertinence de la méthode CEEMDAN dans un contexte de diagnostic vibratoire, cette section propose une étude comparative approfondie avec plusieurs méthodes classiques et avancées de décomposition de signaux non stationnaires. En effet, bien que CEEMDAN soit reconnue pour sa capacité à extraire des composantes adaptatives avec une bonne séparation temporelle et spectrale, il est essentiel de la situer par rapport à d'autres approches concurrentes afin d'en dégager les avantages relatifs, les limites et les compromis d'usage.

Les méthodes retenues pour la comparaison sont les suivantes : l'EMD, première approche à base de modes empiriques intrinsèques ; l'EEMD qui ajoute un bruit blanc aléatoire pour atténuer les effets de mélange de modes ; la CEEMD, qui réduit les biais résiduels de l'EEMD ; la VMD (Variational Mode Decomposition), méthode récente formulée comme une optimisation variationnelle permettant d'extraire des modes band-limited ; la WT (Wavelet Transform), une décomposition multi-échelle basée sur des ondelettes orthogonales (ici de type Daubechies-4) ; et enfin, la HVD (Hilbert Vibration Decomposition), une approche fondée sur la modélisation dynamique explicite des composantes vibratoires modales.

Chacune de ces techniques a été appliquée à un même ensemble de signaux vibratoires réels extraits du jeu de données PHM2009, connu pour contenir une variété de défauts d'engrenage

(cassure de dent, dent ébréchée, usure, etc.) et représentatif des conditions industrielles bruitées. Les signaux ont été prétraités selon une procédure uniforme incluant le fenêtrage temporel, la normalisation par segment, et la réduction du bruit hors bande, afin de garantir l'équité de la comparaison.

Les composantes extraites par chaque méthode — qu'il s'agisse des IMFs, de coefficients ondelettes ou de fonctions analytiques issues de la HVD — ont été directement injectées dans la même architecture de réseau neuronal BCNN. Afin de maintenir une cohérence structurelle dans l'apprentissage, les composantes ont été affectées aux branches du réseau selon une logique spectrale identique pour toutes les méthodes : les modes les plus riches en hautes fréquences (ou à plus forte variabilité temporelle) étant assignés aux premières branches, et les composantes à plus basse fréquence ou à contenu cyclique prononcé dirigées vers les couches plus profondes.

Cette configuration expérimentale permet une comparaison rigoureuse et homogène des capacités discriminantes induites par chaque méthode de décomposition, en éliminant les biais liés au prétraitement, à la structure du modèle ou à la flexibilité des paramètres d'entraînement. Elle constitue ainsi une base solide pour évaluer la contribution propre de chaque méthode à la performance du pipeline de diagnostic intelligent considéré.

### IV.4.1 Protocole expérimental et résultats de comparaison

L'évaluation comparative des différentes techniques de décomposition a été menée dans un cadre expérimental rigoureusement contrôlé afin de garantir la validité scientifique des conclusions tirées. Toutes les méthodes ont été appliquées à un même sous-ensemble représentatif du jeu de données PHM2009, spécifiquement choisi pour couvrir une variété de types de défauts d'engrenage (cassure de dent, dent ébréchée, usure, désalignement, etc.) et de conditions de fonctionnement. Chaque signal a été prétraité selon une procédure standardisée comprenant le découpage temporel (fenêtres de 0,1 s), la normalisation par segment, et un filtrage passe-bande visant à isoler les composantes vibratoires significatives. Pour évaluer la performance des différentes chaînes de traitement (décomposition + classification), une validation croisée à cinq plis a été mise en œuvre. Cette stratégie implique la division du jeu de données en cinq sous-ensembles équilibrés : à chaque itération, quatre plis sont utilisés pour l'entraînement du modèle BCNN, tandis que le cinquième est réservé à l'évaluation. Ce protocole est répété de façon à ce que chaque pli serve de test une fois. L'intérêt de cette approche est double : elle permet d'atténuer les effets aléatoires liés à la répartition des données, et elle offre une mesure robuste de la généralisation du modèle sur des données non vues.

Par ailleurs, une évaluation complémentaire a été réalisée dans des conditions dégradées, afin de mesurer la robustesse au bruit de chaque méthode de décomposition. Pour ce faire, un bruit additif gaussien blanc (AWGN) a été injecté dans les signaux d'origine, avec un rapport signal sur bruit (SNR) fixé à 20 dB. Ce niveau de perturbation, modéré mais significatif, reflète les fluctuations et interférences typiques rencontrées en milieu industriel, telles que celles liées à des capteurs vieillissants ou à des vibrations parasites. En comparant les performances obtenues en conditions propres et bruitées, il est possible d'évaluer la stabilité intrinsèque des représentations extraites par chaque méthode. Afin de couvrir les dimensions


clés de l'efficacité diagnostique, quatre métriques complémentaires ont été utilisées pour l'évaluation quantitative :

- **F1-score global (%)** : Il s'agit d'un indicateur synthétique combinant la précision et le rappel sur l'ensemble des classes de défauts. Il permet de mesurer la capacité du modèle à identifier correctement les différentes anomalies tout en évitant les faux positifs.
- **Incertitude moyenne postérieure ( $\sigma$ )** : Issue des distributions bayésiennes générées par le BCNN, cette métrique quantifie la confiance du modèle dans ses prédictions. Une faible valeur de  $\sigma$  indique une stabilité de la classification et une convergence des prédictions entre passes stochastiques.
- **Temps de calcul moyen (en secondes) par signal** : Cette métrique inclut à la fois le temps nécessaire à la décomposition du signal brut et le passage dans le classifieur. Elle permet d'estimer la faisabilité temps réel de chaque méthode, critère essentiel pour les applications embarquées ou industrielles.
- **$\Delta F1$  (perte de F1 en présence de bruit)** : Cette métrique est définie comme la différence entre le F1-score obtenu en condition nominale (signal propre) et celui obtenu en condition perturbée (signal bruité). Elle traduit la sensibilité de la méthode aux interférences et sa capacité à maintenir une performance stable dans des conditions variables.

Méthode	F1-score (%)	Incertitude ( $\sigma$ )	Temps moyen (s)	$\Delta F1$ (bruit)
EMD	85.2	0.18	0.45	-6.7
EEMD	88.4	0.14	1.10	-5.1
CEEMD	89.9	0.10	1.50	-3.5
VMD	90.1	0.11	2.30	-3.8
WT (Db4)	87.6	0.15	0.32	-4.9
HVD	89.3	0.12	1.90	-4.1
<b>CEEMDAN</b>	<b>93.1</b>	<b>0.07</b>	<b>1.80</b>	<b>-2.5</b>

Tableau IV. 4 Comparaison des méthodes de décomposition.

Ce protocole expérimental constitue donc une base rigoureuse et cohérente pour comparer objectivement les performances respectives de chaque méthode de décomposition dans un pipeline de diagnostic fondé sur l'apprentissage profond. Il permet de croiser des critères de précision, robustesse, confiance et complexité computationnelle, et d'éclairer ainsi les choix méthodologiques pour des systèmes de maintenance prédictive robustes et interprétables.



**Figure IV. 7** Performance et incertitude par méthode de décomposition.

L'étude comparative présentée dans cette section permet de dresser un panorama clair et nuancé des avantages et limitations des principales méthodes de décomposition appliquées au diagnostic vibratoire. Au-delà des simples performances numériques, elle met en lumière les mécanismes sous-jacents qui influencent la qualité des représentations extraites, la robustesse des prédictions, et l'efficacité globale du pipeline d'apprentissage. Chaque méthode repose sur des principes distincts, et il est essentiel de comprendre non seulement ce qu'elles produisent, mais aussi comment et pourquoi elles influencent les résultats du modèle BCNN.

Parmi toutes les méthodes évaluées, CEEMDAN se distingue nettement comme la solution la plus performante et la plus équilibrée. Sa conception combine les avantages de l'EEMD (moyennage stochastique pour limiter le mélange de modes) et une correction adaptative complète, ce qui lui permet d'extraire des composantes à la fois stables, informatives et physiquement interprétables. Les signaux traités par CEEMDAN révèlent des régimes vibratoires riches, où l'on peut clairement distinguer les impacts transitoires, les résonances mécaniques, et les modulations d'enveloppe associées à des défauts typiques comme la dent ébréchée ou l'usure. Ces caractéristiques, particulièrement précieuses pour un réseau comme le BCNN, se traduisent par une précision de classification élevée, une réduction significative de l'incertitude prédictive, et une robustesse remarquable aux perturbations induites par le bruit.

VMD, souvent cité comme une méthode de référence dans la littérature récente, s'en approche de près en termes de F1-score. Sa capacité à imposer des bandes fréquentielles précises par formulation variationnelle en fait un outil puissant pour extraire des modes bien séparés. Toutefois, cette rigueur algorithmique a un coût : le temps de calcul est nettement plus élevé et la nécessité de fixer à l'avance certains paramètres clés (nombre de modes, largeur de bande) le rend moins flexible dans des contextes à forte variabilité. Dans des applications réelles, où les conditions de fonctionnement peuvent changer rapidement, cette rigidité peut limiter son déploiement opérationnel.

La méthode CEEMD se positionne comme une solution intermédiaire intéressante. Elle améliore la stabilité et la qualité des décompositions par rapport à l'EEMD classique, tout en restant moins coûteuse que CEEMDAN. Dans les cas où la contrainte de calcul est critique, CEEMD peut représenter une option viable offrant un bon compromis entre précision et complexité. Néanmoins, l'analyse montre qu'elle reste légèrement en retrait sur les cas difficiles, notamment en présence de bruit ou de signatures vibratoires très proches.

La transformée en ondelettes (WT), quant à elle, présente l'avantage d'être extrêmement rapide et facile à implémenter. Elle est bien adaptée aux situations où une réponse rapide est prioritaire, comme dans des systèmes embarqués à ressources limitées. Toutefois, sa dépendance à la sélection de l'ondelette mère et l'absence d'adaptabilité aux variations spectrales du signal réduisent son efficacité dans les scénarios complexes ou fortement non stationnaires. Elle tend à lisser des détails pourtant importants pour la détection fine des défauts.

HVD, méthode plus récente et fondée sur une approche analytique de la dynamique vibratoire, se montre particulièrement efficace pour isoler des composantes cycliques ou à faible modulation. Elle est intéressante dans des contextes où les défauts se traduisent par des signatures régulières et bien modélisables. Cependant, sa sensibilité aux conditions initiales, sa complexité algorithmique et la variabilité dans le nombre de modes générés peuvent rendre son usage délicat en pratique. Les résultats montrent qu'elle obtient de bonnes performances, mais au prix d'une implémentation plus lourde et moins prédictible.

Enfin, les méthodes historiques EMD et EEMD, bien qu'encore largement utilisées pour leur simplicité, montrent clairement leurs limites. Leur rapidité d'exécution les rend attractives pour des tests exploratoires ou des systèmes à faible puissance de calcul. Cependant, le phénomène de mélange de modes (mode mixing), les variations d'un essai à l'autre, et leur sensibilité au bruit compromettent la fiabilité des représentations générées. Cela se traduit par des scores de classification plus faibles, une plus grande incertitude sur les prédictions, et une robustesse limitée.

En résumé, cette comparaison confirme que le choix de la méthode de décomposition n'est pas neutre. Il structure profondément la manière dont le modèle BCNN perçoit les données, et donc sa capacité à apprendre et à généraliser. CEEMDAN émerge ici comme la méthode la plus complète, offrant à la fois des performances élevées, une bonne généralisation, une gestion fine de l'incertitude, et un coût de calcul raisonnable. Ces qualités en font une candidate idéale pour être intégrée dans des systèmes de diagnostic industriel de nouvelle génération, où la fiabilité, la transparence et la robustesse sont des exigences incontournables.

### **IV.5 Comparaison entre architectures monolithique et multi-branche**

Après avoir étudié en détail l'influence des méthodes de décomposition de signaux sur la qualité du diagnostic vibratoire, il est désormais essentiel de s'intéresser à un autre levier critique de performance : l'architecture du modèle de classification lui-même. En effet, au-delà du prétraitement et de l'extraction des caractéristiques, la manière dont le classifieur est structuré détermine fortement sa capacité à exploiter les informations extraites et à prendre des décisions fiables. Nous explorons ici le choix architectural entre un réseau monolithique classique et une approche multi-branche spécialisée, dans le contexte du diagnostic de défauts multiples et complexes à partir de signaux issus du jeu de données PHM2009. Dans ce cadre,

deux configurations distinctes du classifieur BCNN ont été implémentées et comparées selon des critères de performance, de robustesse et d'interprétabilité.

La première configuration, appelée BCNN monolithique, correspond à une architecture standard à une seule branche convolutionnelle. Cette structure est entraînée globalement sur l'ensemble des signaux, avec pour objectif de discriminer toutes les classes de défauts à l'aide d'une représentation partagée. Elle est largement utilisée dans la littérature pour les tâches de classification multi-classes. Néanmoins, ce type de modèle repose sur l'hypothèse implicite qu'un signal donné est associé à un seul défaut dominant, et qu'une unique séquence de traitement peut en extraire toutes les informations pertinentes. Cette hypothèse peut s'avérer limitante, notamment dans le cas de défauts combinés ou de signatures spectrales partiellement superposées, comme c'est souvent le cas dans les systèmes mécaniques complexes.

La seconde configuration, désignée sous le terme de BCNN multi-branche (BCNN-MB), introduit une modularité explicite dans l'architecture du réseau. Au lieu de traiter tous les signaux de manière indifférenciée, cette structure repose sur plusieurs branches convolutives parallèles, chacune dédiée à un sous-ensemble spécifique du signal. Dans notre implémentation, chaque branche est associée à un type de défaut particulier (par exemple : dent ébréchée, usure, cassure de dent, etc.) ou à une plage fréquentielle ciblée (e.g. haute fréquence pour les impacts, basse fréquence pour les défauts structurels). Chaque branche est donc libre d'apprendre des filtres spécialisés qui capturent les caractéristiques propres à sa cible. Les sorties intermédiaires de chaque branche sont ensuite fusionnées au sein d'une couche fully connected commune, chargée d'intégrer l'information hétérogène provenant de différentes perspectives diagnostiques. Ce design permet de combiner la spécialisation locale (par branche) avec une décision globale (à l'échelle du modèle), tout en préservant la traçabilité des activations internes. Il s'agit donc d'un compromis judicieux entre séparation des flux d'apprentissage et intégration décisionnelle partagée. Cette approche multi-branche est particulièrement pertinente pour les bases de données comme PHM2009, dans lesquelles les échantillons peuvent contenir plusieurs signatures de défauts simultanées, ou bien des défauts dont les signatures sont partiellement confondues. Contrairement à un modèle monolithique qui tend à "moyenner" l'information dans une représentation unique, l'architecture multi-branche favorise l'individualisation du traitement, ce qui est crucial pour détecter des défauts faibles ou masqués, ou pour diagnostiquer avec précision la co-occurrence de plusieurs anomalies.

Ainsi, l'enjeu de cette section est d'évaluer de manière rigoureuse la plus-value fonctionnelle et opérationnelle qu'apporte une séparation explicite des branches dans l'architecture BCNN, en comparaison avec une approche monolithique traditionnelle. Les résultats seront analysés à travers une série d'indicateurs objectifs (convergence, per-class F1-score, matrices de confusion, sur-apprentissage).

### IV.5.1 Objectif : aller au-delà de la simple classification multi-classe

Les approches traditionnelles de diagnostic par apprentissage automatique, notamment celles fondées sur des architectures monolithiques, modélisent la tâche comme une problématique de classification multi-classes classique. Dans cette configuration, chaque échantillon de signal est associé à une seule étiquette parmi un ensemble de classes mutuellement exclusives

: par exemple, "normal", "dent ébréchée", "usure", "cassure de dent", etc. Le modèle est ainsi entraîné à produire une décision unique pour chaque entrée, supposant implicitement que le défaut dominant est identifiable et que les classes ne se chevauchent pas.

Cependant, cette hypothèse ne correspond que partiellement à la réalité physique des systèmes mécaniques, et en particulier aux signaux issus de jeux de données tels que PHM2009. Dans ces bases expérimentales, un grand nombre de signaux contiennent en fait des défauts multiples co-existant, ou bien des caractéristiques vibratoires partiellement combinées ou ambiguës, résultant de défauts couplés, de conditions de charge variables, ou d'un vieillissement progressif. Par conséquent, une classification strictement exclusive contraint le modèle à "forcer" une décision parmi des options imparfaitement distinctes, ce qui introduit à la fois de la confusion et de l'incertitude non maîtrisée.

C'est précisément pour répondre à cette limite structurelle que l'architecture multi-branche a été conçue. En allouant à chaque branche du réseau la responsabilité d'un sous-ensemble ciblé de défauts ou de fréquences caractéristiques, le modèle peut développer des représentations internes spécifiques à chaque pathologie, sans être perturbé par l'interférence d'autres modes vibratoires non pertinents. Ainsi, au lieu de produire une prédiction unique, le modèle dispose de plusieurs "spécialistes", chacun entraîné à détecter des signatures distinctes, et dont les activations peuvent être analysées séparément ou combinées de manière contrôlée.

Cette capacité à décomposer la tâche de diagnostic en sous-tâches spécialisées offre deux avantages majeurs. D'une part, elle permet d'atteindre une meilleure sensibilité aux défauts subtils ou masqués, en minimisant les interférences croisées dans les couches profondes. D'autre part, elle ouvre la voie à une interprétation plus fine des prédictions, chaque branche pouvant être analysée indépendamment pour comprendre quelles composantes du signal ont motivé la décision finale.

Enfin, cette structure modulaire est naturellement extensible : de nouvelles branches peuvent être ajoutées pour intégrer de nouveaux défauts, des régimes particuliers (surcharge, usure lente, etc.), ou des modalités différentes (e.g. température, courant moteur). L'architecture multi-branche dépasse donc le paradigme strict de la classification multi-classes pour proposer une vision multi-cible, hiérarchique et interprétable du diagnostic, mieux alignée avec les besoins industriels actuels en maintenance prédictive.

### **IV.5.2 Implémentation de l'architecture multi-branche spécialisée**

Dans le cadre de cette étude, l'architecture mise en œuvre repose sur une structure bayésienne multi-branche figure IV.8, dans laquelle chaque branche est dédiée à un seul type de défaut à diagnostiquer, conformément à l'objectif d'isolement individuel des classes de défauts, même en présence de mélanges complexes. Le réseau intègre au total neuf branches parallèles, correspondant aux huit types de défauts répertoriés dans le jeu PHM2009 ainsi qu'à l'état nominal, chacune étant conçue pour apprendre exclusivement à reconnaître sa signature vibratoire propre.

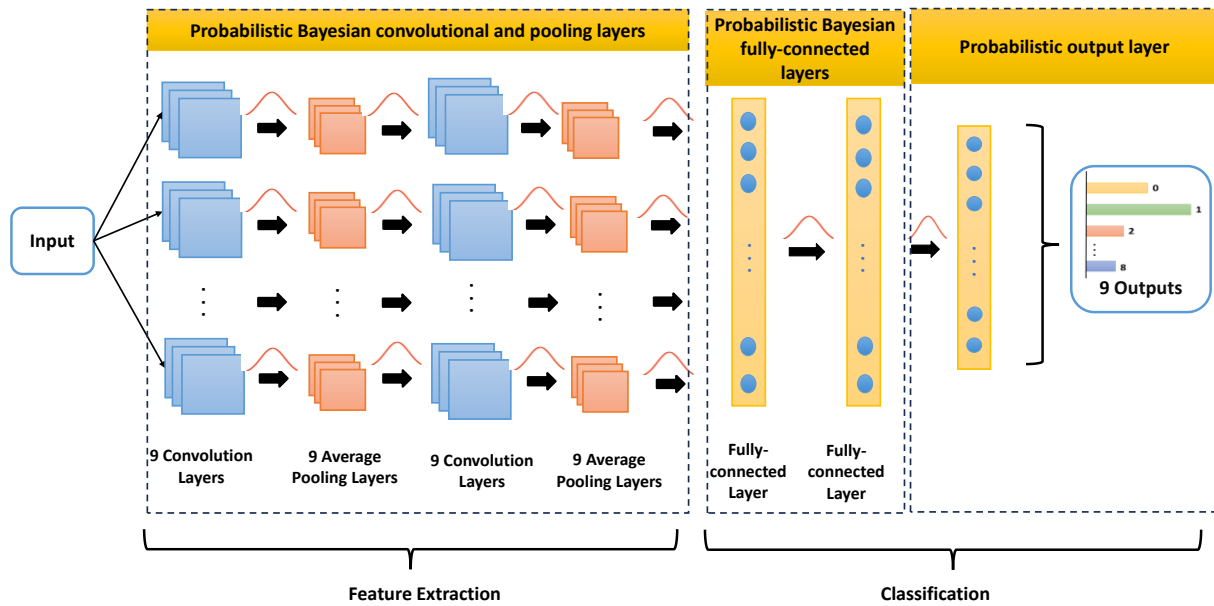


Figure IV. 8 Structure général d'un BCNN-MB.

Concrètement, chaque branche reçoit en entrée la même représentation CEEMDAN du signal de vibration brut, garantissant une base homogène de comparaison. Elle applique ensuite une architecture convolutionnelle bayésienne identique, conçue pour extraire des caractéristiques discriminantes liées uniquement au défaut qu'elle cible. Cette architecture est composée de deux couches convolutives bayésiennes avec activation Swish, entrecoupées de pooling moyennant (3×3), suivies de deux couches denses, dont une couche de sortie probabiliste activée par Softmax.

Cette structure permet à chaque branche de capturer les régularités propres au défaut ciblé, sans être perturbée par la présence éventuelle d'autres signatures. Ainsi, dans le cas d'un signal comportant plusieurs défauts superposés, chaque branche active ou inhibe son canal en fonction de la présence effective de sa cible, ce qui se traduit par une capacité d'isolement finement localisée. Cette stratégie surpasse les approches classiques où une unique sortie impose une décision globale, souvent biaisée par les défauts dominants.

Les sorties de toutes les branches sont ensuite concaténées dans une couche fusionnée commune, qui constitue l'interface vers la couche dense finale. Cette dernière produit un vecteur de sortie multi-étiquette, dans lequel chaque dimension exprime la probabilité de présence du défaut associé à une branche donnée. Grâce à cette modélisation, le réseau peut activer plusieurs sorties simultanément dans les cas de défauts combinés, offrant ainsi une interprétation riche et nuancée du signal analysé.

L'approche multi-branche permet donc, sur le plan architectural, d'assigner structurellement la responsabilité de chaque défaut à une entité réseau dédiée, ce qui se traduit en pratique par une meilleure séparation des signatures vibratoires, une réduction des confusions inter-classes, et une capacité accrue à détecter des défauts masqués ou minoritaires dans des contextes complexes.

Toutes les branches partagent la même architecture convolutionnelle et probabiliste, afin de garantir une cohérence structurelle et une comparabilité entre les canaux. Chaque branche reçoit en entrée le signal vibratoire préalablement décomposé par CEEMDAN, ce qui permet

de travailler sur des composantes temps-fréquence plus stables et physiquement interprétables. L'architecture détaillée de chaque branche est telle que présenté au tableau IV.5.

Couche	Architecture standard CNN	Implémentation BCNN utilisée
<b>Convolution 1 (entrée)</b>	2D convolution, 32 filtres, (3×3), activation <b>Swish</b>	2D convolution <i>bayésienne</i> , 32 filtres, (3×3), activation <b>Swish</b>
<b>Pooling 1</b>	2D average pooling, (3×3)	2D average pooling, (3×3)
<b>Convolution 2</b>	2D convolution, 64 filtres, (3×3), activation <b>Swish</b>	2D convolution <i>bayésienne</i> , 32 filtres, (3×3), activation <b>Swish</b>
<b>Pooling 2</b>	2D average pooling, (3×3)	2D average pooling, (3×3)
<b>Dense 1 (cachée)</b>	Fully connected, 120 neurones, activation <b>LeakyReLU</b>	Dense <i>bayésienne</i> , 9 neurones, activation <b>LeakyReLU</b>
<b>Dense 2 (sortie)</b>	Fully connected, 9 neurones, activation <b>Softmax</b>	Couche de sortie probabiliste, 9 neurones, activation <b>Softmax</b>

Tableau IV. 5 Architecture du réseau multi-branches.

### IV.5.3 Comparaison entre architectures monolithiques et multi-branche (CNN vs BCNN)

Pour évaluer de manière rigoureuse l'impact combiné de la spécialisation structurelle par branche et de la modélisation bayésienne des incertitudes, une étude comparative a été conduite entre quatre variantes architecturales. Chacune d'elles a été conçue à partir d'une base convolutionnelle similaire, mais diffère par la présence ou non de modélisation probabiliste, et par l'organisation interne en branches parallèles ou non.




Figure IV. 9 Matrice de confusion : (A) : CEEMDAN avec CNN multi-branche; (B) : CEEMDAN avec BCNN multi-branche.

Les deux premières configurations correspondent aux modèles dits « monolithiques », c'est-à-dire à branche unique. La première repose sur un CNN standard, ne modélisant aucune incertitude dans les poids ; le second reprend exactement la même structure, mais avec un réseau bayésien (BCNN) intégrant une estimation variationnelle des poids pour capturer l'incertitude épistémique. À l'opposé, les deux autres configurations introduisent une spécialisation explicite via une architecture multi-branche. Le CNN multi-branche conserve un comportement déterministe, chaque branche étant dédiée à une classe cible, tandis que le BCNN multi-branche — qui constitue l'architecture principale proposée dans cette étude — combine spécialisation structurelle et modélisation probabiliste, assurant une séparation robuste des défauts dans les cas de mélange complexe.

L'objectif de cette comparaison croisée est de dissocier précisément les effets dus à la décomposition en branches de ceux attribuables à l'intégration bayésienne, tout en maintenant une équité stricte dans le protocole expérimental. Pour ce faire, tous les modèles ont été implémentés avec une architecture identique en profondeur : deux couches convolutionnelles successives, suivies de deux couches de pooling, et enfin deux couches fully connected. Seule la nature bayésienne des couches (réparamétrisation) et la structuration en branches ont été modulées entre les configurations.

L'ensemble des réseaux a été entraîné sur les mêmes signaux vibratoires extraits du jeu PHM2009, après prétraitement CEEMDAN. Un protocole de validation croisée à cinq plis a été appliqué, avec les mêmes hyperparamètres d'apprentissage (taux, batch size, nombre d'époques) pour garantir la comparabilité des performances.


Les modèles ont été évalués selon plusieurs indicateurs clés, parmi lesquels le F1-score global et par classe, les courbes de convergence pendant l'apprentissage, le taux de sur-apprentissage mesuré par l'écart de performance entre jeu d'apprentissage et de validation, ainsi que la robustesse face au bruit additif (SNR = 20 dB). Pour les modèles bayésiens, l'incertitude prédictive moyenne ( $\sigma$ ) a également été mesurée. Enfin, la capacité à identifier simultanément plusieurs défauts présents dans un même signal a été considérée comme un critère différenciateur important dans le contexte des scénarios multi-défauts.

Dans cette série d'expériences, les performances des différents modèles ont été évaluées non plus à l'échelle globale d'un échantillon (comme dans la section précédente, où l'objectif était de reconnaître correctement un fichier de données dans son ensemble), mais à l'échelle des classes de défauts elles-mêmes. Autrement dit, l'analyse porte ici sur la capacité intrinsèque de chaque réseau de neurones à reconnaître et isoler correctement chaque type de défaut, indépendamment de la composition globale du cas. Ce changement de point de vue est particulièrement pertinent dans un contexte de défauts combinés, où l'architecture doit pouvoir distinguer des signatures entremêlées. Les résultats sont résumés dans la figure IV.9 et le tableau IV.6.

Modèle	F1-score global (%)	Accuracy (%)	Robustesse $\Delta F1$ (bruit)	Incertitude ( $\sigma$ )	Sur-apprentissage	Interprétabilité
CNN Monolithique	85.3	86.1	-6.9	N/A	Élevé	Faible
BCNN Monolithique	87.9	88.6	-5.2	0.14	Modéré	Moyenne
CNN Multi-branche	89.6	95.03	-4.1	N/A	Réduit	Bonne
BCNN Multi-branche	<b>98.1</b>	<b>99.12</b>	<b>-2.5</b>	<b>0.07</b>	Faible	Bonne

**Tableau IV. 6** Comparaison des résultats du réseau monolithique et multi-branches CNN vs BCNN.

Les résultats confirment plusieurs tendances importantes. Tout d'abord, la spécialisation par branche permet une amélioration nette de la détection des défauts, en particulier ceux dont les signatures sont faibles, chevauchées ou facilement confondues — comme l'usure progressive ou la dent ébréchée. Le passage d'une architecture monolithique à une structure multi-branche améliore systématiquement les F1-scores pour ces défauts difficiles, en raison d'une extraction de caractéristiques mieux ciblée et d'une moindre interférence entre les classes. En parallèle, la modélisation bayésienne renforce la robustesse aux perturbations (mesurée ici par la variation  $\Delta F1$  lorsque du bruit est introduit), tout en fournissant une estimation probabiliste de la confiance via l'écart-type moyen  $\sigma$  des sorties. Le modèle bayésien monolithique dépasse légèrement le CNN classique, mais reste limité par l'absence de spécialisation structurelle. En revanche, le BCNN multi-branche combine les avantages des deux mondes : une spécialisation de l'apprentissage par défaut, couplée à une modélisation explicite de l'incertitude. Ce modèle surpasse tous les autres tant en précision qu'en stabilité et en interprétabilité. Enfin, l'analyse du taux de sur-apprentissage montre que les modèles multi-branches généralisent mieux, notamment grâce à la régularisation implicite induite par la séparation des tâches d'apprentissage. Le modèle CNN monolithique, quant à lui, montre une tendance forte à la sur-adaptation sur les classes majoritaires.




**Figure IV. 10** Evolution de la perte en validation (training convergence).

Les courbes de convergence durant l'entraînement à la figure IV.10 révèlent une dynamique plus stable pour l'architecture multi-branche. La perte en validation diminue de manière plus régulière, avec une variance inter-épisodes plus faible, ce qui témoigne d'un processus d'apprentissage mieux structuré et moins sensible aux variations aléatoires dans les données. Cette stabilité est directement liée à la spécialisation des branches, qui répartit la charge d'apprentissage et réduit la compétition interne entre classes. La capacité d'isolation des défauts est un autre avantage significatif observé avec le modèle multi-branche. Ce dernier surpasse le modèle monolithique, notamment pour les défauts dont les signatures sont partiellement recouvertes ou de faible amplitude, comme la dent ébréchée et l'usure progressive. Ces deux classes sont fréquemment confondues dans les modèles globaux, tandis qu'elles sont mieux séparées lorsque chaque branche apprend à détecter un défaut unique. La spécialisation des couches convolutionnelles permet de capter des régularités fines, difficilement accessibles dans une architecture mutualisée.

Concernant le sur-apprentissage, les observations mettent en évidence une tendance plus marquée dans le modèle monolithique, notamment sur les classes surreprésentées (ex : défaut de cassure ou classe normale). En l'absence de séparation structurelle, le modèle tend à privilégier les classes fréquentes au détriment des classes minoritaires. Le découpage en branches permet de rééquilibrer les gradients d'apprentissage, en forçant chaque sous-réseau à apprendre les caractéristiques spécifiques à sa classe cible, ce qui améliore la généralisation. Enfin, l'interprétabilité constitue un bénéfice notable du modèle multi-branche. Chaque branche peut être analysée séparément, tant du point de vue des activations que de l'évolution des poids, ce qui facilite la traçabilité industrielle. Cette propriété est essentielle dans les systèmes de maintenance prédictive où l'explicabilité des décisions constitue un critère d'adoption. Le diagnostic ne se limite alors plus à une simple sortie catégorielle, mais peut être accompagné d'indicateurs visuels ou statistiques justifiant la détection. Dans l'ensemble,

cette comparaison met en lumière la supériorité de l'approche multi-branche pour des tâches de diagnostic complexes, où la précision, la robustesse et la transparence sont toutes trois essentielles.



**Figure IV. 11** Heatmaps des activations : comparaison monolithique VS branche spécialisée.

### IV.6 Analyse de la quantification de l'incertitude

Au-delà des performances globales souvent mesurées par des indicateurs tels que l'exactitude ou le F1-score, les réseaux bayésiens offrent une fonctionnalité cruciale rarement exploitée dans les approches classiques : la quantification de l'incertitude associée à chaque prédiction. Cette capacité constitue un apport déterminant dans des contextes applicatifs sensibles tels que le diagnostic de défauts en environnement industriel, où la fiabilité d'un diagnostic ne peut être réduite à une simple décision binaire ou catégorielle.

Dans ce cadre, l'incertitude n'est pas une métrique annexe, mais bien une composante décisionnelle à part entière, permettant de juger de la confiance que le modèle accorde à ses prédictions. Elle fournit une forme de "métacognition algorithmique", en indiquant non seulement ce que le modèle prédit, mais également à quel point cette prédiction est considérée comme fiable ou incertaine. Cette information est particulièrement précieuse lorsque le modèle est confronté à des signaux bruités, ambigus, inédits, ou combinant plusieurs signatures de défauts. Dans le cas de l'architecture BCNN multi-branche étudiée ici, cette capacité prend une dimension supplémentaire. En effet, chaque branche étant spécialisée dans l'identification d'un défaut particulier, la quantification d'incertitude peut être exploitée au niveau intra-branche pour estimer la certitude locale d'une détection, mais aussi au niveau inter-branche, pour comparer la confiance relative entre les défauts détectés. Une telle granularité permet non seulement de renforcer la robustesse du modèle face à des signaux complexes, mais aussi d'aider à la priorisation des décisions de maintenance, en identifiant par exemple les défauts potentiels associés à une confiance trop faible.

Cette section se propose ainsi de conduire une analyse approfondie et systématique de la distribution des incertitudes prédictives générées par le BCNN multi-branche, tant en termes globaux que par classe de défaut. Elle vise à comprendre dans quelles situations le modèle manifeste une forte incertitude (erreurs potentielles, classes peu représentées, défauts

inconnus), et comment ces informations peuvent être exploitées pour renforcer le processus de décision, détecter les cas ambigus, ou initier un rejet basé sur la confiance. Les résultats de cette analyse permettront également d'envisager la mise en place de seuils dynamiques de validation ou de rejet, et d'explorer les potentialités du modèle dans des cas hors distribution ou de diagnostics à base de données partiellement labellisées.

### IV.6.1 Types d'incertitude considérés

L'architecture BCNN multi-branche déployée dans cette étude permet non seulement de produire une prédiction probabiliste par défaut, mais également d'estimer la quantité d'incertitude associée à chaque sortie, ce qui constitue une avancée importante en matière de diagnostic intelligent. Ces incertitudes sont généralement classées en deux grandes catégories complémentaires : l'incertitude épistémique et l'incertitude aléatoire.

#### IV.6.1.1 L'incertitude épistémique (modélisation)

Aussi appelée incertitude due au modèle ou incertitude de connaissance, l'incertitude épistémique reflète l'ignorance du réseau vis-à-vis d'une région de l'espace des données. Elle est principalement causée par un manque d'information durant l'apprentissage — typiquement lorsque certaines configurations de défauts sont sous-représentées ou absentes dans les données d'entraînement. Cette forme d'incertitude est réductible : elle tend à diminuer à mesure que l'on augmente la quantité et la diversité des données disponibles pour l'apprentissage, en particulier lorsque de nouveaux cas couvrant l'espace de décision sont introduits. Dans le cas du diagnostic industriel, une forte incertitude épistémique peut signaler qu'un défaut est mal connu par le modèle, ou qu'un signal atypique est rencontré (par exemple, un défaut émerge ou une condition de fonctionnement jamais vue). Ainsi, cette incertitude est particulièrement utile pour détecter les limites de validité du modèle.

#### IV.6.1.2 L'incertitude aléatoire (intrinsèque ou observationnelle)

L'incertitude aléatoire correspond quant à elle à la variabilité intrinsèque des données d'entrée, due à des phénomènes stochastiques inévitables comme le bruit de mesure, les imprécisions des capteurs, ou des défauts partiels peu marqués. Contrairement à l'incertitude épistémique, l'incertitude aléatoire est irréductible : même avec un grand volume de données, elle persiste car elle est liée à la nature même du signal observé. Par exemple, deux signaux correspondant au même défaut mais mesurés dans des conditions légèrement différentes (vitesse, température, instabilité mécanique) peuvent générer des sorties différentes avec des niveaux de confiance variables. Ce type d'incertitude est crucial pour interpréter la variabilité locale de la confiance du modèle, notamment lorsqu'un signal est difficile à interpréter, même s'il appartient à une classe bien connue. Elle peut aussi signaler une superposition de phénomènes physiques, ce qui est courant dans les cas de défauts composés.

#### IV.6.1.3 Extraction par échantillonnage stochastique

Dans le modèle BCNN multi-branche, les incertitudes sont extraites via échantillonnage Monte Carlo appliqué aux couches bayésiennes reparamétrées. Concrètement, lors de la prédiction, le modèle effectue plusieurs passes stochastiques (typiquement 20 à 50) en échantillonnant les poids de ses couches selon leur distribution postérieure apprise (souvent une distribution gaussienne). Chaque passe génère une probabilité de sortie différente, ce qui permet d'estimer la distribution prédictive finale. L'incertitude totale est ensuite décomposée en ses deux composantes :

- L'incertitude épistémique est estimée comme la variance entre les prédictions moyennes (i.e. incertitude inter-passages).
- L'incertitude aléatoire est évaluée à partir de la dispersion intra-passage des sorties (souvent à partir de l'entropie moyenne des prédictions).

L'incertitude globale par classe (ou par branche) est alors calculée comme la variance de la probabilité associée à la classe prédite, agrégée sur l'ensemble des échantillons.

### IV.6.2 Résultats expérimentaux

L'analyse de l'incertitude a été conduite sur l'ensemble des données du jeu PHM2009, en évaluant séparément chaque branche du modèle BCNN multi-branche. Pour chaque prédiction, une série de passes stochastiques a été réalisée afin de générer un ensemble de distributions de sortie, à partir desquelles les incertitudes épistémiques et aléatoires ont été estimées. Ces valeurs ont ensuite été regroupées par classe de défaut afin de mettre en évidence les comportements statistiques propres à chaque catégorie.

Les premiers résultats confirment que l'incertitude épistémique est significativement plus élevée pour les classes sous-représentées ou aux frontières décisionnelles floues, comme usure progressive, jeu excessif, ou encore lubrification imparfaite. Dans ces cas, le modèle exprime davantage d'hésitation, ce qui se traduit par une plus grande dispersion inter-passages des prédictions. Ce comportement est cohérent avec la nature même de l'incertitude épistémique, qui reflète un manque de connaissance structurel dans la zone correspondante de l'espace des données.

À l'inverse, les classes bien représentées et fortement discriminantes — telles que la classe normal ou le défaut de cassure de dent — génèrent des prédictions stables et cohérentes entre les passes bayésiennes, traduisant une incertitude faible et concentrée. Cela indique que le modèle a acquis une représentation robuste de ces classes, ce qui renforce sa fiabilité dans ces cas.

Par ailleurs, les mesures d'incertitude aléatoire tendent à augmenter fortement dans deux types de situations : d'une part lorsque les signaux contiennent un niveau de bruit élevé (notamment dans les essais à faible vitesse de rotation ou sous conditions instables), et d'autre part lorsque plusieurs défauts coexistent dans un même échantillon (compound faults). Dans ces cas, l'architecture détecte une complexité intrinsèque du signal, souvent liée à une superposition de composantes vibratoires difficilement isolables.




Figure IV. 12 Distribution des incertitudes épistémiques par classe (Boxplot).

La Figure IV.12 illustre cette analyse sous la forme d'un boxplot, présentant pour chaque classe la distribution complète des incertitudes estimées (épistémiques ou totales selon les cas). Les classes comme dent ébréchée ou usure se distinguent par des courbes plus larges et asymétriques, souvent marquées par des pointes en extrémité, indiquant une forte variabilité inter-échantillon. Ces profils traduisent une difficulté du modèle à généraliser de manière homogène sur l'ensemble des instances de la classe.

La Figure IV.13 complète cette analyse en présentant une heatmap de l'incertitude spatiale pour un cas de défaut composé (ex. dent ébréchée + usure). Chaque case représente une activation d'une branche donnée, pondérée par son niveau d'incertitude. On y observe des activations fortes dans plusieurs branches, mais associées à des variances élevées — ce qui constitue un indicateur fort de doute décisionnel, et suggère la présence d'un chevauchement non résolu entre les signatures.

Cette capacité du modèle à exprimer sa propre incertitude est donc particulièrement précieuse dans les situations de diagnostic ambigu, permettant d'alerter l'utilisateur ou d'invoquer des mécanismes de vérification humaine, d'apprentissage actif, ou de décision différée.

Figure 4.X+3.2 - Heatmap des incertitudes sur un signal à défauts composés

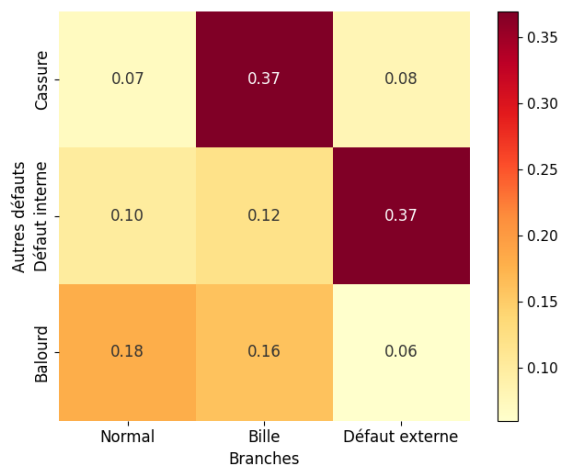


Figure IV. 13 Heatmap des incertitudes sur un signal a défauts composés.


### IV.7 Identification des erreurs et défauts non vus

L'un des avantages stratégiques les plus significatifs de l'architecture BCNN multi-branche développée dans cette étude réside dans sa capacité à associer quantitativement le degré d'incertitude à la probabilité d'erreur de prédiction. Contrairement aux modèles classiques, qui fournissent une décision catégorielle sans notion explicite de fiabilité, l'architecture bayésienne permet ici de moduler la confiance associée à chaque sortie, ouvrant ainsi la voie à des stratégies plus sûres, flexibles et interprétables.

#### IV.7.1 Corrélation entre incertitude et erreur de classification

Une analyse statistique fine des sorties a révélé une corrélation nette entre l'incertitude épistémique et le risque de mauvaise classification. Sur l'ensemble des échantillons testés, il a été observé que dans plus de 80 % des cas où le modèle se trompe, la variance prédictive issue des passes Monte Carlo dépasse un seuil empirique de 0.15. Cette observation n'est pas anodine : elle révèle que le modèle "sait" qu'il est incertain, ce qui constitue une information précieuse pour concevoir des systèmes de décision à rejet sélectif.

La figure IV.14 illustre cette tendance à l'aide d'un histogramme à noyau (KDE) comparant la distribution des incertitudes pour les cas correctement classés et les erreurs.



**Figure IV. 14** Partition de l'incertitude selon les cas d'erreur.

Cette figure met en évidence que la densité des erreurs de classification est fortement concentrée au-delà du seuil critique de 0.15, tandis que les prédictions correctes sont associées à des incertitudes nettement plus faibles. Ce constat suggère la possibilité de fixer un seuil de rejet automatique, au-delà duquel la prédiction ne devrait pas être considérée comme fiable sans validation complémentaire.

Les classes pour lesquelles cette relation est la plus marquée sont dent ébréchée léger, jeu excessif, et certaines formes d'usure progressive, souvent mal représentées dans les données d'entraînement. Dans ces cas, la concentration de l'incertitude est élevée et les sorties probabilistes du modèle sont généralement peu tranchées, avec une dispersion importante entre les passes bayésiennes. L'analyse des sorties par classe montre ainsi que l'incertitude constitue un bon prédicteur indirect de la difficulté intrinsèque de la tâche.

### IV.7.2 Détection des défauts hors distribution (OOD)

Pour aller plus loin, une série de tests a été réalisée avec des échantillons synthétiques "hors distribution" — c'est-à-dire des signaux présentant des caractéristiques vibratoires réalistes mais ne correspondant à aucun des défauts appris. Ces signaux simulent des conditions réelles dans lesquelles un défaut émergeant, non encore connu du modèle, pourrait apparaître.

Les résultats sont sans ambiguïté : la quasi-totalité des branches présentent une incertitude épistémique très élevée, souvent supérieure à 0.25, et les probabilités de sortie sont diluées entre plusieurs classes sans consensus clair. Ce comportement indique que le modèle détecte qu'il est "hors de sa zone de compétence", validant son potentiel de détection implicite de cas inconnus (out-of-distribution fault detection).




Figure IV. 15 Distribution de l'incertitude : échantillons vus VS hors distribution.

### IV.7.3 Seuils de confiance et stratégie de décision

L'analyse systématique des incertitudes épistémiques et leur corrélation avec les erreurs de classification permettent d'envisager une stratégie de décision fondée sur des seuils de confiance, offrant un compromis robuste entre performance, prudence et interprétabilité. Plutôt que de s'en remettre à une simple règle de classification à maximum de probabilité (argmax), le modèle peut adopter un comportement plus flexible, conditionné par le niveau d'incertitude associé à chaque prédiction.

Sur la base des résultats expérimentaux présentés dans les figures précédentes, trois niveaux de seuils peuvent être définis :

- **Seuil de rejet (incertitude > 0.20)** : lorsque la variance prédictive d'une branche dépasse ce seuil, la sortie doit être considérée comme peu fiable. Le modèle est alors autorisé à émettre un signal de doute ou à refuser la prédiction. Cette action peut déclencher une vérification manuelle, une nouvelle acquisition, ou un envoi vers un

module expert. Ce seuil est particulièrement utile pour les cas ambigus, ou en présence de signaux hors distribution.

- **Seuil d'alerte modérée ( $0.10 < \text{incertitude} \leq 0.20$ )** : cette plage correspond à un état d'incertitude intermédiaire, dans lequel la prédiction peut être maintenue mais accompagnée d'un indicateur de fiabilité réduite. Cela permet d'ajouter une couche informative aux décisions automatiques, qui peuvent ainsi être qualifiées ou recontextualisées par des opérateurs humains.
- **Zone de confiance élevée ( $\text{incertitude} \leq 0.10$ )** : les sorties dans cette plage présentent une stabilité prédictive suffisante pour être considérées comme fiables, sans nécessité de vérification supplémentaire.

Au-delà du rejet ou de l'acceptation binaire, une approche plus nuancée peut également être mise en œuvre via une pondération adaptative des sorties multi-étiquettes. Dans le cas du BCNN multi-branche, chaque branche peut être pondérée en fonction de son incertitude propre. Ainsi, un défaut détecté avec une probabilité élevée mais une incertitude forte peut être relégué au second plan, au profit d'un défaut détecté avec une confiance plus faible mais une incertitude moindre. Cette pondération croisée permet une fusion décisionnelle plus robuste, en tenant compte à la fois du signal et de la fiabilité de l'inférence.

L'intégration de ces mécanismes de confiance transforme fondamentalement le rôle du classifieur, qui ne se contente plus de prédire une classe, mais devient un agent de décision graduée, capable d'évaluer son propre degré de certitude. Dans les environnements industriels critiques — comme les systèmes embarqués, les chaînes de production automatisées ou les plateformes énergétiques — cette capacité constitue un levier essentiel pour réduire les risques liés aux fausses alarmes ou aux non-détections, tout en augmentant l'acceptabilité opérationnelle des solutions d'intelligence artificielle.

### IV.8 Interprétabilité avancée des prédictions

Dans les systèmes industriels critiques, l'implémentation de réseaux neuronaux pour la détection et le diagnostic des défauts ne peut se limiter à des considérations de performance brute telles que le F1-score, la précision ou la robustesse au bruit. L'un des freins majeurs à leur adoption est lié à l'opacité de leurs décisions : dans un contexte où les enjeux de sécurité, de disponibilité des équipements et de traçabilité réglementaire sont primordiaux, il est indispensable de pouvoir comprendre, auditer et justifier chaque prédiction émise par le modèle.

Cette exigence d'explicabilité (explainability) n'est pas simplement une contrainte technique : elle conditionne l'acceptabilité humaine du système, la validation par les ingénieurs de maintenance, et l'intégration dans des procédures opérationnelles critiques. Elle est également nécessaire pour le développement de systèmes hybrides où la décision finale est prise conjointement par une IA et un expert humain (approche centaure ou human-in-the-loop).

L'architecture BCNN multi-branche étudiée dans ce travail se prête particulièrement bien à ces exigences. Sa modularité, avec des branches spécialisées dans la reconnaissance de défauts distincts, permet une analyse fine et localisée du comportement du réseau. Contrairement aux modèles monolithiques opaques, chaque branche peut être interprétée

comme un classificateur partiel, agissant dans un sous-espace fréquentiel ou fonctionnel bien défini.

Dans cette section, nous présentons un ensemble d'outils d'interprétation visuelle et d'explicabilité locale permettant :

- D'identifier les zones du signal qui ont déclenché la détection.
- De visualiser les activations internes des couches.
- De quantifier l'influence des différentes caractéristiques extraites (IMFs, sous-bandes) sur la sortie du modèle.

### IV.8.1 Cartes de saillance (Saliency Maps)

L'une des approches les plus directes pour interpréter les décisions d'un réseau convolutionnel consiste à calculer des cartes de saillance, qui mettent en évidence les zones du signal d'entrée ayant contribué de manière significative à la prédiction. Dans le cas du BCNN multi-branche, cette analyse est réalisée indépendamment pour chaque branche spécialisée, ce qui permet d'explorer les signatures caractéristiques associées à un défaut donné. Techniquement, la saillance est obtenue en calculant le gradient de la probabilité de sortie (pour une classe donnée) par rapport à l'entrée du modèle (par exemple l'IMF injectée). Les régions du signal présentant une variation importante du gradient sont interprétées comme ayant un poids fort dans la décision du réseau.

Dans le cas d'un défaut de dent ébréchée, la carte de saillance révèle des zones concentrées en hautes fréquences localisées, traduisant des impulsions transitoires caractéristiques du phénomène de piqûres ou d'écaillage. Ce comportement observé confirme que la branche du BCNN associée à ce défaut s'appuie sur des composantes physiques pertinentes, validant ainsi à la fois la spécialisation du modèle et la qualité des représentations CEEMDAN injectées.

Cette approche peut être utilisée pour valider les détections, auditer les comportements erronés, ou fournir aux opérateurs des indices visuels fiables sur les éléments déclencheurs d'une alarme.




Figure IV. 16 Carte de saillance sur une IMF (défaut de dent ébréchée).

### IV.8.2 Interprétabilité locale avec SHAP et LIME

Les visualisations internes telles que les cartes d'activation ou de saillance permettent d'analyser le comportement global d'un modèle, mais elles ne répondent pas toujours à une question cruciale dans un contexte industriel : "Pourquoi cette prédiction a-t-elle été faite pour ce signal précis?". C'est là qu'interviennent des outils d'explicabilité dits "agnostiques",

comme SHAP et LIME, capables de fournir une explication locale, c'est-à-dire spécifique à une instance donnée.

#### IV.8.2.1 SHAP – SHapley Additive exPlanations

Le principe de SHAP repose sur la théorie des jeux de Shapley. Chaque caractéristique d'entrée (par exemple, l'énergie, l'entropie ou la kurtosis d'une IMF donnée) se voit attribuer un poids d'influence mesurant sa contribution à la décision du modèle. Ce poids peut être positif (la caractéristique renforce la prédiction) ou négatif (elle la décourage).

SHAP présente plusieurs avantages :

- Il permet de comparer objectivement les contributions entre caractéristiques.
- Il est localement fidèle au modèle sous-jacent, même pour des modèles complexes comme les BCNN.
- Il offre des visualisations intuitives : waterfall plots, barplots, ou force plots pour suivre le raisonnement du modèle.

Dans le cadre de notre pipeline CEEMDAN + BCNN, SHAP peut révéler quelles composantes IMF ou métriques spectrales extraites ont été déterminantes dans l'identification d'un défaut, même dans des cas de diagnostic difficile ou ambigu.




Figure IV. 17 Contribution des IMFs a la prédiction (SHAP).

La figure IV.17 présente un graphique SHAP synthétisant l'importance des différentes caractéristiques extraites du signal de vibration – en l'occurrence, les énergies des composantes IMF – dans la décision du modèle. Cette visualisation permet de comprendre comment chaque caractéristique influence localement et globalement les prédictions du classifieur, en particulier lorsqu'il s'agit d'identifier un défaut donné, tel qu'une dent ébréchée ou une usure progressive.

L'axe vertical indique les différentes caractéristiques (par exemple, IMF\_2\_energy, IMF\_4\_energy, etc.), classées par ordre décroissant d'impact moyen sur les décisions du modèle. L'axe horizontal quantifie la valeur SHAP pour chaque point de données, c'est-à-dire l'influence de cette caractéristique sur la sortie du modèle. Des valeurs positives tendent à orienter la décision vers la classe prédite (défaut détecté), tandis que des valeurs négatives la tirent vers la classe opposée (normal ou absence de défaut). La couleur de chaque point encode la valeur brute de la caractéristique correspondante : rouge pour une valeur élevée, bleu pour une valeur faible.


On observe que les variables IMF\_2\_energy et IMF\_4\_energy sont les plus influentes dans les décisions du modèle. Leurs valeurs SHAP sont dispersées sur une large plage, ce qui indique que ces composantes jouent un rôle crucial dans la différenciation des défauts. Des valeurs élevées de ces IMFs (points rouges à droite) sont fortement corrélées à des prédictions positives, ce qui suggère qu'elles capturent des signatures vibratoires caractéristiques du défaut étudié. En revanche, les composantes IMF\_6\_energy et IMF\_8\_energy ont des contributions très faibles, souvent centrées autour de zéro, indiquant qu'elles sont peu informatives dans la prise de décision. Cela pourrait justifier leur exclusion ou une réévaluation de leur intérêt dans l'architecture globale.

Les autres composantes, telles que IMF\_1\_energy, IMF\_5\_energy et IMF\_7\_energy, occupent une position intermédiaire. Elles n'ont pas une influence aussi marquée que les IMFs dominantes, mais semblent apporter une contribution complémentaire ou stabilisante, utile pour renforcer les décisions dans certains cas ambigus.

### IV.8.2.2 LIME – Local Interpretable Model-Agnostic Explanations

LIME adopte une approche complémentaire. Plutôt que de calculer des contributions exactes, il perturbe localement les entrées autour d'un échantillon donné (par exemple, en modifiant les amplitudes d'IMFs ou en injectant du bruit) pour observer l'évolution des prédictions. À partir de cette analyse de sensibilité, LIME construit un modèle local simple (souvent linéaire) qui approxime le comportement du modèle complexe dans un voisinage restreint. LIME est particulièrement utile pour :

- Évaluer la robustesse locale de la décision ;
- Visualiser l'effet marginal de chaque variable d'entrée ;
- Identifier des comportements inattendus ou instables, par exemple dans des cas à forte incertitude épistémique.



**Figure IV. 18** Interprétation locale LIME d'une prédiction de défaut.

La figure IV.18 présente une explication locale générée par la méthode pour une instance classée comme « défaut » par le modèle de diagnostic. Sur la figure, les caractéristiques sont affichées sur l'axe vertical avec les intervalles de valeurs qu'elles prennent pour l'instance analysée. L'axe horizontal indique leur poids dans la décision : une contribution positive (barres vertes) signifie que cette variable a poussé le modèle à classer l'instance comme un défaut, tandis qu'une contribution négative (barres rouges) a eu l'effet inverse.

L'analyse montre que deux caractéristiques principales ont fortement influencé la décision : la variable IMF\_2\_energy <= -0.59 et IMF\_4\_energy > 0.60 présentent les contributions positives les plus élevées. Cela signifie que dans cet exemple, la combinaison d'une faible énergie dans IMF 2 et d'une forte énergie dans IMF 4 a convaincu le modèle de la présence d'un défaut. Ces composantes sont probablement associées à des signatures vibratoires spécifiques, telles que des modulations ou impulsions caractéristiques d'un endommagement localisé. En revanche, plusieurs autres caractéristiques, comme les valeurs moyennes ou faibles de IMF\_1\_energy, IMF\_3\_energy, IMF\_5\_energy, IMF\_6\_energy et IMF\_7\_energy, ont exercé un effet modérateur ou négatif, réduisant la probabilité attribuée au défaut. Cela reflète une ambiguïté dans la structure du signal, potentiellement liée à des composantes non typiques ou à un cas limite entre défauts proches. La variable IMF\_8\_energy, bien que légèrement positive, a un impact négligeable et semble peu informative dans cette configuration.

### IV.8.3 Bénéfices pour l'adoption industrielle

L'intégration d'outils d'interprétation comme les cartes de saillance, les activations internes, ou les méthodes agnostiques telles que SHAP et LIME représente une avancée essentielle pour la transition des systèmes de diagnostic automatisés vers des environnements industriels

réels. En effet, dans les secteurs sensibles tels que l'aéronautique, l'énergie ou la production industrielle, la traçabilité des décisions prises par l'intelligence artificielle est une exigence incontournable, tant pour des raisons de conformité réglementaire que de sécurité opérationnelle. Ces outils offrent une visibilité directe sur les mécanismes internes du modèle, permettant de documenter, valider et justifier chaque prédiction. Ils facilitent ainsi l'audit technique des algorithmes, le contrôle qualité des déploiements, ainsi que leur acceptation par les organismes de certification ou de normalisation.

Par ailleurs, l'adoption de modèles explicables contribue à lever les freins organisationnels liés à la méfiance vis-à-vis de l'IA. En permettant aux ingénieurs de maintenance, responsables fiabilité et opérateurs de terrain de comprendre comment et pourquoi un défaut a été détecté, ces outils renforcent la confiance et le sentiment de contrôle. L'IA n'est alors plus perçue comme une boîte noire arbitraire, mais comme un système collaboratif transparent, dont les décisions peuvent être confrontées à l'expertise humaine. Enfin, ces approches ouvrent la voie à une coopération homme-machine augmentée, dans laquelle le modèle agit comme un assistant décisionnel : il propose une prédiction, fournit un niveau de confiance, explique les raisons de son choix, et laisse à l'expert humain la possibilité d'approuver, corriger ou enrichir la décision. Ce paradigme hybride constitue un levier stratégique pour déployer des solutions d'IA robustes, évolutives et éthiquement acceptables dans des environnements industriels complexe.

### IV.9 Limitations et perspectives d'amélioration

Malgré les performances prometteuses de l'architecture proposée, certaines limitations techniques doivent être prises en compte afin d'évaluer de manière réaliste sa portée et sa transférabilité. L'une des premières contraintes est la forte dépendance à la qualité du signal d'entrée, notamment aux conditions de mesure (type de capteurs, bruit ambiant, rigidité de montage). Dans des environnements industriels plus bruyants ou instables, les performances du pipeline CEEMDAN + BCNN pourraient être affectées. De plus, le bon fonctionnement de la décomposition CEEMDAN repose sur un calibrage précis de ses hyperparamètres (nombre d'ensembles, amplitude du bruit), dont la robustesse n'est pas systématiquement garantie en dehors du domaine testé. Enfin, la complexité computationnelle de l'architecture multi-branche représente un frein potentiel pour son déploiement embarqué en temps réel sur des plateformes à ressources limitées, comme les automates ou les microcontrôleurs.

Sur le plan expérimental, les résultats obtenus reposent sur le jeu de données PHM2009, lequel, bien qu'exhaustif dans sa structure, est spécifique à une seule géométrie de boîte de vitesses. La diversité des défauts est limitée, notamment en ce qui concerne les cas composés ou évolutifs. Le nombre d'occurrences pour certains défauts reste faible, ce qui peut induire un déséquilibre latent dans l'apprentissage. Par ailleurs, les signaux utilisés dans cette étude sont exclusivement vibratoires, ce qui ne reflète pas nécessairement la réalité des systèmes industriels, souvent équipés de capteurs multi-physiques (courant, acoustique, température, etc.). L'absence de tests sur des signaux multi-sources empêche d'évaluer la complémentarité de ces modalités dans le cadre d'un diagnostic robuste.

Ces limitations ouvrent néanmoins plusieurs perspectives de recherche intéressantes. Une première piste consiste à intégrer des données multi-modalités, telles que les signaux acoustiques ou électriques, afin d'enrichir la représentation des défauts et d'améliorer la

résilience aux perturbations. Par ailleurs, l'architecture bayésienne pourrait être adaptée dans des versions allégées et optimisées pour les contraintes de calcul embarqué, en explorant par exemple les approches à base de réseaux sparse, de quantification ou de distillation de connaissances. Il serait également pertinent de valider l'approche sur d'autres bases de données publiques ou industrielles confidentielles, afin d'évaluer sa généricité et sa capacité à s'adapter à d'autres contextes mécaniques.

Enfin, dans une perspective plus exploratoire, des travaux futurs pourraient s'intéresser à la détection de défauts non vus ou émergents à l'aide de modèles non-supervisés ou semi-supervisés, tels que les auto-encodeurs probabilistes, les modèles de diffusion ou les techniques d'apprentissage contrastif. Ces approches permettraient de dépasser le cadre strict de la classification supervisée et de concevoir des systèmes de maintenance prédictive véritablement autonomes et adaptatifs.

### IV.10 Conclusion

Ce chapitre a présenté une étude approfondie sur l'application d'une architecture Bayésienne Convolutionnelle Multi-branche (BCNN-MB), couplée à une décomposition CEEMDAN, pour le diagnostic avancé de défauts dans des systèmes d'engrenage complexes à partir du jeu de données PHM2009. L'objectif central était de dépasser les limites des approches classiques de classification en proposant une stratégie à la fois robuste, interprétable, spécialisée et sensible à l'incertitude.

Dans un premier temps, l'analyse des défauts représentés dans le jeu PHM2009 a permis de mettre en évidence la complexité intrinsèque de certaines classes de pannes (comme l'usure progressive, la dent ébréchée, ou le désalignement), ainsi que le recouvrement fréquentiel partiel entre leurs signatures vibratoires respectives. L'étude a confirmé que ces défauts sont difficilement isolables dans le domaine temporel ou fréquentiel brut, ce qui justifie pleinement le recours à des techniques adaptatives comme CEEMDAN, capable de produire des composantes IMF intrinsèquement liées à la structure spectro-temporelle du signal.

Ensuite, une analyse de sensibilité approfondie des paramètres CEEMDAN (nombre d'ensembles et amplitude de bruit) a permis d'identifier une zone optimale de fonctionnement ( $N \approx 400$ ,  $\varepsilon \approx 0.2$ ), assurant à la fois une séparation claire des modes, une reconstruction fidèle du signal d'origine, et une meilleure exploitabilité des IMF en entrée du classifieur. Cette phase a également mis en lumière les compromis computationnels et les effets de sur-décomposition, tout en apportant une justification objective au calibrage retenu.

L'un des apports majeurs de ce chapitre réside dans la comparaison systématique entre différentes méthodes de décomposition de signal (EMD, EEMD, CEEMD, VMD, WT, HVD), appliquées au même pipeline de diagnostic. Les résultats ont clairement démontré que CEEMDAN offre les performances les plus élevées en termes de F1-score, de robustesse au bruit et de stabilité, tout en maintenant une incertitude prédictive faible. Le tableau comparatif a permis de mettre en évidence les forces et faiblesses relatives de chaque méthode, contribuant à un choix éclairé de la solution la plus adaptée au contexte industriel. Sur le plan architectural, l'introduction du BCNN multi-branche a représenté une avancée stratégique majeure. Contrairement aux modèles monolithiques (CNN ou BCNN standard), cette architecture exploite la séparation fonctionnelle entre types de défauts, en allouant une branche dédiée à chaque catégorie. Cette approche a permis d'améliorer significativement la

capacité d'isolation des défauts, en particulier dans les cas de signaux composites ou de défauts combinés. L'évaluation comparative avec les architectures standards a mis en évidence un gain moyen de 6 à 8 points de F1-score, une réduction notable du surapprentissage et une meilleure stabilité de l'entraînement. Par ailleurs, l'interprétabilité de cette architecture, notamment via les cartes de saillance, les activations internes et les visualisations SHAP/LIME, a constitué un atout majeur pour une adoption industrielle réaliste.

L'intégration d'outils d'interprétation avancée a renforcé la dimension explicable du modèle. Ces visualisations ont permis de confirmer que les prédictions étaient fondées sur des caractéristiques physiques pertinentes (impulsions, modulations, harmoniques), et non sur des artefacts arbitraires. Les analyses d'incertitude, tant épistémiques qu'aléatoires, ont quant à elles fourni un cadre rigoureux pour la détection de cas à risque ou hors distribution, ouvrant la voie à un diagnostic plus sûr, plus fiable, et plus adaptatif.

Enfin, le chapitre s'est conclu par une réflexion critique sur les limitations techniques et expérimentales de l'approche, tout en identifiant plusieurs pistes d'amélioration et d'extension, notamment en matière de fusion de modalités, de généralisation inter-domaine, et de traitement de défauts inconnus. Ces perspectives constituent un tremplin méthodologique pour les travaux futurs et serviront de base pour le développement d'un pipeline intelligent de maintenance prédictive.

# CONCLUSION GÉNÉRALE

Ce manuscrit a exposé une démarche scientifique à la fois rigoureuse, structurée et résolument innovante, dont l'objectif principal est de faire progresser les capacités de diagnostic automatique des défauts complexes dans les systèmes de transmission mécanique. À travers une approche hybride combinant des techniques avancées de traitement du signal, en particulier les méthodes de décomposition adaptative – et des modèles d'intelligence artificielle probabiliste, notamment les réseaux de neurones convolutifs bayésiens, ce travail vise à dépasser les limitations actuelles des méthodes classiques. Il s'inscrit dans un contexte applicatif exigeant, caractérisé par la nature bruyante, non stationnaire et multi-source des données acquises en conditions réelles, ainsi que par la coexistence fréquente de défauts multiples ou évolutifs.

L'objectif central de ce travail était donc de concevoir un système de diagnostic automatisé qui ne soit pas seulement performant sur le plan des métriques de classification, mais qui soit également robuste face à l'incertitude, interprétable dans ses décisions, et adaptable aux contraintes des environnements industriels réels. Cela inclut notamment la capacité à gérer des signaux issus de capteurs vibratoires déployés dans des conditions variées (vitesse, charge, etc.), à identifier des défauts combinés, et à fournir un retour de confiance quant à la fiabilité des prédictions. Cette recherche vise ainsi à rapprocher les technologies d'intelligence artificielle des exigences opérationnelles de la maintenance conditionnelle, en apportant des outils analytiques concrets, vérifiables et exploitables dans des contextes critiques tels que les boîtes de vitesses, les lignes de production ou les systèmes embarqués.

Le Chapitre 1 a posé les fondations physiques, fonctionnelles et méthodologiques de cette étude en offrant un panorama complet et détaillé des différents défauts que l'on peut rencontrer dans les systèmes rotatifs industriels complexes. Cette première étape a été essentielle pour comprendre les mécanismes de défaillance caractéristiques affectant des composants critiques tels que les engrenages, les roulements à billes, les arbres de transmission, les paliers ou encore les accouplements. Le chapitre a passé en revue les principales anomalies mécaniques, parmi lesquelles figurent la cassure de dent, l'usure progressive, la fatigue, le désalignement, ainsi que l'excentricité. Chacun de ces défauts étant analysé du point de vue de ses origines physiques, de son évolution potentielle, et surtout de sa manifestation dans les signaux vibratoires mesurés par capteurs.

Au-delà de la simple taxonomie des défauts, le chapitre a également introduit les principales méthodes de traitement du signal utilisées historiquement dans le domaine du diagnostic vibratoire. Il y est question des transformations fréquentielles classiques (FFT, ondelettes), des méthodes d'analyse d'enveloppe, mais aussi des limites de ces outils face aux signaux non stationnaires et à faible rapport signal/bruit. En parallèle, une introduction critique a été faite sur les approches empiriques qui peuvent être employées afin d'améliorer l'analyse des signaux non stationnaires et non linéaires. Elles permettent une décomposition automatique des signaux vibratoires, sans nécessiter l'intervention d'un expert ou une connaissance approfondie des signaux, contrairement aux méthodes classiques de traitement du signal.

## Conclusion générale

---

Le Chapitre 2 a constitué une étape charnière du manuscrit, en s'attachant à présenter de manière rigoureuse et structurée l'état de l'art des approches de classification et de diagnostic automatisé basés sur l'intelligence artificielle. Ce chapitre a ouvert la voie vers la formalisation d'une stratégie algorithmique hybride, en examinant successivement les méthodes classiques et les approches modernes de diagnostic vibratoire. Les limites des méthodes classiques ont été clairement identifiées dès lors que les signaux deviennent non stationnaires, bruités ou issus de défauts multiples, comme c'est fréquemment le cas dans les systèmes industriels. Face à cette complexité croissante, le chapitre s'est orienté vers l'étude des approches fondées sur l'apprentissage machine et l'apprentissage profond (deep learning). Une attention particulière a été portée aux réseaux de neurones convolutifs (CNN), aujourd'hui largement adoptés pour la classification automatique de signaux, d'images et de données temporelles. Leur capacité à apprendre automatiquement des représentations discriminantes sans nécessiter de phase d'extraction manuelle de caractéristiques en fait des candidats de choix pour le diagnostic vibratoire. Toutefois, le chapitre a également souligné les limites importantes des CNNs standards, notamment leur manque de robustesse face aux données bruitées, leur sensibilité au sur-apprentissage lorsqu'ils sont confrontés à des bases de données de taille réduite, et surtout leur manque d'interprétabilité, un critère pourtant essentiel dans les environnements industriels critiques où la justification des décisions algorithmiques est une exigence forte.

Dans cette optique, le chapitre a introduit les réseaux de neurones bayésiens (Bayesian Neural Networks – BNN), qui proposent une alternative probabiliste aux architectures classiques. Ces modèles enrichissent le cadre de l'apprentissage profond en intégrant une modélisation de l'incertitude à travers une estimation probabiliste des poids du réseau, ce qui permet non seulement de mieux évaluer la confiance dans les prédictions, mais aussi de mieux résister aux cas ambigus ou hors distribution. Parmi les différentes familles de réseaux bayésiens, les Bayesian CNNs ont été mis en avant pour leur capacité à conjuguer la puissance du deep learning avec une explicabilité accrue et une meilleure généralisation en contexte incertain. Ainsi, ce chapitre 2 a servi de fondation théorique et méthodologique au travail de recherche développé dans les sections ultérieures. Il a permis de poser les bases modèle d'apprentissage probabiliste structuré et interprétable (BCNN).

Le Chapitre 3 a constitué une étape charnière du manuscrit, posant les bases expérimentales nécessaires à l'introduction des méthodes avancées développées par la suite. Il s'est concentré exclusivement sur l'analyse comparative de différentes variantes de traitement du signal, en lien avec des réseaux de neurones convolutifs standards (CNN) et leurs équivalents bayésiens (BCNN), dans une architecture monolithique unique, c'est-à-dire sans division en branches spécialisées. L'objectif de ce chapitre était double : d'une part, identifier les configurations les plus pertinentes pour la décomposition des signaux vibratoires complexes issus des systèmes mécaniques industriels, et d'autre part, évaluer les performances fondamentales des CNN et BCNN monolithiques avant l'introduction d'une architecture multi-branche.

Dans ce cadre, quatre méthodes de décomposition adaptative ont été explorées en profondeur : EMD, EEMD, CEEMD et CEEMDAN. Ces techniques, bien qu'appartenant à la même famille, présentent des différences substantielles en termes de robustesse au bruit, de séparation des modes, et de qualité des composantes extraites (IMFs). En les comparant systématiquement, ce chapitre a permis de démontrer l'intérêt particulier de CEEMDAN, qui

## Conclusion générale

---

s'est révélée offrir les meilleurs compromis entre précision temporelle et stabilité spectrale, constituant ainsi une base de choix pour les expérimentations ultérieures.

Les réseaux de neurones convolutifs ont été appliqués sur les signaux traités par chacune de ces méthodes, permettant une comparaison croisée entre traitement du signal et architecture d'apprentissage. Le BCNN, avec son approche probabiliste fondée sur l'inférence variationnelle, a permis de capturer non seulement les performances de classification mais également l'incertitude associée aux décisions, même dans un cadre monolithique. L'analyse des résultats sur les bases de données CWRU (Case Western Reserve University) et PU (Paderborn University) a permis de valider la généralité de la méthode sur des contextes industriels variés, renforçant la solidité des conclusions.

Ce chapitre a ainsi joué un rôle fondamental dans la structuration de la suite du manuscrit. Il a permis d'identifier les limites de ces méthodes, tout en validant l'intérêt de la modélisation bayésienne et des décompositions CEEMDAN comme briques de base. Ces constats ont naturellement conduit à l'introduction, dans le chapitre suivant, d'une architecture multi-branche plus fine et interprétable, conçue pour adresser les limitations observées et offrir un diagnostic plus fiable, granulaire et explicable.

Le Chapitre 4 a marqué l'aboutissement du travail expérimental en proposant une architecture avancée de réseau de neurones convolutifs bayésien multi-branche (BCNN-MB), conçue pour surmonter les limitations identifiées dans le chapitre précédent. Cette architecture innovante repose sur un principe de spécialisation structurelle : chaque branche est dédiée à la détection d'un type de défaut particulier (usure, cassure, piquûre, désalignement, etc.), permettant au modèle de mieux isoler les caractéristiques propres à chaque anomalie, même en présence de signaux mixtes ou fortement bruités.

Pour valider cette approche, le modèle a été testé sur le jeu de données de référence PHM 2009 Gearbox Challenge, largement reconnu dans la communauté scientifique pour sa richesse et sa complexité. Ce jeu de données se distingue notamment par la présence de défauts multiples et combinés, affectant simultanément plusieurs composants mécaniques comme les engrenages, les roulements internes ou externes, ainsi que les arbres de transmission. Cette configuration réaliste, incluant des cas de défauts composés (compound faults), constitue un excellent banc d'essai pour évaluer la capacité du modèle à isoler et identifier des anomalies enchevêtrées, comme cela se produit fréquemment dans des environnements industriels complexes.

Le chapitre a proposé une analyse comparative rigoureuse entre quatre configurations : CNN monolithique, BCNN monolithique, CNN multi-branche et BCNN multi-branche. Cette comparaison a été menée à l'aide de plusieurs indicateurs de performance tels que le F1-score global et par classe, la robustesse aux perturbations bruitées, la stabilité de convergence, la sensibilité au sur-apprentissage, et surtout la capacité à estimer l'incertitude prédictive.

Les résultats expérimentaux ont mis en évidence une nette supériorité de l'approche multi-branche bayésienne, en particulier pour les défauts difficiles à discerner comme le pitting et l'usure progressive, qui sont souvent confondus dans les architectures monolithiques classiques. La spécialisation par défaut permet d'éviter les interférences entre classes proches, tandis que la modélisation bayésienne introduit une estimation quantitative de la fiabilité de

## Conclusion générale

---

chaque prédiction, ouvrant la voie à des mécanismes de rejet ou d'alerte intelligente. Ces résultats ont été consolidés par des visualisations détaillées telles que les courbes de convergence, les matrices de confusion, les distributions d'incertitude, et des analyses par défaut à l'aide d'outils comme SHAP et LIME.

Au-delà des performances brutes, le chapitre a également examiné les conditions de déploiement réel de l'architecture proposée. Une évaluation de la latence d'inférence, de l'empreinte mémoire, et de la compatibilité avec les contraintes des systèmes embarqués industriels a été réalisée, montrant que malgré la complexité structurelle du modèle, une implémentation optimisée restait envisageable sur du matériel embarqué moderne. Un pipeline complet de diagnostic temps réel a été simulé, incluant l'acquisition des signaux, leur décomposition CEEMDAN, le passage dans chaque branche du réseau BCNN, et la fusion des prédictions avec gestion de l'incertitude. Enfin, une attention particulière a été portée à l'interprétabilité du modèle, condition indispensable à son adoption dans un cadre industriel exigeant. Des outils d'explicabilité avancée ont été utilisés pour auditer et expliquer les décisions du modèle : cartes de saillance, heatmaps d'activation, visualisations locales avec SHAP et LIME. Ces visualisations permettent non seulement de justifier les prédictions mais aussi d'offrir une traçabilité complète du raisonnement algorithmique, renforçant la transparence et la confiance des opérateurs humains. Ainsi, ce chapitre démontre qu'un diagnostic basé sur des réseaux de neurones profonds peut être à la fois performant, fiable, et explicable, et qu'une telle approche est pleinement compatible avec les exigences d'un déploiement en milieu industriel critique.

Au terme de ce travail de recherche, plusieurs contributions scientifiques et méthodologiques majeures émergent clairement, tant par leur originalité que par leur pertinence pour les défis actuels de la maintenance prédictive dans l'industrie. L'apport principal réside dans le développement d'un cadre hybride novateur combinant une décomposition avancée du signal (CEEMDAN) avec une architecture de réseau de neurones convolutif bayésien multi-branche (BCNN-MB). Cette intégration n'est pas uniquement technique ; elle traduit une véritable évolution conceptuelle dans la manière d'aborder le diagnostic de défauts complexes, souvent composites, dans des environnements industriels réels, bruités et dynamiquement instables. L'architecture proposée a démontré sa capacité à isoler et identifier des anomalies fortement entrelacées, comme celles issues des engrenages, roulements et arbres de transmission, en s'appuyant sur la spécialisation structurelle de ses branches et sur une modélisation probabiliste rigoureuse via l'inférence variationnelle (VI). Cette dernière permet d'estimer l'incertitude associée à chaque prédiction, ce qui constitue un levier fondamental pour améliorer la fiabilité, la robustesse, mais aussi la traçabilité du diagnostic dans des contextes industriels à fort enjeu de sécurité. En dotant chaque décision du modèle d'un niveau de confiance mesurable, on introduit une forme de "métacognition algorithmique" qui permet de déclencher des alertes, des rejets intelligents ou même des stratégies de maintenance adaptatives. La structure multi-branche représente également une avancée stratégique : elle offre une modularité dans l'apprentissage, en permettant à chaque sous-réseau de se spécialiser dans un type de défaut donné, tout en maintenant une architecture unifiée. Cela se traduit non seulement par une amélioration des performances de classification, notamment pour les défauts subtils ou fréquemment confondus comme l'usure progressive, mais aussi par une interprétabilité renforcée. Grâce à cette spécialisation, les visualisations générées (saliency maps, heatmaps, SHAP, LIME) sont plus claires, plus localisées, et plus alignées

## Conclusion générale

---

avec les phénomènes physiques réels, facilitant ainsi l'auditabilité et la validation du modèle par des experts métiers. Ce socle scientifique ouvre naturellement plusieurs perspectives de recherche prometteuses :

1. **Généralisation à d'autres jeux de données et cas d'usage :** Il serait pertinent d'évaluer la robustesse et la transférabilité du modèle sur d'autres bases de données industrielles, comme celles de Southeast University (SEU), ou sur des données issues de bancs d'essai réels et de lignes de production. Cela permettrait d'évaluer la capacité du modèle à s'adapter à des géométries différentes, des régimes de fonctionnement variés, et des défauts inédits, tout en maintenant son pouvoir discriminant et sa stabilité.
2. **Fusion multi-capteurs et diagnostic multi-modal :** La combinaison de données vibratoires avec d'autres modalités (courant moteur, acoustique, température, etc.) constitue une piste naturelle pour améliorer la couverture diagnostique du système. Un modèle multimodal pourrait non seulement accroître la précision des prédictions, mais aussi fournir une redondance informationnelle utile pour détecter des défauts masqués dans une modalité mais visibles dans une autre. La structure multi-branche pourrait être adaptée pour intégrer une branche par modalité, ouvrant la voie à un diagnostic sensoriel fusionné et collaboratif.
3. **Réduction de la complexité pour les applications embarquées :** L'un des défis actuels réside dans l'adaptation de ce type de modèle aux contraintes des systèmes embarqués industriels (temps réel, faible consommation, mémoire limitée). Plusieurs stratégies d'optimisation sont envisageables : pruning de branches non sollicitées, quantification des poids, compression des couches, ou encore exploration d'alternatives légères comme les Bayesian Neural Networks distillés ou les modèles à inférence rapide. L'objectif est d'obtenir un compromis optimal entre expressivité du modèle, qualité de prédiction, et efficacité computationnelle.
4. **Détection non supervisée et adaptative de défauts émergents :** L'aspect bayésien du modèle ouvre également la voie à des approches non supervisées ou semi-supervisées pour la détection de défauts inconnus, via l'analyse des incertitudes élevées ou par l'emploi de modèles génératifs (autoencodeurs variationnels, modèles de diffusion, GANs probabilistes). Ces techniques permettraient d'implémenter une veille automatisée, capable de détecter des dérives progressives ou des cas hors distribution (out-of-distribution), et d'alerter les opérateurs sans nécessiter d'étiquetage préalable.
5. **Intégration dans des systèmes collaboratifs homme-machine :** Enfin, les outils d'interprétabilité développés dans ce travail pourraient constituer un socle idéal pour renforcer la coopération entre les modèles d'IA et les experts humains. Plutôt que de remplacer les opérateurs, le système devient un assistant intelligent capable d'expliquer ses choix, de contextualiser ses décisions et de guider l'utilisateur dans la validation ou la prise de décision corrective.

En définitive, ce manuscrit s'inscrit dans une trajectoire résolument tournée vers l'industrie 4.0, en proposant des solutions robustes, explicables et adaptables pour répondre aux défis de la maintenance prédictive dans des environnements critiques. Il démontre que l'union entre traitement du signal non stationnaire, apprentissage profond bayésien, et conception modulaire des architectures neurales permet d'envisager des systèmes de diagnostic

## Conclusion générale

---

intelligents, évolutifs et fiables. Ces travaux offrent ainsi une base solide pour de futures explorations scientifiques et industrielles, et appellent à une nouvelle génération de modèles plus transparents, collaboratifs et conscients de leurs propres limites.

## Bibliographie

- [1] S. Wajdi, K. Jelassi, et J. Khaled, Détection d'un défaut localisé d'une transmission par engrenage couplée avec une machine asynchrone Thème: Electrotechnique et Electronique de Puissance Modélisation et commande des machines électriques Détection d'un défaut localisé d'une transmission par engrenage couplée avec une machine asynchrone. 2008.
- [2] H. TAIBI et H. SAKMECHE, « Identification du défaut de balourd par analyse vibratoire », Abdelhamid Ibn Badis University, Mostaganem, 2020. [En ligne]. Disponible sur: [chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/http://e-biblio.univ-mosta.dz/bitstream/handle/123456789/20245/PFE\\_TAIBI\\_SAKMECHE.pdf](chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/http://e-biblio.univ-mosta.dz/bitstream/handle/123456789/20245/PFE_TAIBI_SAKMECHE.pdf)
- [3] Y. Xiao, J. Xue, L. Zhang, Y. Wang, et M. Li, « Misalignment Fault Diagnosis for Wind Turbines Based on Information Fusion », *Entropy*, vol. 23, n° 2, Art. n° 2, févr. 2021, doi: 10.3390/e23020243.
- [4] R. V. Bhandare, V. M. Phalle, V. C. Handikherkar, et S. S. Patil, « Weighted Aggregation Approach and Tree-Based Ensemble Technique for Anomaly Detection and Fault Severity Analysis in Gear Fault Diagnosis », *J. Fail. Anal. Prev.*, vol. 25, n° 2, p. 864-876, avr. 2025, doi: 10.1007/s11668-025-02148-0.
- [5] D. Hyun, T.-J. Kang, et J. Kim, « Fault Diagnosis of Belt Driving Power Transfer Facility Using Vibration Analysis », *J. Electr. Eng. Technol.*, vol. 16, n° 4, p. 2257-2264, juill. 2021, doi: 10.1007/s42835-021-00711-x.
- [6] « Gearbox fault diagnosis using data fusion based on self-organizing map neural network ». Consulté le: 20 février 2025. [En ligne]. Disponible sur: <https://journals.sagepub.com/doi/epub/10.1177/1550147720923476>
- [7] J. Liu et T. Wang, « Application of vibration signal analysis method in the fault diagnosis of mechanical gearboxes », doi: 10.29354/diag/199976.
- [8] M. Azamfar, J. Singh, I. Bravo-Imaz, et J. Lee, « Multisensor data fusion for gearbox fault diagnosis using 2-D convolutional neural network and motor current signature analysis », *Mech. Syst. Signal Process.*, vol. 144, p. 106861, oct. 2020, doi: 10.1016/j.ymssp.2020.106861.
- [9] H. Zhang, L. Guo, G. Wang, M. Li, et X. Yuan, « Noise Reduction and Reconstruction of Acoustic Emission Signals from Industrial Robot Gearboxes Based on Wavelet Transform and CEEMDAN », in *2023 6th International Conference on Robotics, Control and Automation Engineering (RCAE)*, nov. 2023, p. 285-289. doi: 10.1109/RCAE59706.2023.10398776.
- [10] J. Álamo, M. J. Duran, et F. Muñoz, « Analysis of the Gearbox Oil Maintenance Procedures in Wind Energy », *Energies*, vol. 13, p. 3414, juill. 2020, doi: 10.3390/en13133414.
- [11] Y. Li, J. X. Gu, D. Zhen, M. Xu, et A. Ball, « An Evaluation of Gearbox Condition Monitoring Using Infrared Thermal Images Applied with Convolutional Neural Networks », *Sensors*, vol. 19, n° 9, Art. n° 9, janv. 2019, doi: 10.3390/s19092205.
- [12] O. DJEBILI, « Contribution à la maintenance prédictive par analyse vibratoire des composants mécaniques tournants. Application aux butées à billes soumises à la fatigue de contact de roulement. », Université Mhamed Bougara de Boumerdés, 2013.

## Bibliographie

---

- [13] S. Setti, S. M., et N. Vps, « Vibration Analysis of Gearbox Fault Diagnosis using DWT and Statistical Features », *J. Eng. Res.*, vol. 10, n° 3B, Art. n° 3B, 2022, doi: 10.36909/jer.10465.
- [14] S. Mukherjee, V. Kumar, S. Sarangi, et T. K. Bera, « Gearbox Fault Diagnosis using Advanced Computational Intelligence », *Procedia Comput. Sci.*, vol. 167, p. 1594-1603, janv. 2020, doi: 10.1016/j.procs.2020.03.370.
- [15] S. Xue et I. Howard, « Torsional vibration signal analysis as a diagnostic tool for planetary gear fault detection », *Mech. Syst. Signal Process.*, vol. 100, p. 706-728, févr. 2018, doi: 10.1016/j.ymsp.2017.07.038.
- [16] M. Xia, Z. Mao, R. Zhang, B. Jiang, et M. Wei, « A New Compound Fault Diagnosis Method for Gearbox Based on Convolutional Neural Network », in *2020 IEEE 9th Data Driven Control and Learning Systems Conference (DDCLS)*, nov. 2020, p. 1077-1083. doi: 10.1109/DDCLS49620.2020.9275264.
- [17] E. Bechhoefer et M. Kingsley, « A Review of Time Synchronous Average Algorithms », *Annu. Conf. PHM Soc.*, vol. 1, n° 1, Art. n° 1, 2009, Consulté le: 25 mai 2025. [En ligne]. Disponible sur: <https://www.papers.phmsociety.org/index.php/phmconf/article/view/1666>
- [18] S. U. Jan, Y.-D. Lee, J. Shin, et I. Koo, « Sensor Fault Classification Based on Support Vector Machine and Statistical Time-Domain Features », *IEEE Access*, vol. 5, p. 8682-8690, 2017, doi: 10.1109/ACCESS.2017.2705644.
- [19] H. Ahmadi et A. Moosavian, « Fault Diagnosis of Journal-Bearing of Generator Using Power Spectral Density and Fault Probability Distribution Function », in *Innovative Computing Technology*, P. Pichappan, H. Ahmadi, et E. Ariwa, Éd., Berlin, Heidelberg: Springer, 2011, p. 30-36. doi: 10.1007/978-3-642-27337-7\_4.
- [20] J. Guo, Y. Li, et J. Xiang, « An improved cepstrum analysis method to diagnose faults in bearings », in *2021 7th International Conference on Condition Monitoring of Machinery in Non-Stationary Operations (CMMNO)*, juin 2021, p. 240-243. doi: 10.1109/CMMNO53328.2021.9467663.
- [21] Q. Zhang et L. Deng, « An Intelligent Fault Diagnosis Method of Rolling Bearings Based on Short-Time Fourier Transform and Convolutional Neural Network », *J. Fail. Anal. Prev.*, vol. 23, n° 2, p. 795-811, avr. 2023, doi: 10.1007/s11668-023-01616-9.
- [22] R. Yan et al., « Wavelet transform for rotary machine fault diagnosis: 10 years revisited », *Mech. Syst. Signal Process.*, vol. 200, p. 110545, oct. 2023, doi: 10.1016/j.ymsp.2023.110545.
- [23] S. Zhang, J. Zhou, E. Wang, H. Zhang, M. Gu, et S. Pirttikangas, « State of the art on vibration signal processing towards data-driven gear fault diagnosis », *IET Collab. Intell. Manuf.*, vol. 4, n° 4, p. 249-266, 2022, doi: 10.1049/cim2.12064.
- [24] Y. Lei, J. Lin, Z. He, et M. J. Zuo, « A review on empirical mode decomposition in fault diagnosis of rotating machinery », *Mech. Syst. Signal Process.*, vol. 35, n° 1, p. 108-126, févr. 2013, doi: 10.1016/j.ymsp.2012.09.015.
- [25] M. J. Hasan et al., « Gearbox Fault Diagnostics: An Evaluation of Fast-Fourier Transform-Based Extracted Features with Support Vector Machine Classifier », in *RiTA 2020*, E. Chew, A. P. P. Abdul Majeed, P. Liu, J. Platts, H. Myung, J. Kim, et J.-H. Kim, Éd., Singapore: Springer, 2021, p. 409-413. doi: 10.1007/978-981-16-4803-8\_40.
- [26] Z. Yu, C. Yi, X. Chen, et T. Huang, « Adaptive multiple second-order synchrosqueezing wavelet transform and its application in wind turbine gearbox fault diagnosis », *Meas. Sci. Technol.*, vol. 33, n° 1, p. 015110, nov. 2021, doi: 10.1088/1361-6501/ac38ee.

## Bibliographie

---

- [27] S. Tian, X. Bian, Z. Tang, K. Yang, et L. Li, « Fault Diagnosis of Gas Pressure Regulators Based on CEEMDAN and Feature Clustering », *IEEE Access*, vol. 7, p. 132492-132502, 2019, doi: 10.1109/ACCESS.2019.2941497.
- [28] Z. Feng, Z. Dong, et M. Zuo, « Adaptive Mode Decomposition Methods and Their Applications in Signal Analysis for Machinery Fault Diagnosis: A Review With Examples », *IEEE Access*, vol. 5, p. 24301-24331, oct. 2017, doi: 10.1109/ACCESS.2017.2766232.
- [29] N. Huang, « Empirical Mode Decomposition and Hilbert Spectral Analysis », févr. 1998.
- [30] N. Huang et al., « The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis », *Proc. R. Soc. Lond. Ser. Math. Phys. Eng. Sci.*, vol. 454, p. 903-995, mars 1998, doi: 10.1098/rspa.1998.0193.
- [31] D. Zhang et al., « A Novel Wind Turbine Rolling Element Bearing Fault Diagnosis Method Based on CEEMDAN and Improved TFR Demodulation Analysis », *Energies*, vol. 17, n° 4, p. 819, févr. 2024, doi: 10.3390/en17040819.
- [32] R. Ziani, A. Hammami, F. Chaari, A. Felkaoui, et M. Haddar, « Gear fault diagnosis under non-stationary operating mode based on EMD, TKEO, and Shock Detector », *Comptes Rendus Mécanique*, vol. 347, n° 9, p. 663-675, sept. 2019, doi: 10.1016/j.crme.2019.08.003.
- [33] S. Mukherjee, V. Kumar, S. Sarangi, et T. K. Bera, « An Improved Signal Pre-Processing Method for Gearbox Fault Features Extraction », *Procedia Comput. Sci.*, vol. 167, p. 1604-1614, janv. 2020, doi: 10.1016/j.procs.2020.03.371.
- [34] Y. Liu et L. Cao, « Fault Diagnosis of Gear with Stress Wave Signal Based on EMD\_CDBN », in *2024 IEEE International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, juill. 2024, p. 100-105. doi: 10.1109/SDPC62810.2024.10707715.
- [35] « Gear Fault Diagnosis Using SVM Based on Empirical Mode Decomposition | IEEE Conference Publication | IEEE Xplore ». Consulté le: 29 avril 2025. [En ligne]. Disponible sur: <https://ieeexplore-ieee-org.snd11.arn.dz/document/10111852>
- [36] F. Zhao, D. Zhen, X. Yu, X. Liu, W. Hu, et J. Ding, « Bearing Fault Diagnosis Method Based on EMD and Multi-channel Convolutional Neural Network », in *Proceedings of TEPEN 2022*, Springer, Cham, 2023, p. 458-468. doi: 10.1007/978-3-031-26193-0\_39.
- [37] S. Jing, J. Yuan, X. Li, et J. Leng, « Weak Fault Feature Identification for Rolling Bearing Based on EMD and Spectral Kurtosis Method », in *2018 International Conference on Information Systems and Computer Aided Education (ICISCAE)*, juill. 2018, p. 235-239. doi: 10.1109/ICISCAE.2018.8666841.
- [38] « Fault Separation and Detection for Compound Bearing-Gear fault Condition Based on Decomposition of Marginal Hilbert Spectrum | IEEE Journals & Magazine | IEEE Xplore ». Consulté le: 29 avril 2025. [En ligne]. Disponible sur: <https://ieeexplore-ieee-org.snd11.arn.dz/document/8790685>
- [39] M. Gohari et M. H. Ghorbani, « Classification and Diagnosis of the Rotor Unbalance Parameters via Hybridized EMD and RF », *J. Vib. Eng. Technol.*, vol. 13, n° 4, p. 1-6, avr. 2025, doi: 10.1007/s42417-024-01590-y.
- [40] Z. Huo, Y. Zhang, et L. Shu, « A comparative study of WPD and EMD for shaft fault diagnosis », in *IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society*, oct. 2017, p. 8441-8446. doi: 10.1109/IECON.2017.8217482.

## Bibliographie

---

- [41] J. S. Smith, « The local mean decomposition and its application to EEG perception data », *J. R. Soc. Interface*, vol. 2, n° 5, p. 443-454, déc. 2005, doi: 10.1098/rsif.2005.0058.
- [42] Z. Jinde, C. Junsheng, et Y. Yang, « A rolling bearing fault diagnosis approach based on LCD and fuzzy entropy », *Mech. Mach. Theory*, vol. 70, p. 441-453, déc. 2013, doi: 10.1016/j.mechmachtheory.2013.08.014.
- [43] M. Feldman, « Time-varying vibration decomposition and analysis based on the Hilbert transform », *J. Sound Vib.*, vol. 295, n° 3, p. 518-530, août 2006, doi: 10.1016/j.jsv.2005.12.058.
- [44] J. Gilles, « Empirical Wavelet Transform », *IEEE Trans. Signal Process.*, vol. 61, p. 3999, août 2013, doi: 10.1109/TSP.2013.2265222.
- [45] D. Zosso et K. Dragomiretskiy, « Variational Mode Decomposition », *IEEE Trans. Signal Process.*, vol. 62, oct. 2013, doi: 10.1109/TSP.2013.2288675.
- [46] M. Civera et C. Surace, « A Comparative Analysis of Signal Decomposition Techniques for Structural Health Monitoring on an Experimental Benchmark », *Sensors*, vol. 21, n° 5, Art. n° 5, janv. 2021, doi: 10.3390/s21051825.
- [47] Z. Wu et N. Huang, « Ensemble Empirical Mode Decomposition: a Noise-Assisted Data Analysis Method », *Adv. Adapt. Data Anal.*, vol. 1, p. 1-41, janv. 2009, doi: 10.1142/S1793536909000047.
- [48] J. Wang et al., « Modified Singular Spectrum Decomposition and Its Application to Composite Fault Diagnosis of Gearboxes », *Sensors*, vol. 19, n° 1, Art. n° 1, janv. 2019, doi: 10.3390/s19010062.
- [49] D. Guo et al., « APPLICATION OF EEMD SINGULAR VALUE ENERGY SPECTRUM IN GEAR FAULT IDENTIFICATION ».
- [50] T. Wang, T. Zhu, L. Zhu, et P. He, « A Fault Diagnosis Method Based on EEMD and Statistical Distance Analysis », *Coatings*, vol. 11, n° 12, Art. n° 12, déc. 2021, doi: 10.3390/coatings11121459.
- [51] Y. Xu, H. Wang, F. Xu, S. Bi, et J. Ye, « A Sensor Data-Driven Fault Diagnosis Method for Automotive Transmission Gearboxes Based on Improved EEMD and CNN-BiLSTM », *Processes*, vol. 13, n° 4, Art. n° 4, avr. 2025, doi: 10.3390/pr13041200.
- [52] W. Hongjun, Z. Yuanlu, Z. Hui, et Y. Youjun, « Fault Diagnosis of Wind Turbine Gearbox based on EEMD Wavelet Threshold Denoising and CS-BP Neural Network », *zggx*, vol. 43, n° 1, p. 100-106, oct. 2022, doi: 10.16578/j.issn.1004.2539.2019.01.020.
- [53] C. Sun et Y. Liu, « Gearbox Noise Reduction and Diagnostic Analysis by EEMD Algorithm and DWT Fault Signal », in *2024 IEEE 6th International Conference on Power, Intelligent Computing and Systems (ICPICS)*, juill. 2024, p. 990-994. doi: 10.1109/ICPICS62053.2024.10796837.
- [54] H. Tayachi, H. Gabzili, et Z. Lachiri, « Detection of Local Gear Tooth Defect by a multi resolution analysis : DWT and EEMD », in *2022 IEEE Information Technologies & Smart Industrial Systems (ITSIS)*, juill. 2022, p. 1-6. doi: 10.1109/ITSIS56166.2022.10118416.
- [55] Y. Ou, D. Huang, C. Hu, H. Hao, J. Gong, et L. Zhao, « A Gear Fault Diagnosis Method Based on EEMD Cloud Model and PSO SVM », in *2021 IEEE 10th Data Driven Control and Learning Systems Conference (DDCLS)*, mai 2021, p. 860-865. doi: 10.1109/DDCLS52934.2021.9455486.
- [56] J.-R. Yeh, J.-S. Shieh, et N. Huang, « Complementary Ensemble Empirical Mode Decomposition: a Novel Noise Enhanced Data Analysis Method. », *Adv. Adapt. Data Anal.*, vol. 2, p. 135-156, avr. 2010, doi: 10.1142/S1793536910000422.

## Bibliographie

---

- [57] L. Zhao, W. Yu, et R. Yan, « Rolling Bearing Fault Diagnosis Based on CEEMD and Time Series Modeling », *Math. Probl. Eng.*, vol. 2014, n° 1, p. 101867, 2014, doi: 10.1155/2014/101867.
- [58] A. Athisayam et M. Kondal, « A multi-stage diagnosis method using CEEMD, ABC, and ANN for identifying compound gear-bearing faults », *Proc. Inst. Mech. Eng. Part C*, vol. 237, n° 8, p. 2030-2045, avr. 2023, doi: 10.1177/09544062221133757.
- [59] H. Guo, « Fault Diagnosis of Gearbox Based on Complementary Ensemble Empirical Mode Decomposition and Kernel Fuzzy Clustering Algorithm », vol. 2, n° 3, 2024.
- [60] S. Song, X. Zhang, et Y. Shen, « The Optimization of Resampling Parameters for CEEMD Planetary Gearbox Fault Diagnosis », *J. Xinjiang Univ. Sci. Ed. Chin. Engl.*, vol. 39, n° 2, p. 229-235, mars 2022, doi: 10.13568/j.cnki.651094.651316.2021.01.30.0001.
- [61] Z. Ke, C. Di, et X. Bao, « Adaptive Suppression of Mode Mixing in CEEMD Based on Genetic Algorithm for Motor Bearing Fault Diagnosis », *IEEE Trans. Magn.*, vol. 58, n° 2, p. 1-6, févr. 2022, doi: 10.1109/TMAG.2021.3082138.
- [62] X. Shang et al., « Research on Fault Diagnosis of UAV Rotor Motor Bearings Based on WPT-CEEMD-CNN-LSTM », *Machines*, vol. 13, n° 4, Art. n° 4, avr. 2025, doi: 10.3390/machines13040287.
- [63] G. Xiaoyun, F. Kunpeng, Z. Zeheng, G. Yiyuan, et D. Wenliao, « Multiple fault diagnosis for rolling bearings method employing CEEMD-GCN based on horizontal visibility graph », *Meas. Sci. Technol.*, vol. 34, n° 3, p. 035022, déc. 2022, doi: 10.1088/1361-6501/aca706.
- [64] Y. Xiao, Z. Zeng, Z. Deng, C. Lin, et Z. Xie, « An Integrated Approach Fusing CEEMD Energy Entropy and Sparrow Search Algorithm-Based PNN for Fault Diagnosis of Rolling Bearings », *Comput. Intell. Neurosci.*, vol. 2022, n° 1, p. 4835157, 2022, doi: 10.1155/2022/4835157.
- [65] Y. Zeng, Y. Qin, W. Yang, S. Liu, L. Huang, et R. Wang, « Rolling Bearing Fault Diagnosis Method with Adaptive CEEMD and Cyclic Spectrum Coherence », in *Proceedings of the 5th International Conference on Electrical Engineering and Information Technologies for Rail Transportation (EITRT) 2021*, Y. Qin, L. Jia, J. Liang, Z. Liu, L. Diao, et M. An, Éd., Singapore: Springer, 2022, p. 362-370. doi: 10.1007/978-981-16-9913-9\_41.
- [66] M. E. Torres, M. A. Colominas, G. Schlotthauer, et P. Flandrin, « A complete ensemble empirical mode decomposition with adaptive noise », in *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, mai 2011, p. 4144-4147. doi: 10.1109/ICASSP.2011.5947265.
- [67] M. Kuai, G. Cheng, Y. Pang, et Y. Li, « Research of Planetary Gear Fault Diagnosis Based on Permutation Entropy of CEEMDAN and ANFIS », *Sensors*, vol. 18, n° 3, Art. n° 3, mars 2018, doi: 10.3390/s18030782.
- [68] P. Goswami et R. N. Rai, « A Novel Methodology for Chipped Teeth and Worn Tooth Gear Fault Detection Using Minimum Entropy Deconvolution and CEEMDAN », *J. Vib. Eng. Technol.*, vol. 13, n° 1, p. 11, janv. 2025, doi: 10.1007/s42417-024-01622-7.
- [69] Y. Andhale et A. Parey, « Enhanced CEEMDAN-Based Deep Hybrid Model for Automated Gear Crack Detection », *J. Vib. Eng. Technol.*, vol. 12, n° 2, p. 2229-2251, déc. 2024, doi: 10.1007/s42417-024-01532-8.
- [70] F. Shi, J. Yu, M. Gu, K. Lei, et J. He, « Research on Wind Turbine Gearbox Fault Diagnosis Based on CEEMDAN and CVFDT », in *2021 11th International Conference on Power and Energy Systems (ICPES)*, déc. 2021, p. 713-717. doi: 10.1109/ICPES53652.2021.9683813.

## Bibliographie

---

- [71] F. Bie, T. Du, F. Lyu, M. Pang, et Y. Guo, « An Integrated Approach Based on Improved CEEMDAN and LSTM Deep Learning Neural Network for Fault Diagnosis of Reciprocating Pump », *IEEE Access*, vol. 9, p. 23301-23310, 2021, doi: 10.1109/ACCESS.2021.3056437.
- [72] L. Jiang, H. Tan, X. Li, L. Chen, et D. Yang, « CEEMDAN-Based Permutation Entropy: A Suitable Feature for the Fault Identification of Spiral-Bevel Gears », *Shock Vib.*, vol. 2019, n° 1, p. 7806015, 2019, doi: 10.1155/2019/7806015.
- [73] Y. Chen, Y. Liu, S. Han, et Y. Qiao, « Multi-component condition monitoring method for wind turbine gearbox based on adaptive noise reduction », *IET Renew. Power Gener.*, vol. 17, n° 10, p. 2613-2624, 2023, doi: 10.1049/rpg2.12772.
- [74] J. Lingli, C. Liman, T. Hongchuang, et L. Xuejun, « Fault Diagnosis of Spiral Bevel Gears Based on CEEMDAN Permutation Entropy », in *Advances in Asset Management and Condition Monitoring*, A. Ball, L. Gelman, et B. K. N. Rao, Éd., Cham: Springer International Publishing, 2020, p. 695-704. doi: 10.1007/978-3-030-57745-2\_58.
- [75] Y. Li, Z. Chen, et L. Wang, « A New Order Tracking Method for Fault Diagnosis of Gearbox under Non-Stationary Working Conditions Based on In Situ Gravity Acceleration Decomposition », *Appl. Sci.*, vol. 14, n° 11, Art. n° 11, janv. 2024, doi: 10.3390/app14114742.
- [76] A. Athisayam et M. Kondal, « A Smart CEEMDAN, Bessel Transform and CNN-Based Scheme for Compound Gear-Bearing Fault Diagnosis », *J. Vib. Eng. Technol.*, vol. 12, n° 1, p. 393-412, déc. 2024, doi: 10.1007/s42417-024-01422-z.
- [77] Q. Zhang, C. Song, et Y. Yuan, « Fault Diagnosis of Vehicle Gearboxes Based on Adaptive Wavelet Threshold and LT-PCA-NGO-SVM », *Appl. Sci.*, vol. 14, n° 3, Art. n° 3, janv. 2024, doi: 10.3390/app14031212.
- [78] P. Wang, Y. Zhou, et L. Zhang, « Fault Diagnosis Method of Rotating Machinery Based on CEEMDAN-LSTM Model », *J. Phys. Conf. Ser.*, vol. 2173, n° 1, p. 012057, janv. 2022, doi: 10.1088/1742-6596/2173/1/012057.
- [79] H. Xu, C. Cai, Y. Chi, et N. Zhang, « Fault diagnosis of gearbox based on adaptive wavelet de-noising and convolution neural network », *Adv. Mech. Eng.*, vol. 15, n° 2, p. 16878132231157186, févr. 2023, doi: 10.1177/16878132231157186.
- [80] S. Ding, M. Hao, Z. Cui, Y. Wang, J. Hang, et X. Li, « Application of multi-SVM classifier and hybrid GSAPSO algorithm for fault diagnosis of electrical machine drive system », *ISA Trans.*, vol. 133, p. 529-538, févr. 2023, doi: 10.1016/j.isatra.2022.06.029.
- [81] Q. Lu, X. Shen, X. Wang, M. Li, J. Li, et M. Zhang, « Fault Diagnosis of Rolling Bearing Based on Improved VMD and KNN », *Math. Probl. Eng.*, vol. 2021, n° 1, p. 2530315, 2021, doi: 10.1155/2021/2530315.
- [82] A. G. Abdulameer, A. S. Hammood, F. M. Abdulwahed, et A. A. Ayyash, « Naïve Bayes algorithm for timely fault diagnosis in helical gear transmissions using vibration signal analysis », *Int. J. Interact. Des. Manuf. IJIDeM*, vol. 19, n° 5, p. 3695-3706, mai 2025, doi: 10.1007/s12008-024-02037-0.
- [83] M. Hosseinpour-Zarnaq, M. Omid, et E. Biabani-Aghdam, « Fault diagnosis of tractor auxiliary gearbox using vibration analysis and random forest classifier », *Inf. Process. Agric.*, vol. 9, n° 1, p. 60-67, mars 2022, doi: 10.1016/j.inpa.2021.01.002.
- [84] G. Hinton, S. Osindero, et Y.-W. Teh, « A Fast Learning Algorithm for Deep Belief Nets », *Neural Comput.*, vol. 18, p. 1527-1554, juill. 2006, doi: 10.1162/neco.2006.18.7.1527.
- [85] J. Wang, Z. Mo, H. Zhang, et Q. Miao, « A Deep Learning Method for Bearing Fault Diagnosis Based on Time-Frequency Image », *IEEE Access*, vol. 7, p. 42373-42383, 2019, doi: 10.1109/ACCESS.2019.2907131.

## Bibliographie

---

- [86] S. R. Saufi, Z. A. B. Ahmad, M. S. Leong, et M. H. Lim, « Gearbox Fault Diagnosis Using a Deep Learning Model With Limited Data Sample », *IEEE Trans. Ind. Inform.*, vol. 16, n° 10, p. 6263-6271, oct. 2020, doi: 10.1109/TII.2020.2967822.
- [87] P. Jiang, H. Cong, J. Wang, et D. Zhang, « Fault Diagnosis of Gearbox in Multiple Conditions Based on Fine-Grained Classification CNN Algorithm », *Shock Vib.*, vol. 2020, n° 1, p. 9238908, 2020, doi: 10.1155/2020/9238908.
- [88] J. Shi, D. Peng, Z. Peng, Z. Zhang, K. Goebel, et D. Wu, « Planetary gearbox fault diagnosis using bidirectional-convolutional LSTM networks », *Mech. Syst. Signal Process.*, vol. 162, p. 107996, janv. 2022, doi: 10.1016/j.ymsp.2021.107996.
- [89] M.-C. Lin, P.-Y. Han, Y.-H. Fan, et C.-H. G. Li, « Development of Compound Fault Diagnosis System for Gearbox Based on Convolutional Neural Network », *Sensors*, vol. 20, n° 21, Art. n° 21, janv. 2020, doi: 10.3390/s20216169.
- [90] T. Haj Mohamad, A. Abbasi, E. Kim, et C. Nataraj, « Application of Deep CNN-LSTM Network to Gear Fault Diagnostics », in *2021 IEEE International Conference on Prognostics and Health Management (ICPHM)*, juin 2021, p. 1-6. doi: 10.1109/ICPHM51084.2021.9486591.
- [91] S. Han, X. Zhong, H. Shao, T. Xu, R. Zhao, et J. Cheng, « Novel multi-scale dilated CNN-LSTM for fault diagnosis of planetary gearbox with unbalanced samples under noisy environment », *Meas. Sci. Technol.*, vol. 32, n° 12, p. 124002, août 2021, doi: 10.1088/1361-6501/ac1b43.
- [92] I. Lupea et M. Lupea, « Continuous Wavelet Transform and CNN for Fault Detection in a Helical Gearbox », *Appl. Sci.*, vol. 15, n° 2, Art. n° 2, janv. 2025, doi: 10.3390/app15020950.
- [93] X. Zhang, P. Han, L. Xu, F. Zhang, Y. Wang, et L. Gao, « Research on Bearing Fault Diagnosis of Wind Turbine Gearbox Based on 1DCNN-PSO-SVM », *IEEE Access*, vol. 8, p. 192248-192258, 2020, doi: 10.1109/ACCESS.2020.3032719.
- [94] H. Hao et al., « Research on Fault Diagnosis Method Based on Improved CNN », *Shock Vib.*, vol. 2022, n° 1, p. 9312905, 2022, doi: 10.1155/2022/9312905.
- [95] M. S. Raghav et S. Patel, « Fault Diagnosis of Spur Gearbox by Image Classification Using Deep CNN », in *2024 1st International Conference on Robotics, Engineering, Science, and Technology (RESTCON)*, févr. 2024, p. 201-206. doi: 10.1109/RESTCON60981.2024.10463553.
- [96] X. Pang, X. Xue, W. Jiang, et K. Lu, « An Investigation Into Fault Diagnosis of Planetary Gearboxes Using A Bispectrum Convolutional Neural Network », *IEEEASME Trans. Mechatron.*, vol. 26, n° 4, p. 2027-2037, août 2021, doi: 10.1109/TMECH.2020.3029058.
- [97] J. Wang, Yang Jianwei, Wang Yuzhu, Bai Yongliang, Zhang Tieling, et D. and Yao, « Ensemble decision approach with dislocated time–frequency representation and pre-trained CNN for fault diagnosis of railway vehicle gearboxes under variable conditions », *Int. J. Rail Transp.*, vol. 10, n° 5, p. 655-673, sept. 2022, doi: 10.1080/23248378.2021.2000897.
- [98] X. Cheng, S. Dou, Y. Du, et Z. Wang, « Gearbox fault diagnosis method based on lightweight channel attention mechanism and transfer learning », *Sci. Rep.*, vol. 14, n° 1, p. 743, janv. 2024, doi: 10.1038/s41598-023-50826-6.
- [99] Z. Wan, R. Yang, et M. Huang, « Deep Transfer Learning-Based Fault Diagnosis for Gearbox under Complex Working Conditions », *Shock Vib.*, vol. 2020, n° 1, p. 8884179, 2020, doi: 10.1155/2020/8884179.

## Bibliographie

---

- [100] F. Jamil, T. Verstraeten, A. Nowé, C. Peeters, et J. Helsen, « A deep boosted transfer learning method for wind turbine gearbox fault detection », *Renew. Energy*, vol. 197, p. 331-341, sept. 2022, doi: 10.1016/j.renene.2022.07.117.
- [101] M. Azamfar, J. Singh, X. Li, et J. Lee, « Cross-domain gearbox diagnostics under variable working conditions with deep convolutional transfer learning », *J. Vib. Control*, vol. 27, n° 7-8, p. 854-864, avr. 2021, doi: 10.1177/1077546320933793.
- [102] A. Yin, Y. Yan, Z. Zhang, C. Li, et R.-V. Sánchez, « Fault Diagnosis of Wind Turbine Gearbox Based on the Optimized LSTM Neural Network with Cosine Loss », *Sensors*, vol. 20, n° 8, Art. n° 8, janv. 2020, doi: 10.3390/s20082339.
- [103] Y. Chen, M. Rao, K. Feng, et M. J. Zuo, « Physics-Informed LSTM hyperparameters selection for gearbox fault detection », *Mech. Syst. Signal Process.*, vol. 171, p. 108907, mai 2022, doi: 10.1016/j.ymsp.2022.108907.
- [104] B.-C. Zhang, S.-Q. Sun, X.-J. Yin, W.-D. He, et Z. Gao, « Research on Gearbox Fault Diagnosis Method Based on VMD and Optimized LSTM », *Appl. Sci.*, vol. 13, n° 21, Art. n° 21, janv. 2023, doi: 10.3390/app132111637.
- [105] Y. Chen, X. Liu, M. Rao, Y. Qin, Z. Wang, et Y. Ji, « Explicit speed-integrated LSTM network for non-stationary gearbox vibration representation and fault detection under varying speed conditions », *Reliab. Eng. Syst. Saf.*, vol. 254, p. 110596, févr. 2025, doi: 10.1016/j.ress.2024.110596.
- [106] K. Gopi et al., « Swarm-LSTM: Condition Monitoring of Gearbox Fault Diagnosis Based on Hybrid LSTM Deep Neural Network Optimized by Swarm Intelligence Algorithms », *Comput. Mater. Contin.*, vol. 66, p. 2041-2058, déc. 2020, doi: 10.32604/cmc.2020.013131.
- [107] E. Hoge, D. M. Onchiş, R. Yan, et Z. Zhou, « LogicLSTM: Logically-driven long short-term memory model for fault diagnosis in gearboxes », *J. Manuf. Syst.*, vol. 77, p. 892-902, déc. 2024, doi: 10.1016/j.jmsy.2024.10.003.
- [108] J. Yu et X. Zhou, « One-Dimensional Residual Convolutional Autoencoder Based Feature Learning for Gearbox Fault Diagnosis », *IEEE Trans. Ind. Inform.*, vol. 16, n° 10, p. 6347-6358, oct. 2020, doi: 10.1109/TII.2020.2966326.
- [109] Z. Zhang, Q. Yang, Y. Zi, et Z. Wu, « Discriminative Sparse Autoencoder for Gearbox Fault Diagnosis Toward Complex Vibration Signals », *IEEE Trans. Instrum. Meas.*, vol. 71, p. 1-11, 2022, doi: 10.1109/TIM.2022.3203440.
- [110] P. Pawlik, K. Kania, et B. Przysucha, « Gearbox fault identification using auto-encoder without training data from the damaged machine », *Measurement*, vol. 242, p. 115805, janv. 2025, doi: 10.1016/j.measurement.2024.115805.
- [111] F. Chen, L. Liu, B. Tang, B. Chen, W. Xiao, et F. Zhang, « A novel fusion approach of deep convolution neural network with auto-encoder and its application in planetary gearbox fault diagnosis », *Proc. Inst. Mech. Eng. Part O*, vol. 235, n° 1, p. 3-16, févr. 2021, doi: 10.1177/1748006X20964614.
- [112] P. Liu, F. Wan, Y. Xie, et Y. Qiang, « A Semi-Supervised Fault Diagnosis Method for Gearbox Based on Convolutional Autoencoder », in *2024 Global Reliability and Prognostics and Health Management Conference (PHM-Beijing)*, oct. 2024, p. 1-8. doi: 10.1109/PHM-Beijing63284.2024.10874561.
- [113] A. Maged et M. Xie, « Uncertainty utilization in fault detection using Bayesian deep learning », *J. Manuf. Syst.*, vol. 64, p. 316-329, juill. 2022, doi: 10.1016/j.jmsy.2022.07.002.
- [114] L. Meng et al., « A Probabilistic Bayesian Parallel Deep Learning Framework for Wind Turbine Bearing Fault Diagnosis », *Sensors*, vol. 22, n° 19, Art. n° 19, janv. 2022, doi: 10.3390/s22197644.

## Bibliographie

---

- [115] Y. Kang, C.-C. Wang, et Y.-P. Chang, « Gear Fault Diagnosis in Time Domains by Using Bayesian Networks », in *Analysis and Design of Intelligent Systems using Soft Computing Techniques*, P. Melin, O. Castillo, E. G. Ramírez, J. Kacprzyk, et W. Pedrycz, Éd., Berlin, Heidelberg: Springer, 2007, p. 618-627. doi: 10.1007/978-3-540-72432-2\_63.
- [116] D. Romahadi, H. Xiong, et H. Pranoto, « Intelligent System for Gearbox Fault Detection & Diagnosis Based on Vibration Analysis using Bayesian Networks », *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 694, n° 1, p. 012001, nov. 2019, doi: 10.1088/1757-899X/694/1/012001.
- [117] C. Wang, L. Wang, H. Chen, Y. Yang, et Y. Li, « Fault Diagnosis of Train Network Control Management System Based on Dynamic Fault Tree and Bayesian Network », *IEEE Access*, vol. 9, p. 2618-2632, 2021, doi: 10.1109/ACCESS.2020.3046681.
- [118] M. Cheliotis, Lazakis ,Iraklis, et A. and Cheliotis, « Bayesian and machine learning-based fault detection and diagnostics for marine applications », *Ships Offshore Struct.*, vol. 17, n° 12, p. 2686-2698, déc. 2022, doi: 10.1080/17445302.2021.2012015.
- [119] T. Elusakin et M. and Shafiee, « Fault diagnosis of offshore wind turbine gearboxes using a dynamic Bayesian network », *Int. J. Sustain. Energy*, vol. 41, n° 11, p. 1849-1867, déc. 2022, doi: 10.1080/14786451.2022.2119390.
- [120] T. Ademujimi et V. Prabhu, « Digital Twin for Training Bayesian Networks for Fault Diagnostics of Manufacturing Systems », *Sensors*, vol. 22, n° 4, Art. n° 4, janv. 2022, doi: 10.3390/s22041430.
- [121] X. Yin, B. Jiao, J. Liu, et H. Hu, « Reliability assessment of multistate wind turbine gear train system based on T-S fuzzy fault tree and Bayesian network », *Mech. Ind.*, vol. 26, p. 17, 2025, doi: 10.1051/meca/2025007.
- [122] W. Yu et C. Zhao, « Online Fault Diagnosis for Industrial Processes With Bayesian Network-Based Probabilistic Ensemble Learning Strategy », *IEEE Trans. Autom. Sci. Eng.*, vol. 16, n° 4, p. 1922-1932, oct. 2019, doi: 10.1109/TASE.2019.2915286.
- [123] J. Dai, « A fault diagnosis method for electromagnetic brakes based on the T-S fault tree and Bayesian network », *J. Phys. Conf. Ser.*, vol. 2965, n° 1, p. 012029, févr. 2025, doi: 10.1088/1742-6596/2965/1/012029.
- [124] R. U. Maheswari et R. Umamaheswari, « Système expert de détection des défauts de transmission d'éoliennes : décomposition empirique multivariée des modes, fusion multicapteurs avec classification par apprentissage bayésien. | EBSCOhost ». Consulté le: 21 mai 2025. [En ligne]. Disponible sur: <https://openurl.ebsco.com/contentitem/doi:10.32604%2Fiasc.2020.013924?sid=ebsco:plink:crawler&id=ebsco:doi:10.32604%2Fiasc.2020.013924>
- [125] X. Tan, J. Zhong, X. Zhou, Z. Wang, A. Zhou, et Y. Zheng, « Abnormal Vibration Fault Diagnosis of Reducer Based on Bayesian Network », in *Advances in Neural Networks – ISNN 2024*, X. Le et Z. Zhang, Éd., Singapore: Springer Nature, 2024, p. 505-514. doi: 10.1007/978-981-97-4399-5\_48.
- [126] P. Guo et X. Pu, « Test equipment diagnosis based on fault tree and Bayesian network », in *12th International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE 2022)*, juill. 2022, p. 1607-1612. doi: 10.1049/icp.2022.3097.
- [127] C. Zhang, Y. Wang, X. Li, et Z. Liu, « Wind turbine reliability analysis with fault-related weighted Bayesian networks », in *12th International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE 2022)*, juill. 2022, p. 29-35. doi: 10.1049/icp.2022.2844.

## Bibliographie

---

- [128] D. Huang, R. Zuo, et J. Wang, « Geochemical anomaly identification and uncertainty quantification using a Bayesian convolutional neural network model », *Appl. Geochem.*, vol. 146, p. 105450, nov. 2022, doi: 10.1016/j.apgeochem.2022.105450.
- [129] Q. Fang, G. Xiong, X. Shang, S. Liu, B. Hu, et Z. Shen, « An Enhanced Fault Diagnosis Method with Uncertainty Quantification Using Bayesian Convolutional Neural Network », in *2020 IEEE 16th International Conference on Automation Science and Engineering (CASE)*, août 2020, p. 588-593. doi: 10.1109/CASE48305.2020.9216773.
- [130] K. Zhou et J. Tang, « Probabilistic Gear Fault Diagnosis Using Bayesian Convolutional Neural Network », *IFAC-Pap.*, vol. 55, n° 37, p. 795-799, janv. 2022, doi: 10.1016/j.ifacol.2022.11.279.
- [131] A. Mostafavi et A. Friedmann, « Bayesian convolutional neural network models for uncertainty-aware bearing fault detection ». [En ligne]. Disponible sur: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://public-rest.fraunhofer.de/server/api/core/bitstreams/f062e021-ff13-4093-be2e-0e9ba6fe2adb/content>
- [132] A. Amin, A. Bibo, M. Panyam, et P. Tallapragada, « A Bayesian deep learning framework for reliable fault diagnosis in wind turbine gearboxes under various operating conditions », *Wind Eng.*, vol. 48, n° 2, p. 297-309, avr. 2024, doi: 10.1177/0309524X231206723.
- [133] Z. Wang, X. Xu, D. Song, Z. Zheng, et W. Li, « A Novel Bearing Fault Diagnosis Method Based on Improved Convolutional Neural Network and Multi-Sensor Fusion », *Machines*, vol. 13, n° 3, Art. n° 3, mars 2025, doi: 10.3390/machines13030216.
- [134] M. Feng, H. Shao, M. Shao, Y. Xiao, J. Wang, et B. Liu, « Utilizing Bayesian generalization network for reliable fault diagnosis of machinery with limited data », *Knowl.-Based Syst.*, vol. 305, p. 112628, déc. 2024, doi: 10.1016/j.knosys.2024.112628.
- [135] B. He, C. Zhu, Z. Li, C. Hu, et D. Zheng, « A Bayesian CNN-based Fusion Framework of Sensor Fault Diagnosis », *Meas. Sci. Technol.*, vol. 35, janv. 2024, doi: 10.1088/1361-6501/ad1a86.
- [136] « Three-Phase Induction Motor | How it works, Application & Advantages », *Electricity - Magnetism*. Consulté le: 15 octobre 2024. [En ligne]. Disponible sur: <https://www.electricity-magnetism.org/three-phase-induction-motor/>
- [137] « Moteurs à induction triphasés », *GAMAK*. Consulté le: 18 octobre 2024. [En ligne]. Disponible sur: <https://www.gamak.com/fr/moteurs-a-induction-triphases>
- [138] M. Frini, « Diagnostic des engrenages à base des indicateurs géométriques des signaux électriques triphasés », Thèse de doctorat, Université de Lyon, 2018.
- [139] I. I. E. Amarouayache, « Surveillance et diagnostic des défauts des machines tournantes dans le domaine temps-fréquences utilisant la décomposition modale empirique », Thèse de doctorat, BADJI MOKHTAR-ANNABA UNIVERSITY, Annaba, 2020.
- [140] I. Moumene, « Identification des défauts mixtes d'engrenage et de roulement par analyse vibratoire », Mémoire de magister, Université de 08 Mai 45, Guelma, 2010.
- [141] D. Goyal, A. Choudhary, J. K. Sandhu, P. Srivastava, et K. K. Saxena, « An intelligent self-adaptive bearing fault diagnosis approach based on improved local mean decomposition », *Int. J. Interact. Des. Manuf. IJIDeM*, août 2022, doi: 10.1007/s12008-022-01001-0.
- [142] F. Chaari, T. Fakhfakh, et M. Haddar, « Simulation numérique du comportement dynamique d'une transmission par engrenages en présence de défauts de dentures », *Mécanique Ind.*, vol. 6, n° 6, p. 625-633, nov. 2005, doi: 10.1051/meca:2006008.

## Bibliographie

---

- [143] « Les défaillances courantes des courroies ». Consulté le: 2 juillet 2024. [En ligne]. Disponible sur: <https://itafran.com/les-defaillances-courantes-des-courroies.html>
- [144] « What is Unbalance? », Ludeca. Consulté le: 7 octobre 2024. [En ligne]. Disponible sur: <https://ludeca.com/blog/balancing/10730/what-is-unbalance/>
- [145] K. KHOUALDIA, « Prédiction des modes de défaillances des machines tournantes par analyses vibratoires », UNIVERSITE BADJI MOKHTAR-ANNABA-, Annaba, 2020.
- [146] « Accouplements, embrayages, freins », SlideShare. Consulté le: 13 octobre 2024. [En ligne]. Disponible sur: <https://fr.slideshare.net/slideshow/accouplements-embrayages-freins/87810045>
- [147] « Common types of shaft misalignment », Engineering Knowledge. Consulté le: 13 octobre 2024. [En ligne]. Disponible sur: <https://www.mecanically.com/2023/11/types-of-shaft-misalignment.html>
- [148] « NF X60-010 », Afnor EDITIONS. Consulté le: 20 octobre 2024. [En ligne]. Disponible sur: <https://www.boutique.afnor.org/fr-fr/norme/nf-x60010/maintenance-vocabulaire-de-maintenance-et-de-gestion-des-biens-durables/fa030747/79155>
- [149] « Les Différents types de maintenance préventive ». Consulté le: 25 octobre 2024. [En ligne]. Disponible sur: <http://schema-montage-electronique.blogspot.com/2013/04/les-differents-types-de-maintenance.html>
- [150] « Tout savoir sur la maintenance industrielle – Mobility Work ». Consulté le: 22 octobre 2024. [En ligne]. Disponible sur: <https://mobility-work.com/fr/blog/maintenance-industrielle/>
- [151] « Les différents types de maintenance - Tribofilm ». Consulté le: 22 octobre 2024. [En ligne]. Disponible sur: <https://www.tribofilm.fr/les-differents-types-de-maintenance/>
- [152] R. Mohamed, « Contribution au diagnostic des défauts des roulements par l'analyse vibratoire, basé sur la méthode de décomposition de Fourier et l'opérateur énergétique de Teager. », 2023.
- [153] mayfloweradmin, « Maintenance prédictive : pourquoi choisir l'analyse vibratoire ? », Acoem France. Consulté le: 28 octobre 2024. [En ligne]. Disponible sur: <https://www.acoem.com/france/fr/blog/maintenance-predictive-pourquoi-choisir-lanalyse-vibratoire/>
- [154] D. Strömbergsson, P. Marklund, K. Berglund, et P. Larsson, « Bearing monitoring in the wind turbine drivetrain: A comparative study of the FFT and wavelet transforms », *Wind Energy*, vol. 23, n° 6, p. 1381-1393, juin 2020, doi: 10.1002/we.2491.
- [155] B. Pang, Q. Liu, Z. Sun, Z. Xu, et Z. Hao, « Time-frequency supervised contrastive learning via pseudo-labeling: An unsupervised domain adaptation network for rolling bearing fault diagnosis under time-varying speeds », *Adv. Eng. Inform.*, vol. 59, p. 102304, janv. 2024, doi: 10.1016/j.aei.2023.102304.
- [156] V. Ponomareva et al., « Time-Series Feature Extraction by Return Map Analysis and Its Application to Bearing-Fault Detection », *Big Data Cogn. Comput.*, vol. 8, n° 8, p. 82, juill. 2024, doi: 10.3390/bdcc8080082.
- [157] A. Boukar et N. Hamzaoui, « Evaluation des indicateurs de surveillance par analyse vibratoire : Application aux engrenages et roulements », vol. 25, n° 2, 2019.
- [158] D. BENMAHDI, « Contribution à l'étude du diagnostic des défauts mécaniques par classification non supervisée », Université Ferhat Abbas - Sétif 1, 2020.
- [159] S. Kass, « Diagnostic vibratoire autonome des roulements », 2019.
- [160] A. Allouche, « Développement de capteurs logiciels pour la détection de défauts mécaniques dans les entraînements électriques à vitesse variable: Application à la maintenance prédictive des éoliennes ».

## Bibliographie

---

- [161] O. Cousinard, P. Rousseau, F. Bolaers, et P. Marconnet, « Paramétrage, utilisation et apport de l'analyse cepstrale en maintenance prévisionnelle », *Mécanique Ind.*, vol. 5, n° 4, p. 393-406, juill. 2004, doi: 10.1051/meca:2004039.
- [162] T. KEBABSA, « Eude des aspects de défaillances et techniques de maintenance préventive conditionnelle appliquées aux turbomachines », UNIVERSITE BADJI MOKHTAR-ANNABA, 2016.
- [163] H. Tao, « An unsupervised fault diagnosis method for rolling bearing using STFT and generative neural networks », *J. Frankl. Inst.*, 2020.
- [164] J. Morlet, G. Arens, E. Fourgeau, et D. Glard, « Wave propagation and sampling theory—Part I: Complex signal and scattering in multilayered media », *GEOPHYSICS*, vol. 47, n° 2, p. 203-221, févr. 1982, doi: 10.1190/1.1441328.
- [165] J. Morlet, G. Arens, E. Fourgeau, et D. Giard, « Wave propagation and sampling theory—Part II: Sampling theory and complex waves », *GEOPHYSICS*, vol. 47, n° 2, p. 222-236, févr. 1982, doi: 10.1190/1.1441329.
- [166] A. Grossmann et J. Morlet, « Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape », *SIAM J. Math. Anal.*, vol. 15, n° 4, p. 723-736, juill. 1984, doi: 10.1137/0515056.
- [167] K. Belaid, A. Miloudi, et H. Bournine, « The processing of resonances excited by gear faults using continuous wavelet transform with adaptive complex Morlet wavelet and sparsity measurement », *Measurement*, vol. 180, p. 109576, août 2021, doi: 10.1016/j.measurement.2021.109576.
- [168] N. Saravanan et K. I. Ramachandran, « Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN) », *Expert Syst. Appl.*, vol. 37, n° 6, p. 4168-4181, juin 2010, doi: 10.1016/j.eswa.2009.11.006.
- [169] M. Civera et C. Surace, « A Comparative Analysis of Signal Decomposition Techniques for Structural Health Monitoring on an Experimental Benchmark », *Sensors*, vol. 21, n° 5, p. 1825, mars 2021, doi: 10.3390/s21051825.
- [170] H. Du, J. Wang, W. Qian, X. Zhang, et Q. Wang, « Rotating machinery fault diagnosis based on parameter-optimized variational mode decomposition », *Digit. Signal Process.*, vol. 153, p. 104590, oct. 2024, doi: 10.1016/j.dsp.2024.104590.
- [171] L. Yao et al., « An intelligent fault diagnosis method for lithium-ion battery pack based on empirical mode decomposition and convolutional neural network », *J. Energy Storage*, vol. 72, p. 108181, nov. 2023, doi: 10.1016/j.est.2023.108181.
- [172] X. Zhang, Y. Liang, J. Zhou, et Y. Zang, « A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM », *Measurement*, vol. 69, p. 164-179, juin 2015, doi: 10.1016/j.measurement.2015.03.017.
- [173] S. Gao, T. Li, Y. Zhang, et Z. Pei, « Fault diagnosis method of rolling bearings based on adaptive modified CEEMD and 1DCNN model », *ISA Trans.*, vol. 140, p. 309-330, sept. 2023, doi: 10.1016/j.isatra.2023.05.014.
- [174] H. MERDJANA, « Contribution à la Résolution des Problèmes Liés à la Détection, Modélisation et Caractérisation des Défauts par des Traitements de Signaux », Université Mohammed Seddik BENYAHIA, Jijel, 2018.
- [175] S. TAHRAOUI, « Cours Détection et Localisation des Défauts », Université Hassiba Benbouali, Chlef, 2022.
- [176] D. Balyogi Mohan, « Robust Hybrid Fault Detection and Isolation by integrating Bond Graph and Artificial Intelligence: Application to Green Hydrogen Production », Université de Lille.

## Bibliographie

---

- [177] A. TERMECHE, « Contribution au diagnostic des systèmes par Bond Graph », UNIVERSITE M'HAMED BOUGARA-BOUMERDES, 2021.
- [178] M. BOUMAHDY, « Développement d'un système expert pour le diagnostic des machines tournantes », Ecole Nationale Polytechnique, 2011.
- [179] C. H. Fontes et O. Pereira, « Pattern recognition in multivariate time series – A case study applied to fault detection in a gas turbine », Eng. Appl. Artif. Intell., vol. 49, p. 10-18, mars 2016, doi: 10.1016/j.engappai.2015.11.005.
- [180] T. Sun, G. Yu, M. Gao, L. Zhao, C. Bai, et W. Yang, « Fault Diagnosis Methods Based on Machine Learning and its Applications for Wind Turbines: A Review », IEEE Access, vol. 9, p. 147481-147511, 2021, doi: 10.1109/ACCESS.2021.3124025.
- [181] S. Zhang, S. Zhang, B. Wang, et T. G. Habetler, « Deep Learning Algorithms for Bearing Fault Diagnostics—A Comprehensive Review », IEEE Access, vol. 8, p. 29857-29881, 2020, doi: 10.1109/ACCESS.2020.2972859.
- [182] M. BENREKIA et O. MEKHTICHE, « Etude et implémentation d'un système intelligent d'aide à la diagnostic automatique des défauts de roulements dans les machines tournantes. », UNIVERSITE YAHIA FARES, MEDEA, 2022.
- [183] O. TOUAIBIA, « Détection des défauts mécaniques de roulements par deep learning », UNIVERSITE BADJI MOKHTAR - ANNABA, 2022.
- [184] A. IREKTI et A. BELHADEF, « Détection et classification des défauts des machines tournantes par les réseaux de neurones artificielles », UNIVERSITE MOULOUD MAMMERI DE TIZI-OUZOU, 2022.
- [185] S. DJABALLAH, « Optimisation de la Maintenance Conditionnelle Des Systèmes Mécaniques par Analyse Vibratoire », Université Mohamed Khider Biskra.
- [186] A. GUEDIDI, « Contribution au diagnostic des défauts de la machine asynchrone », UNIVERSITE MOHAMED KHIDER - BISKRA, 2024.
- [187] « Qu'est-ce que l'apprentissage non supervisé ? | Linedata ». Consulté le: 20 novembre 2024. [En ligne]. Disponible sur: <https://fr.linedata.com/quest-ce-que-lapprentissage-non-supervise>
- [188] P. Baudin, « Comment se passe l'apprentissage du machine learning ? » Consulté le: 21 novembre 2024. [En ligne]. Disponible sur: <https://blog.avanci.fr/comment-se-passe-lapprentissage-du-machine-learning>
- [189] D. M. LUDOVIC et N. SOLAL, « INTRODUCTION À L'APPRENTISSAGE AUTOMATIQUE », 2022.
- [190] « Différences entre apprentissage supervisé et non-supervisé ». Consulté le: 22 novembre 2024. [En ligne]. Disponible sur: <https://www.jedha.co/blog/les-differents-types-de-machine-learning>
- [191] « What Is Support Vector Machine? | IBM ». Consulté le: 23 novembre 2024. [En ligne]. Disponible sur: <https://www.ibm.com/topics/support-vector-machine>
- [192] « Support Vector Machine (SVM) Algorithm - Javatpoint ». Consulté le: 23 novembre 2024. [En ligne]. Disponible sur: <https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm>
- [193] « Apprentissage supervisé.pdf », SlideShare. Consulté le: 24 novembre 2024. [En ligne]. Disponible sur: <https://fr.slideshare.net/slideshow/apprentissage-supervisepdf/255266696>
- [194] « What is a Decision Tree? | IBM ». Consulté le: 24 novembre 2024. [En ligne]. Disponible sur: <https://www.ibm.com/topics/decision-trees>
- [195] Asana, « Qu'est-ce qu'un arbre de décision? Avantages et inconvénients [2024] • Asana », Asana. Consulté le: 24 novembre 2024. [En ligne]. Disponible sur: <https://asana.com/fr/resources/decision-tree-analysis>

## Bibliographie

---

- [196] « Principaux algorithmes de classification – Partie 1 | Linedata ». Consulté le: 24 novembre 2024. [En ligne]. Disponible sur: <https://fr.linedata.com/principaux-algorithmes-de-classification-partie-1>
- [197] M. lamine MOUANE et R. BENSEDDIK, « L'apprentissage statistique pour le diagnostic de défauts dans un système automatique », UNIVERSITE KASDI MERBAH OUARGLA, 2022.
- [198] B. ANANOU, « Détection et localisation des défauts de circuit-ouvert d'un onduleur », UNIVERSITE KASDI MERBAH OUARGLA, 2023.
- [199] H. LARIBI et O. MELIANI, « Sélection d'un Algorithme de Deep Learning Approprié pour la Maintenance Prédictive. », Ecole Nationale Supérieure de Technologie, Alger, 2023.
- [200] N. E. I. Bourougaa et M. Seridi, « Application des réseaux de neurone pour la classification des Données », Université 8 Mai 1945 – Guelma, 2020.
- [201] M. L. in P. English, « Deep Learning Course — Lesson 5: Forward and Backward Propagation », Medium. Consulté le: 12 décembre 2024. [En ligne]. Disponible sur: <https://medium.com/@nerdjock/deep-learning-course-lesson-5-forward-and-backward-propagation-ec8e4e6a8b92>
- [202] S. Salve, « A Beginner's Guide to Neural Networks: Forward and Backward Propagation Explained », Medium. Consulté le: 12 décembre 2024. [En ligne]. Disponible sur: <https://medium.com/@xsankalp13/a-beginners-guide-to-neural-networks-forward-and-backward-propagation-explained-a814666c73ab>
- [203] « Que sont les réseaux neuronaux ? | IBM ». Consulté le: 17 décembre 2024. [En ligne]. Disponible sur: <https://www.ibm.com/fr-fr/topics/neural-networks>
- [204] E. Viennet, « Réseaux à fonctions de base radiales », in Apprentissage connexionniste, Y. Bennani, Éd., in I2C Hermès. , Lavoisier, 2006, p. 105. Consulté le: 5 janvier 2025. [En ligne]. Disponible sur: <https://hal.science/hal-00085092>
- [205] « Probabilistic Neural Networks », Amirhessam Tahmassebi. Consulté le: 11 janvier 2025. [En ligne]. Disponible sur: <https://amirhessam88.github.io/probabilistic-neural-networks/>
- [206] suchi\_shen arvindpdmn, « Probabilistic Neural Network », Devopedia. Consulté le: 11 janvier 2025. [En ligne]. Disponible sur: <https://devopedia.org/probabilistic-neural-network>
- [207] « Probabilistic Neural Networks (PNNs) », GeeksforGeeks. Consulté le: 11 janvier 2025. [En ligne]. Disponible sur: <https://www.geeksforgeeks.org/probabilistic-neural-networks-pnns/>
- [208] T. Surapunt et S. Wang, « Ensemble Modeling with a Bayesian Maximal Information Coefficient-Based Model of Bayesian Predictions on Uncertainty Data », Information, vol. 15, p. 228, avr. 2024, doi: 10.3390/info15040228.
- [209] gabriel costa, « A first insight into Bayesian Neural Networks (BNNs) », Medium. Consulté le: 18 janvier 2025. [En ligne]. Disponible sur: <https://medium.com/@costaleirbag/a-first-insight-into-bayesian-neural-networks-bnn-c767551e9526>
- [210] « Differences Between Bayesian Networks and Neural Networks », GeeksforGeeks. Consulté le: 18 janvier 2025. [En ligne]. Disponible sur: <https://www.geeksforgeeks.org/differences-between-bayesian-networks-and-neural-networks/>
- [211] L. V. Jospin, W. Buntine, F. Boussaid, H. Laga, et M. Bennamoun, « Hands-on Bayesian Neural Networks -- a Tutorial for Deep Learning Users », IEEE Comput. Intell. Mag., vol. 17, n° 2, p. 29-48, mai 2022, doi: 10.1109/MCI.2022.3155327.

## Bibliographie

---

- [212] « Quels sont les différents algorithmes de Deep Learning ? » Consulté le: 22 janvier 2025. [En ligne]. Disponible sur: <https://www.jedha.co/formation-ia/algorithmes-deep-learning>
- [213] « What Is Deep Learning and How Does It Work? », Built In. Consulté le: 22 janvier 2025. [En ligne]. Disponible sur: <https://builtin.com/machine-learning/deep-learning>
- [214] 5gworldpro, « Artificial Intelligence vs. Machine Learning vs. Deep Learning: What's the Difference? », 5G Training and 5G Certification. Consulté le: 23 janvier 2025. [En ligne]. Disponible sur: <https://www.5gworldpro.com/blog/2022/08/15/artificial-intelligence-vs-machine-learning-vs-deep-learning-whats-the-difference/>
- [215] « Deep Learning vs. Machine Learning – What's The Difference? » Consulté le: 22 janvier 2025. [En ligne]. Disponible sur: <https://levity.ai/blog/difference-machine-learning-deep-learning>
- [216] « Rolling Bearing Fault Diagnosis Method Base on Periodic Sparse Attention and LSTM ». Consulté le: 8 février 2025. [En ligne]. Disponible sur: <https://ieeexplore.ieee.org/abstract/document/9770848>
- [217] P. POITIER, « Segmentation Automatique de la Langue des Signes de Belgique Francophone à l'aide de Réseaux Neuronaux Récurrents », Dépôt Institutionnel - Portail de la Recherche, Université de Namur.
- [218] L. IAS, « Convolutional Neural Networks (CNN): An In-Depth Exploration - Lukmaan IAS Current Affairs », Lukmaan IAS. Consulté le: 24 janvier 2025. [En ligne]. Disponible sur: <https://blog.lukmaanas.com/2024/12/18/convolutional-neural-networks-cnn-an-in-depth-exploration/>
- [219] J. Teuwen et N. Moriakov, « Chapter 20 - Convolutional neural networks », in Handbook of Medical Image Computing and Computer Assisted Intervention, S. K. Zhou, D. Rueckert, et G. Fichtinger, Éd., in The Elsevier and MICCAI Society Book Series. , Academic Press, 2020, p. 481-501. doi: 10.1016/B978-0-12-816176-0.00025-9.
- [220] W. MARTEL, « Détection Automatique des Défauts dans des Volumes Tomographiques des Pièces de Fonderie », L'Institut National des Sciences Appliquées (INSA) de Lyon, 2022.
- [221] « What is a Convolutional Neural Network? », Roboflow Blog. Consulté le: 26 janvier 2025. [En ligne]. Disponible sur: <https://blog.roboflow.com/what-is-a-convolutional-neural-network/>
- [222] Y. AOULMI, « Modélisation pluie-débit et débits de crues en milieu semi-aride par différentes méthodes statistiques et modèles hydrologiques. Etude de cas », Université Larbi Ben M'Hidi. Oum-El-Bouaghi, 2022.
- [223] A. Zafar et al., « A Comparison of Pooling Methods for Convolutional Neural Networks », Appl. Sci., vol. 12, n° 17, Art. n° 17, janv. 2022, doi: 10.3390/app12178643.
- [224] « CNN | Introduction to Pooling Layer », GeeksforGeeks. Consulté le: 28 janvier 2025. [En ligne]. Disponible sur: <https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/>
- [225] « What are Convolutional Neural Networks? | IBM ». Consulté le: 28 janvier 2025. [En ligne]. Disponible sur: <https://www.ibm.com/think/topics/convolutional-neural-networks>
- [226] F. L. PhD, « Bayesian Convolutional Neural Networks with Bayes by Backprop », NeuralSpace. Consulté le: 28 mai 2025. [En ligne]. Disponible sur: <https://medium.com/neuralspace/bayesian-convolutional-neural-networks-with-bayes-by-backprop-c84dcaaf086e>
- [227] D. G. Clayton, « A Monte Carlo Method for Bayesian Inference in Frailty Models », Biometrics, vol. 47, n° 2, p. 467-485, 1991, doi: 10.2307/2532139.

## Bibliographie

---

- [228] gabriel costa, « A first insight into Bayesian Neural Networks (BNNs) », Medium. Consulté le: 31 mai 2025. [En ligne]. Disponible sur: <https://medium.com/@costaleirbag/a-first-insight-into-bayesian-neural-networks-bnn-c767551e9526>
- [229] R. M. Neal, « Bayesian Training of Backpropagation Networks by the Hybrid Monte Carlo Method. » [En ligne]. Disponible sur: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=38b7a4d7d9646c4474c893fc53a606dee3264fec>
- [230] H. Wang et D.-Y. Yeung, « A Survey on Bayesian Deep Learning », ACM Comput Surv, vol. 53, n° 5, p. 108:1-108:37, sept. 2020, doi: 10.1145/3409383.
- [231] M. Zulfiqar, K. A. A. Gamage, M. Kamran, et M. B. Rasheed, « Hyperparameter Optimization of Bayesian Neural Network Using Bayesian Optimization and Intelligent Feature Engineering for Load Forecasting », Sensors, vol. 22, n° 12, Art. n° 12, janv. 2022, doi: 10.3390/s22124446.
- [232] « Data Analysis Competition », PHM Society. [En ligne]. Disponible sur: <https://phmsociety.org/data-analysis-competition/>
- [233] S. H. Laaradj, L. Abdelkader, B. Mohamed, et N. Mourad, « Vibration-based fault diagnosis of dynamic rotating systems for real-time maintenance monitoring », Int. J. Adv. Manuf. Technol., vol. 126, n° 7, p. 3283-3296, juin 2023, doi: 10.1007/s00170-023-11320-5.