



الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة الشهيد الشيخ العربي التبسي - تبسة

Université Echahid Echikh Larbi Tébessi – Tébessa –

Faculté des Sciences et de la Technologie

Département de Génie Mécanique

MEMOIRE

Pour l'obtention du **diplôme de Master Académique**

Spécialité : Construction mécanique

Intitulé

Diagnostic des défauts d'engrenages et de roulements par l'analyse vibratoire et les réseaux de neurones artificiels.

Présenté par :

M^{lle} KEMACHE Samira

Devant le jury :

Président :

BELGHALEM Hadj

MCA

Encadreur :

ALIA Saief Eddine

MAB

Examineur :

YOUNES Ramdane

MCA

Promotion : 2023/2024

Dédicace

Je tiens à dédier ce travail :

À mes très chers parents et mes grands-parents qui m'ont guidé durant les moments les plus pénibles de mon chemin ; ma mère qui a été à mes côtés toute ma vie et mon père qui a sacrifié afin de me voir devenir ce que je suis.

À mes chères sœurs et mon cher frère.

Toute ma famille et mes amies.

Remerciement

Je remercie **Dieu**, le tout puissant, pour tout.

Je tiens à exprimer mes vifs remerciements à mon encadrant **Dr. ALIA Saief Eddine** pour la confiance qu'il m'a accordée, ses encouragements, et ses précieux conseils.

Je tiens à remercier également les membres de jury : **Dr. YOUNES Ramdane** et **Dr. BELGHALEM Hadj** d'avoir accepté de juger mon travail.

Résumé

L'analyse vibratoire combinée aux réseaux de neurones artificiels permet de diagnostiquer les défauts d'engrenages et de roulements, ce qui constitue une méthode avancée pour repérer les anomalies dans ces éléments mécaniques critiques.

L'analyse vibratoire repose sur la détection et l'interprétation des vibrations émises par les engrenages et les roulements pendant leur fonctionnement, alors que les réseaux de neurones artificiels sont des modèles d'apprentissage automatique capables d'apprendre à partir de données d'entrée pour reconnaître des schémas complexes.

Les différents défauts tels que les fissures, l'usure génèrent des signatures vibratoires spécifiques qui peuvent être capturées et analysées, ces défauts contenant des informations sur les vibrations associées à différents types de défauts peuvent être utilisés comme des données d'entraînement des modèles d'apprentissage.

En combinant ces deux approches, nous pouvons créer des systèmes de diagnostic précis pour détecter les défauts d'engrenages et de roulements qui peut aider à prévenir les pannes coûteuses et les arrêts imprévus des équipements, améliorant ainsi la fiabilité et la disponibilité des systèmes mécaniques.

Mots clés : Analyse vibratoire, réseaux de neurones artificiels, diagnostic des défauts, défaut de roulement, défaut d'engrenage.

Abstract

Vibration analysis combined with artificial neuron networks can be used to diagnose gear and bearing defects, which is an advanced method for detecting anomalies in these critical mechanical elements.

Vibration analysis is based on the detection and interpretation of the vibrations emitted by the gear and bearings during their operation while artificial neuron networks are machine learning models capable of learning from input data to recognize complex patterns. Different defects such as cracks, wear and tear generate specific vibrational signatures that can be captured and analyzed, these defects containing information about the vibrations associated with different types of defects can be used as training data for learning models. By combining these two approaches, we can create precise diagnostic systems to detect gear and bearing defects that can help prevent costly equipment failures and unexpected equipment shutdowns, thereby improving the reliability and availability of mechanical systems.

Key words: Vibration analysis, artificial neural networks, fault diagnosis, bearing fault, gear fault.

ملخص

يمكن لتحليل الاهتزازات جنبًا إلى جنب مع الشبكات العصبية الاصطناعية تشخيص عيوب التروس والمحامل، مما يوفر طريقة متقدمة لاكتشاف الحالات الشاذة في هذه العناصر الميكانيكية الحرجة.

يعتمد تحليل الاهتزازات على كشف وتفسير الاهتزازات المنبعثة من التروس والمحامل أثناء تشغيلها، في حين أن الشبكات العصبية الاصطناعية هي نماذج للتعلم الآلي قادرة على التعلم من البيانات المدخلة للتعرف على الأنماط المعقدة.

تولد العيوب المختلفة مثل الشقوق والتآكل بصمات اهتزاز محددة يمكن التقاطها وتحليلها، ويمكن استخدام هذه العيوب التي تحتوي على معلومات عن الاهتزازات المرتبطة بأنواع مختلفة من العيوب كبيانات تدريب لنماذج التعلم.

من خلال الجمع بين هذين النهجين، يمكننا إنشاء أنظمة تشخيصية دقيقة لاكتشاف أخطاء التروس والمحامل التي يمكن أن تساعد في منع الأعطال المكلفة وإيقاف تشغيل المعدات غير المخطط له، وبالتالي تحسين موثوقية الأنظمة الميكانيكية وتوافرها.

الكلمات المفتاحية: تحليل الاهتزاز ، الشبكات العصبية الاصطناعية ، تشخيص الأعطال ، عيب المحمل ، عيب التروس.

Liste des figures

Chapitre I

Figure I.1 : Les types de la maintenance	4
Figure I.2 : Schéma d'un roulement à billes	6
Figure I.3 : Les principales familles de roulements	6
Figure I.4 : Usure dans une bague intérieure d'un roulement	7
Figure I.5.a : Écaillage de fatigue	7
Figure I.5.b : Écaillage superficiel	7
Figure I.6 : Grippage d'un roulement	8
Figure I.7 : La corrosion	8
Figure I.8 : Les grandes familles d'engrenages	9
Figure I.9 : Des piqûres sur les dents	10
Figure I.10 : Grippage des dents	10

Chapitre II

Figure II.1 : Les différentes amplitudes	22
Figure II.2 : Vibration sinusoïdale	23
Figure II.3 : Vibration périodique	24
Figure II.4 : Vibration apériodique	25
Figure II.5 : Coupe longitudinale d'un piézoélectrique	27
Figure II.6 : Piézoélectrique	27
Figure II.7 : Spectre du signal avec un défaut d'engrenages	29
Figure II.8 : Zoom sur le cepstre du signal	30
Figure II.9 : Spectre d'enveloppe du signal $S(t)$	31
Figure II.10 : STFT du signal $S(t)$	32
Figure II.11 : Différents détails et approximations issus de l'analyse d'ondelettes du signal $S(t)$	34
Figure II.12 : Spectre d'enveloppe du signal $S(t)$	34
Figure II.13 : Caractéristiques géométriques du roulement.....	36

Chapitre III

Figure III.1 : Les réseaux de neurones artificiels et l'IA.....	39
Figure III.2 : La structure généralisée au diagnostic des défauts.....	41

Figure III.3 : Les trois principaux algorithmes d'apprentissage automatique.....	41
Figure III.4 : La structure d'un neurone biologique.....	44
Figure III.5 : La structure d'un neurone formel.....	45
Figure III.6 : Fonction linéaire.....	49
Figure III.7 : Fonction sigmoïde.....	49
Figure III.8 : Fonction Tanh.....	49
Figure III.9 : Fonction ReLU.....	49
Figure III.10 : Schéma d'une carte auto-organisatrice.....	51

Chapitre IV

Figure IV.1 : Les signaux temporels.....	54
Figure IV.2 : Roulement à rouleaux coniques SKF 32222 J2.....	55
Figure IV.3 : La représentation temporelle de signal du 1 ^{er} jour 07/03/2013.....	56
Figure IV.4 : Les approximations et les détails de signal du 1 ^{er} jour.....	57
Figure IV.5 : Le spectre d'enveloppe de deux vecteurs de détails D2 et D3.	58
Figure IV.6 : La représentation temporelle de signal de 7 ^{ème} jour 13/03/2013.....	58
Figure IV.7 : Les vecteurs des détails D2 et D3 du 7 ^{ème} jour de mesure.....	59
Figure IV.8 : Spectre d'enveloppe de deux vecteurs de détails D2 et D3.....	60
Figure IV.9 : La représentation temporelle de signal du 38 ^{ème} jour 13/04/2013.....	60
Figure IV.10 : Le vecteur de détail D3 du 38 ^{ème} jour.....	61
Figure IV.11 : Le spectre d'enveloppe du vecteur de détail D3.....	61
Figure IV.12 : La représentation temporelle de signal du 49 ^{ème} jour 24/04/2013.....	62
Figure IV.13 : Le vecteur de détail D3.....	62
Figure IV.14 : Le spectre d'enveloppe du vecteur de détail D3.....	63
Figure IV.15 : La représentation temporelle de signal du 50 ^{ème} jour 25/04/2013.....	63
Figure IV.16 : Le vecteur de détail D3.....	64
Figure IV.17 : Le spectre d'enveloppe de vecteur de détail D3.....	64
Figure IV.18 : Évolution du kurtosis pendant la durée de surveillance.....	65
Figure IV.19 : Classification de l'état des roulements par SOM sur la base des valeurs de Kurtosis.....	66

Liste des tableaux

Chapitre III

Tableau III.1 : Comparaison entre l'apprentissage supervisé et non-supervisé.....	42
Tableau III.2 : Tableau comparatif entre le neurone biologique et le neurone formel.....	46
Tableau III.3 : Les fonctions d'activation les plus courants.....	47

Chapitre IV

Tableau IV.1 : Les fréquences caractéristiques des défauts de roulement.....	55
Tableau IV.2 : Les valeurs du Kurtosis pendant 50 jours.....	65

Table des matières

Dédicace	
Remerciement	
Résumé	
Abstract	
ملخص	
Liste des figures	
Liste des tableaux	
Introduction générale	1
Chapitre I : Généralités et synthèse bibliographique.	
1. Introduction.....	3
2. La maintenance	4
2.1. Définition de la maintenance	4
2.2. Les types de la maintenance	4
2.2.1. La maintenance corrective	4
2.2.2. La maintenance préventive.....	4
2.2.2.1. La maintenance préventive systématique.....	4
2.2.2.2. La maintenance préventive conditionnelle.....	4
2.3. Les niveaux de la maintenance.....	5
2.4. Les objectifs de la maintenance.....	5
2.5. Pratique de la maintenance préventive conditionnelle.....	5
3. Les roulements et leurs défauts.....	6
3.1. Définition de roulement.....	6
3.2. Les défauts de roulement.....	7
3.2.1. L'usure.....	7
3.2.2. L'écaillage.....	7
3.2.3. Le grippage.....	8
3.2.4. La corrosion.....	8
4. Les engrenages et leurs défauts.....	9
4.1. Qu'est-ce que un engrenage ?.....	9
4.2. La fréquence d'engrènement.....	9
4.3. Les défauts d'engrenages.....	9

4.3.1. Les défauts répartis sur toutes les dents.....	9
a. L'usure de la surface de la dent.....	9
b. Défaillance par fatigue des dents d'engrenages.....	10
c. Les piqûres.....	10
4.3.2. Les défauts localisés sur une partie de la denture.....	10
a. L'écaillage.....	10
b. Le grippage.....	10
c. Les fissures.....	11
5. Synthèse bibliographique.....	11
6. Conclusion.....	17
Références bibliographiques.....	18

Chapitre II: L'analyse vibratoire.

1. Introduction	21
2. Les techniques d'analyse.....	21
3. La politique des vibrations	22
3.1. Qu'est-ce qu'une vibration?.....	22
3.2. Les caractéristiques principales des vibrations.....	22
a. L'amplitude.....	22
b. La période.....	23
c. La fréquence	23
3.3. Les types de vibrations	23
a. Vibrations harmoniques	23
b. Vibrations périodiques	24
c. Vibrations apériodiques aléatoires (chocs).....	24
4. La surveillance et le diagnostic.....	25
5. L'analyse vibratoire	26
5.1. Le principe de l'analyse vibratoire	26
5.2. Les capteurs des signaux vibratoires.....	26
5.2.1. Qu'est-ce que un accéléromètre ?.....	27
5.2.2. Pourquoi l'accéléromètre?.....	27
5.3. L'analyse vibratoire dans le domaine temporel.....	27
5.3.1. Le kurtosis.....	28
5.3.2. Facteur de crête	28
5.3.3. Valeur efficace RMS.....	28
5.3.4. Crête a crête	28

5.3.5. La valeur crête	28
5.3.6. Facteur K (FK).....	28
5.4. L'analyse vibratoire dans le domaine fréquentiel	29
5.4.1. L'analyse spectrale.....	29
5.4.2. L'analyse cepstrale.....	30
5.4.3. L'analyse d'enveloppe HFRT.....	31
5.5. L'analyse temps-fréquence.....	32
5.5.1. Transformée de Fourier à courte terme STFT.....	32
5.5.2. La transformée en ondelettes.....	33
6. Les fréquences caractéristiques.....	36
6.1. Les fréquences caractéristiques d'un roulement.....	36
6.2. La fréquence caractéristique d'un engrenage.....	37
7. Conclusion.....	37
Références bibliographiques.....	38

Chapitre III : les réseaux de neurones artificiels.

1. Introduction	39
2. L'intelligence artificielle.....	40
2.1. Qu'est-ce que l'intelligence artificielle IA ?.....	40
2.2. Les domaines de l'application de l'IA.....	40
2.2.1. La santé.....	40
2.2.2. La finance.....	40
2.2.3. La mécanique.....	40
2.3. L'apprentissage automatique : la méthode de l'IA le plus célèbre.....	41
2.3.1. L'apprentissage supervisé.....	42
2.3.2. L'apprentissage non supervisé	42
2.3.3. L'apprentissage par renforcement	42
3. Les réseaux de neurones artificiels	43
3.1. Bref historique	43
3.2. L'origine de RNA, analogie entre neurone biologique et neurone formel...44	
3.2.1. Le neurone biologique	44
3.2.2. Le neurone formel	45
3.2.2.1. La structure d'un neurone formel	45
3.2.2.2. Comment un neurone formel se fonctionne ?.....	45
3.3. Le modèle le plus simple d'un neurone formel, le perceptron.....	46

3.4. La fonction d'activation.....	46
3.4.1. La fonction linéaire.....	48
3.4.2. La fonction sigmoïde.....	48
3.4.3. La fonction tangente hyperbolique.....	49
3.4.4. La fonction d'unité linéaire rectifiée ReLU.....	49
3.5. La classification des RNA.....	49
3.5.1. Les réseaux FEED-FORWARD.....	49
3.5.2. Les réseaux FEED-BACK.....	50
4. Les cartes auto-organisatrices.....	51
4.1. Définition.....	51
4.2. L'algorithme des cartes auto-organisatrices.....	51
5. Conclusion.....	52
Références bibliographiques.....	53
Chapitre IV : L'AMRO et les cartes auto-organisées SOM dans le suivi de la dégradation des roulements.	
1. Introduction	53
2. Plan expérimental	54
2.1. Présentation du banc d'essai	54
2.2. Les fréquences caractéristiques des défauts de roulement.....	55
3. Traitement des signaux par L'AMRO.....	55
4. Traitement des signaux par SOM.....	65
5. Conclusion.....	67
Références bibliographiques.....	68
Conclusion générale.....	69

Introduction générale

L'industrie est un secteur clé de l'économie, elle joue un rôle crucial dans le développement économique, la création d'emplois, et l'innovation technologique. Au cœur de nombreux processus industriels on trouve les machines tournantes, leur performance et leur fiabilité sont vitales pour l'efficacité industrielle, nécessitant une maintenance régulière et des techniques de surveillance avancées pour assurer leur bon fonctionnement et prolonger leur durée de vie.

Parmi les composants essentiels des machines tournantes on trouve les roulements et les engrenages. Etant donné que leur défaillance peut entraîner des arrêts coûteux de la production, voire des dommages graves aux équipements et aux personnes, il est très important de surveiller ces organes vitales en utilisant des techniques performantes et avancées telles que l'analyse vibratoire et les réseaux de neurones artificiels qui ont révolutionné la manière dont nous diagnostiquons les défauts d'engrenages et de roulements dans les machines industrielles.

L'analyse vibratoire consiste à mesurer et à interpréter les vibrations émises par les engrenages et les roulements pendant leur fonctionnement. Ces vibrations contiennent des informations précieuses sur l'état de santé des composants et peuvent révéler des défauts tels que des fissures, des éclatements, des déformations ou des défauts de lubrification. Cette approche peut être abordée en deux étapes : la surveillance et le diagnostic.

La surveillance repose sur le suivi périodique des indicateurs scalaires (le kurtosis, le RMS, le facteur K,...etc). Ses valeurs peuvent ne pas avoir de signification intrinsèque, mais c'est son évolution dans le temps qui est significative du défaut.

Le diagnostic est la deuxième étape de l'analyse vibratoire qui nous permet à localiser l'élément défectueux d'une machine tournante suite à une évolution anormale des vibrations constatée lors de la surveillance. Il utilise des méthodes d'analyse plus approfondies que les indicateurs scalaires : l'analyse spectrale, l'analyse cepstrale, l'analyse multirésolution on ondelettes...etc.

L'introduction de l'intelligence artificielle, en particulier des réseaux de neurones artificiels, a considérablement amélioré la précision et l'efficacité des diagnostics de défauts.

Les réseaux de neurones de différents types : le Perceptron, les réseaux de neurones multicouches, les réseaux de neurones convolutif, les cartes auto organisées...etc sont capables d'apprendre à partir de grandes quantités de données et faire des tâches complexe comme la classification, la visualisation des images,...etc.

Ils jouent un rôle de plus en plus crucial dans le diagnostic des défauts d'engrenages et de roulements. Leur capacité à analyser des données complexes leur permet de détecter des modèles subtils et complexes associés à différents types de défauts. En s'appuyant sur ces modèles, les réseaux de neurones peuvent non seulement identifier les défauts, mais aussi prédire leur gravité et estimer le moment optimal pour effectuer la maintenance corrective. Cela les rend particulièrement efficaces pour la maintenance prédictive et le diagnostic des pannes.

Ce travail est organisé en quatre chapitres comme suite :

- Le premier chapitre contient quelques notions fondamentales d'engrenages et de roulements avec un synthèse bibliographique afin de présenter quelques travaux dans le domaine de diagnostic de défauts de ces deux composants par l'analyse vibratoire et les réseaux de neurones artificiels.
- Le deuxième chapitre est dédié à une étude théorique sur l'analyse vibratoire en présentant ses différentes techniques telles que l'analyse temporelle et l'analyse fréquentielle.
- Le troisième chapitre présente une brève théorie sur les réseaux de neurones artificiels en introduisant ses origines et ses différents modèles plus de sa méthode de fonctionnement.
- Le quatrième chapitre a été divisé en deux parties : la première partie est consacrée à l'application de l'analyse multi-résolution en ondelettes AMRO pour surveiller un ensemble des signaux vibratoires d'une éolienne pendant 50 jours tandis que la deuxième partie se concentre sur l'application de la méthode des cartes auto-organisées SOM sur le même ensemble des signaux vibratoires afin de classifier les défauts de roulement en utilisant les valeurs du Kurtosis comme des entrées.

Chapitre I :

Généralités et synthèse bibliographique.

1. Introduction :

Dans le domaine d'industrie, les machines tournantes jouent un rôle très important en raison de leur grande utilisation dans presque toutes les applications. Par conséquent la prévention de toutes leurs pièces est nécessaire pour assurer non seulement le bon fonctionnement de la machine tournante elle-même mais aussi le succès du travail non-stop de l'usine.

Parmi les composantes fréquemment trouvées dans les machines tournantes, les roulements et les engrenages, ces éléments sont les éléments vitaux de l'industrie et jouent un rôle essentiel pour assurer le fonctionnement de la machine tournante. Pour cela, le diagnostic des défauts de ces derniers est crucial pour la prévention des dommages catastrophiques, les pertes économiques et surtout les problèmes de sécurité pour éviter les pertes néfastes humaines.

Lors de la planification de la maintenance préventive des pannes et assurer le bon fonctionnement de ces machines, éviter les dommages catastrophiques, augmenter la fiabilité et la disponibilité des machines et réduire les temps d'arrêt, des outils de surveillance puissants tels que l'analyse vibratoire, l'analyse d'huile, l'imagerie thermique et l'analyse acoustique sont nécessaires. D'autre part, afin de visualiser et d'évaluer l'état de santé de ces éléments, les travaux se concentrent sur l'application des méthodes de réseaux neuronaux artificiels dans la surveillance et le diagnostic des défauts d'engrenages et de roulements.

2. La maintenance :

2.1. Définition de la maintenance :

Une première définition normative de la maintenance fut donnée par l'AFNOR en 1994 (norme NFX 60-010), à savoir : « l'ensemble des actions permettant de maintenir ou de rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé ».

2.2. Les types de la maintenance :

La figure I.1 présente les deux différents types de la maintenance : la maintenance corrective et la maintenance préventive.

2.2.1. La maintenance corrective :

Maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise. [1]

2.2.2. La maintenance préventive :

Maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien. [1]

2.2.2.1. La maintenance préventive systématique :

Maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage mais sans contrôle préalable de l'état du bien. [1]

2.2.2.2. La maintenance préventive conditionnelle :

Maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent.

La surveillance du fonctionnement et des paramètres peut être exécutée selon un calendrier, ou à la demande, ou de façon continue. [1]

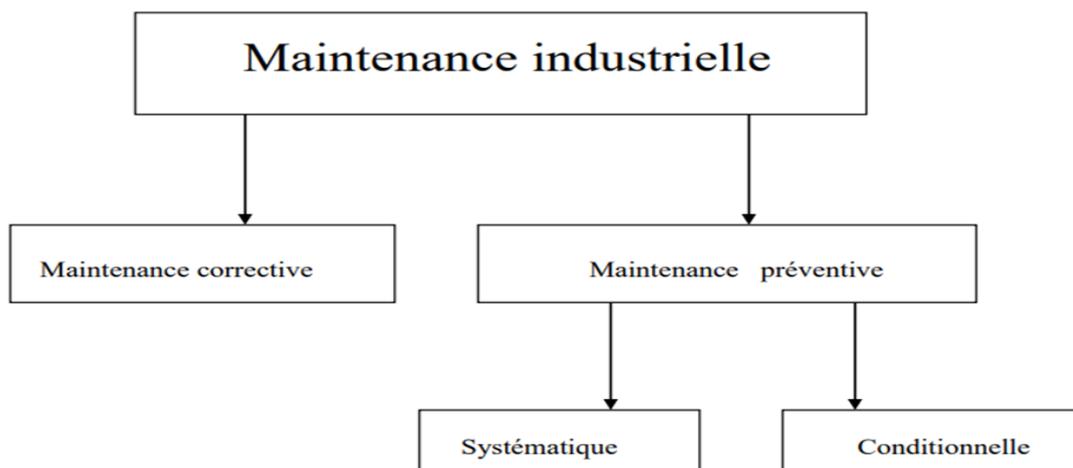


Figure I.1 : Les types de la maintenance.

2.3. Les niveaux de la maintenance :

Chaque panne, selon son gravité nécessite son propre réparation et à partir de celui-ci, nous trouvons cinq niveaux de la maintenance :

Niveau 1 : Ce sont des actions simples et nécessaires pour assurer que la machine se fonctionne sans problème, généralement réalisés par les opérateurs machine. Par exemple : graissages, test de voyant.

Niveau 2 : Ce sont des actions simples nécessitent des procédures simples. Par exemple : changement de pièces de rechange (rail, glissière, galet, rouleaux, chaîne, fusibles, courroies, ...)

Niveau 3 : L'identification et le diagnostic de pannes. Par exemple : vérification et réglages impliquant l'utilisation d'outils de mesure.

Niveau 4 : Des travaux importants de maintenance corrective ou préventive. Par exemple : analyse des huiles, analyse vibratoire, etc...

Niveau 5 : L'ensemble des opérations et des modifications importantes qui nécessite des techniques ou technologies particulières et une main d'œuvre qualifiée. Par exemple : le démontage complet d'une machine, la réparation d'un équipement.

2.4. Les objectifs de la maintenance :

Les objectifs de la maintenance sont nombreux, on peut citer :

- Assurer la sécurité et la prévention des machines et des employés au travail.
- Améliorer la productivité et augmenter de la production par la réduction de la fréquence des pannes ce qui consolider la compétitivité de l'entreprise.
- Maximiser la durée de vie de l'équipement.
- Réduire le temps d'arrêt de production.

2.5. Pratique de la maintenance préventive conditionnelle :

Le principe consiste à suivre l'état de fonctionnement (et son évolution) des équipements en exploitation grâce à différentes technologies basées sur la mesure de paramètres physiques (vibrations, analyse d'huile, etc.), permettant ainsi de diagnostiquer et d'organiser en amont les interventions de maintenance. [2]

Dans ce contexte, il est nécessaire de connaître les différents éléments principaux de la machine tournante, notamment les engrenages et les roulements et avoir une idée sur les différents défauts qui peuvent apparaître.

3. Les roulements et leurs défauts :

3.1. Définition de roulement :

Un roulement est un élément mécanique qui se compose d'une bague externe et interne, d'une cage et de billes (figure I.2). Cet élément est responsable d'assurer le guidage en rotation et qui s'interpose entre deux parties d'une machine dont l'une est tournante et l'autre est fixe.

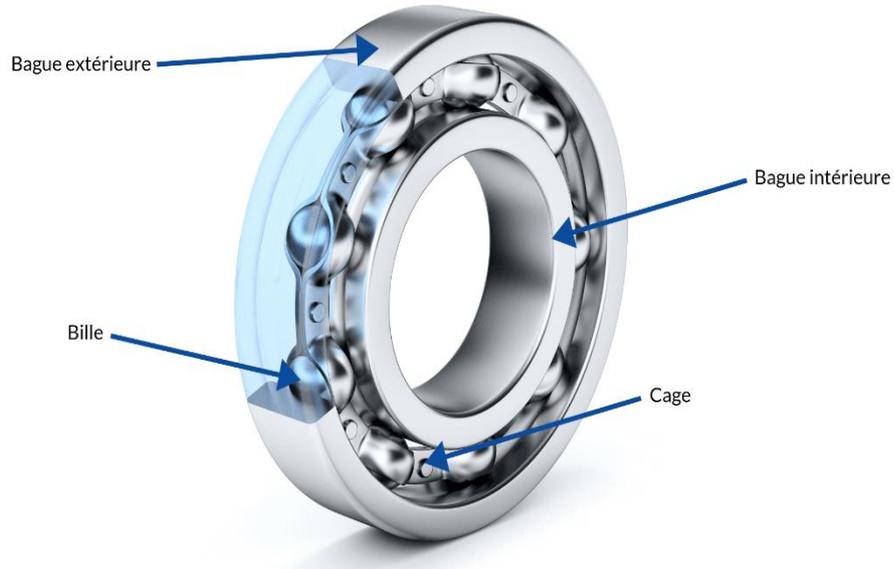


Figure I.2 : Schéma d'un roulement à billes.

Selon les besoins et les conditions : la vitesse limite de rotation, les charges radiales et axiales supportées ou même de défaut d'alignement admissible, on trouve six familles principales de roulements sont illustrées dans la figure I.3.

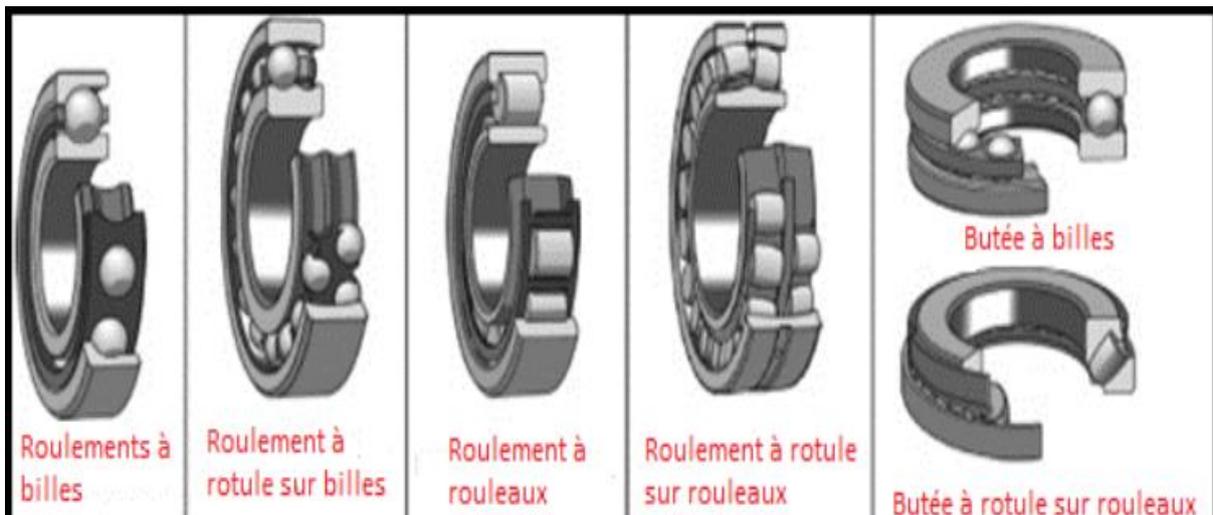


Figure I.3 : Les principales familles de roulements.

3.2. Les défauts de roulements :

Les défauts de roulements peuvent être proviennent de :

- La charge et la vitesse appliquée.
- La lubrification.
- Le montage.
- Autres effets divers d'environnement.

Parmi les nombreux défauts qui peuvent se trouver dans un roulement, citons :

3.2.1. L'usure :

Les roulements sont soumis à une usure normale en raison de la charge, de la vitesse et de la durée de fonctionnement. Au fil du temps, cela peut entraîner une perte de lubrification et une détérioration des surfaces de roulement, conduisant à une défaillance sous forme des empreintes apparaîtront sur les différentes composantes.

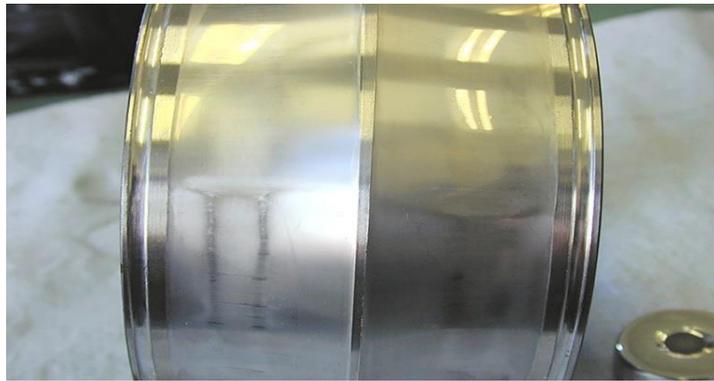


Figure I.4 : Usure dans une bague intérieure d'un roulement.

3.2.2. L'écaillage :

Il existe deux types de défauts d'écaillage : écaillage de fatigue et écaillage superficiel, le premier type est lié aux caractéristiques du matériau d'une part et du lubrifiant d'autre part et peut être présent sous forme de fissuration (figure I.5.a), tant que le deuxième peut être définie comme un ensemble des tâches en surface provenant d'arrachement superficiel de métal (figure I.5.b).



Figure I.5.a : Écaillage de fatigue.



Figure I.5.b : Écaillage superficiel.

3.2.3. Le grippage :

Le grippage est la déformation de différentes composantes de roulement avec un changement de couleur en raison de la surchauffe soudaine de l'élément au cours de travail, plusieurs facteurs peuvent contribuer au grippage des roulements, notamment : Lubrification insuffisante, vitesse de rotation excessive, entrée d'eau, flexion excessive de l'arbre.

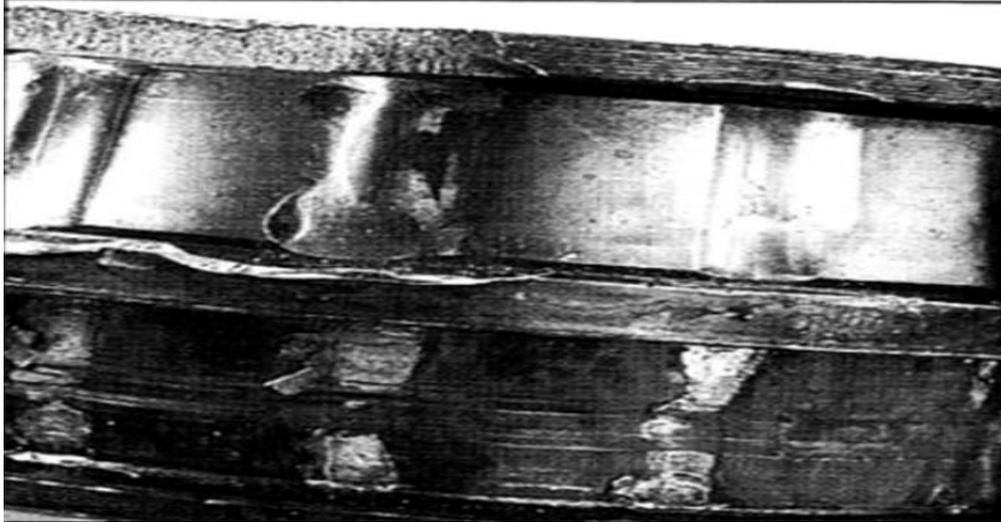


Figure I.6 : Grippage d'un roulement.

3.2.4. La corrosion :

La corrosion est le résultat de la pénétration de l'eau dans le roulement, elle se manifeste par des piqûres à la surface des bagues et des billes. Il existe d'autres facteurs qui peuvent survenir la corrosion tels que : entrée de gaz corrosif, lubrifiant incorrect, température et humidité élevée qui peut entraîner la formation des gouttes d'eau et ensuite de la corrosion.



Figure I.7 : La corrosion.

4. Les engrenages et leurs défauts :

4.1. Qu'est-ce que un engrenage ?

Un engrenage est l'ensemble de deux roues dentées engrenant l'une avec l'autre permettant la transmission de la puissance entre deux arbres rapprochés parallèles, concourants ou bien de position quelconque avec un rapport de vitesse constant.

Il existe quatre familles principales d'engrenages :

- Les engrenages cylindriques à dentures droites.
- Les engrenages cylindriques à dentures hélicoïdales.
- Les engrenages coniques.
- Les engrenages gauches (système roue-vis sans fin).



Figure I.8 : Les grandes familles d'engrenages.

4.2. Fréquence d'engrènement :

Si nous considérons un engrenage de deux roues dentées de Z_1 et Z_2 dents, et tournent aux fréquences de rotation respectivement F_1 et F_2 . Ces deux roues dentées s'engrènent à une fréquence dite la fréquence d'engrènement F_e qui est donnée par la formule suivante :

$$F_e = Z_1 \times F_1 = Z_2 \times F_2 \quad (I.1)$$

4.3. Les défauts d'engrenages :

Il existe deux types de défauts d'engrenages : les défauts repartis tout au long de la denture et les défauts localisés sur une partie de la denture.

4.3.1. Les défauts répartis sur toutes les dents :

a. L'usure de la surface de la dent :

Au cours de glissement de deux dents entre eux d'un engrenage sous contrainte, ce glissement provoque une usure de la surface de dent et qui entraîne une transmission instable à cause de la destruction de la forme de la surface de la dent.

b. Défaillance par fatigue des dents d'engrenages :

C'est un défaut dû à la surcharge d'engrenage pendant une longue période, ce qui provoque la rupture des dents.

c. Les piqûres :

En raison de contraintes élevées appliquées sur l'engrenage cela provoque des petites fissurations. Au fil de temps, ces fissurations se propagent le long de la surface de la dent en formant des petites piqûres qui se présentent sous la forme des cavités de différentes tailles.



Figure I.9 : Des piqûres sur les dents.

4.3.2. Les défauts localisés sur une partie de la denture :

a. L'écaillage :

On peut définir l'écaillage comme étant les piqures qui se produisent seulement dans une partie de la denture, ce type de défauts est lié à l'absence de film d'huile entre les surfaces des dents.

b. le grippage :

C'est l'un de phénomènes indésirables résulte de la rupture du film lubrifiant entre les surfaces d'engrenages en raison d'une surchauffe ou d'une pression excessive.



Figure I.10 : Grippage des dents.

c. Les fissures :

Ce type de défauts peut être produit lors de la fabrication (la nature de matériau : il peut être défectueux ainsi que la procédure de l'obtention peut créer des fissures) ou le montage de l'engrenage, ce qui provoque un bruit d'engrènement et alors une grande nuisance sonore et vibratoire.

5. Synthèse bibliographique :

Dans cette partie, nous présentons une synthèse bibliographique de quelques travaux qui ont été fait dont l'objectif est de déterminer et diagnostiquer les défauts d'engrenages et de roulements par l'analyse vibratoire ainsi la classification de ces défauts en utilisant les réseaux de neurones artificiels (ANN).

L'analyse vibratoire :

Le diagnostic vibratoire de défauts d'engrenages et de roulements est un domaine crucial pour la maintenance préventive des systèmes industriels. Dans ce contexte, de plusieurs recherches et travaux ont été faits afin de présenter les diverses méthodes de l'analyse vibratoire utilisées et leur efficacité à diagnostiquer les défauts d'engrenages et de roulements.

A.Djebala et al. [3] ont fait une étude qui se concentre sur la maintenance conditionnelle des machines à travers l'analyse vibratoire, cette étude examine le cas d'un défaut localisé sur une roue et d'un autre défaut sur un pignon à l'aide d'expérimentations réalisées sur un banc d'essai. Dans ce contexte, ils ont proposé une méthodologie numérique et expérimentale pour faciliter la détection et la surveillance vibratoire des défauts des dents d'engrenages en utilisant des points de mesure situés sur les roulements d'un banc d'essai pour permettre un suivi vibratoire efficace dont l'objectif est de définir des indicateurs temporels sensibles et capables de détecter un défaut d'engrenages dans différentes configurations.

Les résultats obtenus en simulation correspondent étroitement aux résultats expérimentaux. En effet, le kurtosis semble être l'indicateur le plus adapté pour détecter les défauts de type choc, notamment dans les engrenages. Cependant, sa sensibilité est limitée, surtout lorsque le nombre de défauts augmente. De plus, il reste sensible à la bande de fréquence du signal ainsi que la taille du défaut. Le facteur de crête est moins sensible que le kurtosis, et moins sensible que le RMS, ces deux derniers sont plus sensibles à l'amplitude du signal plutôt qu'à sa forme, ce qui fait le kurtosis l'indicateur scalaire de premier choix et même fiable. Enfin, d'autres facteurs comme le couple appliqué et le graissage ont une grande influence sur la variation des indicateurs scalaires et même les outils d'analyse fréquentielle ou ils ont montré également que la détection de défauts sera mieux lorsque le roulement est graissé ou lorsque les engrenages sont soumis à des chargements.

De même chose, A. Boukar et N.Hamzaoui [4] ont fait une étude pour évaluer la capacité des indicateurs scalaires à détecter les défauts de roulements et d'engrenages et leurs gravités dans différentes configurations de défauts créés sur l'engrenage et sur le roulement d'un banc d'essai expérimental. Les signaux vibratoires ont été pris à l'aide de sept voies. Les résultats obtenus montrent que le kurtosis est plus sensible aux chocs engendrés par le défaut d'engrenage que par le défaut de roulement ainsi que le RMS, le facteur crête à crête F_{cc} et le facteur de crête F_c . Pour cela et pour suivre l'évolution de la gravité de l'état du roulement il est nécessaire de trouver un autre indicateur, c'est le facteur K. Dans le cas d'un roulement défectueux (défaut de cage), plus que la vitesse augmente plus que le facteur K augmente et devient important. Enfin, ce n'est pas seulement la vitesse qui affecte l'évaluation de défaut mais même la charge, les indicateurs scalaires seront plus efficaces à la détection de défauts lorsque les engrenages sont chargés.

R.Younes et al. [5] ont fait une analyse vibro-acoustique des différents signaux dans le cas d'un ou de plusieurs défauts combinés, tels que les défauts de roulements et d'engrenages. L'objectif est d'identifier chacun des défauts même lorsqu'ils sont combinés. Cette étude a été déterminée à l'aide d'un banc d'essai qui se compose de deux transmissions par engrenage et trois paliers à roulements et un accéléromètre pour mesurer les signaux vibratoires, pour différentes vitesses de rotations et différentes bandes fréquentielles.

Les auteurs ont commencé par l'étude des indicateurs scalaires temporels : le kurtosis est un indicateur très sensible et efficace à l'évaluation d'un mono-défaut soit le défaut d'un engrenage ou d'un roulement mais sa sensibilité se diminue au cas d'un défaut combiné et l'évolution des autres indicateurs scalaires (RMS, V_c , F_c , K , ...) n'est pas linéaire avec la détérioration du défaut combiné ; il est donc difficile de surveiller l'état du défaut avec un seul indicateur.

Ensuite, pour une vitesse de 15 Hz et une bande de fréquence 12800 Hz, une analyse perceptive des sons correspondant aux différents types de défauts a été établie pour étudier la sensibilité des auditeurs aux défauts combinés et la possibilité de distinguer les différents types de défauts de même ou de natures différentes où ils pourraient de classer les sons selon le type des défauts et son niveau de gravités.

R. CHAIB et al. [6] ils ont fait une étude sur la surveillance par l'analyse vibratoire s'un roulement à rangé à billes et à contact oblique, sous une charge purement radiale constante et de différentes vitesses de rotation auquel la bague extérieure est fixe et la bagues intérieure est montée sur un axe tournant. Ce travail consiste à l'évaluation d'un seul indicateur scalaire -le kurtosis- en utilisant deux accéléromètres l'un est parallèle et l'autre est perpendiculaire à la charge.

Les résultats obtenus montrent que la disposition des capteurs par rapport à la charge appliquée est très importante pour l'évaluation du kurtosis, ainsi que ce dernier est un indicateur fiable à la surveillance de roulements au cours du temps.

De nombreux chercheurs s'accordent à dire que le RMS qui caractérise uniquement l'énergie du signal et non sa forme, n'aide pas à diagnostiquer les défauts et cela est confirmé dans leurs travaux. [3/4/7/8].

D'autres études ont été réalisées dans ce domaine en se basant sur les méthodes fréquentielles.

M. Bouamama et K. Reffasi, [9] ont été réalisés une étude pour détecter la détérioration précoce d'un roulement à l'aide de spectre, ils ont trouvés que lorsque le signal analysé est de courte durée ou non stationnaire le technique utilisée actuellement qui est basée sur l'analyse de Fourier, n'est pas efficace, par contre l'analyse cepstrale est l'une des méthodes efficaces pour la détection des défauts a un état précoce.

R. Younes et al. [10] dans ce travail les auteurs ont fait une étude pour détecter les défauts simples et combinés de roulements par l'analyse spectrale, cepstrale et temporelle dans trois cas : cas d'un défaut à la bague interne, cas d'un défaut à la bague externe et cas d'un défaut combiné. Les signaux vibratoires analysés ont été collectés à l'aide d'un simulateur de pannes de machines (The Machinery Fault Simulator MFS) pour deux vitesses de rotation 15 et 25 Hz et deux fréquences maximum 2000 et 6000 Hz. Le but de cette étude est de discrétiser chaque signal vibratoire à des blocs puis calculer l'asymétrie de chacun, ceux correspondant aux valeurs d'asymétrie les plus élevées ont été considérés comme optimaux. A partir de là, des analyses spectrales et cepstrales ont été réalisées. A la fin de l'étude, le cepstre a été considéré comme étant un outil très efficace et fiable à la détection et le diagnostic de défauts de roulements que ce soit un défaut simple ou combiné.

B. Abou El Anouar et al. [11] ils ont fait une étude pour surveiller et détecter les défauts d'engrenages par l'analyse vibratoire dans le cas d'un défaut d'usure sur les dents des engrenages à dentures hélicoïdales en présentant la fiabilité de l'analyse temporel et fréquentiel ainsi que l'influence de graissage. De première étape, ils ont créé un défaut artificiel de type d'usure sur une dent du pignon d'entrée vu qu'il est plus important que la roue de la sortie. Dans le domaine temporel ils ont concentré que sur les deux indicateurs scalaires : le RMS et le Facteur de Crête, à partir des courbes obtenues il était clair que le Facteur de Crête apparait comme étant un indicateur mieux que le RMS à la détection de défauts d'engrenages. Ensuite, ils ont étudié l'influence de graissage à la détection des défauts : plus que l'engrenage est non graisse plus que le niveau vibratoire augmente. Finalement, ils ont preuve que l'analyse fréquentiel est le plus efficace et fiable à la détection de défauts d'engrenages.

H. LUI et al. [12] Dans ce travail une nouvelle méthode a été inventée sous le nom de la transformée d'Hilbert-Huang et son spectre marginal. Cette méthode est très utile au diagnostic des défauts de roulements à rouleaux notamment les défauts des bagues extérieures et intérieures, elle consiste à appliquer la transformée d'Hilbert pour extraire l'enveloppe du signal et le

décomposer à l'aide d'EMD (Empirical Modes Decomposition) pour obtenir des IMFs (Intrinsic mode functions). Ensuite, pour chaque IMF on applique la transformée d'Hilbert-Huang (HHT) afin d'obtenir un spectre marginal. Enfin, en analysant le spectre marginal il sera facile d'identifier les défauts et leur position.

K. Belaid et al. [13] les auteurs ont travaillé à la détection de deux défauts combinés de type choc simulés sur un engrain en utilisant la transformée continue en ondelette en combinaison avec le Kurtosis, cette expérience consiste à créer, pour chaque roue dentée, un défaut sur le flanc de la dent qui a la forme de rayures.

La méthode utilisée consiste à calculer les coefficients d'ondelettes avec un pas très fin (0,1) de discrétisation des échelles pour obtenir une redondance importante. Ensuite calculer le kurtosis pour tous les vecteurs d'échelles, ce qui met en évidence une concentration d'énergie autour de chaque fréquence de résonance excitée par les défauts et finalement analyser les coefficients associés à chaque bosse de redondance sur le graphe du kurtosis pour identifier les défauts qui les ont excités, ce qui permet de détecter efficacement les défauts combinés d'engrenages et faire un diagnostic fiable.

D'autres travaux ont montré l'efficacité de la transformée continue en ondelette dans le diagnostic de défauts. [14-16]

En outre, D. Chikouche et al. [17] ont évalué la performance de la technique du cepstre synchrone à la détection précoce des défauts d'un réducteur à engrenages (une roue de 21 dents et un pignon de 20 dents) et la comparée avec une analyse temporelle effectuée au même réducteur. Les résultats obtenus lors de l'application des deux techniques ont montré l'efficacité du cepstre synchrone à diagnostiquer d'une façon précoce les défauts de deux roues.

Dans [18], S. K. Mishra et al. ont représenté une approche pour évaluer la performance de l'analyse d'enveloppe à la détection de défaut d'un roulement. Cette méthode consiste à décomposer le signal vibratoire à l'aide de la décomposition en mode empirique EMD et obtenir des IMF's. Ensuite, la transformée en Hilbert sera appliquée pour chaque IMF ainsi que le calcul du rapport d'énergie instantanée (IE), celles avec un $IE > 10\%$ et Kurtosis > 3 seront sommées pour construire un signal à filtrer, ce dernier sera traité en utilisant la HFRT. Cette technique a été comparée avec d'autres quatre techniques et elle a prouvé leur performance à la détection de défaut en court temps.

Les RNA :

D'autre part on trouve les réseaux de neurones artificiels qui jouent un grand rôle dans la classification des défauts d'engrenages et de roulements, plusieurs travaux ont été fait dont le but est de prouver et améliorer la fiabilité de ces réseaux artificiels dans le domaine du diagnostic. [19-23]

N. Gharesi et al. [24] Ont proposé une technique avancée basée sur la neuro-ondulation pour diagnostiquer les défauts de roulement, cette technique présente une combinaison de la décomposition modale variationnelle VMD non récursive et un réseau de neurones basé sur les ondes. Elle est basée sur le traitement des signaux vibratoires pour extraire des informations sur les défauts de roulement, suivie d'une réduction de dimension pour améliorer la charge computationnelle, en introduisant un réseau de neurones à ondelettes pour la classification de ces défauts, bénéficiant des avantages de la transformation en ondelettes et des réseaux de neurones artificiels telles que la précision élevée et la réduction du temps de diagnostic.

H. Sa. Kumar et al. [25] L'article discute de la surveillance de l'état des roulements à éléments roulants en utilisant la transformation en ondelettes discrètes DWT et les réseaux de neurones artificiels ANN. Cette étude a prouvée l'efficacité de la DWT dans l'analyse des signaux vibratoires collectés à l'aide des accéléromètres en les décomposer pour extraire des caractéristiques statistiques importantes. Ensuite, ces caractéristiques extraites seront utilisées sont utilisées pour entraîner un classificateur ANN : le perceptron multicouche (Multilayer Perceptron), améliorant la performance de la classification des défauts.

Ces méthodes permettent une évaluation précise de l'état des roulements et facilitent la maintenance prédictive des machines rotatives.

Rajeswari. Ca et al. [26] Ce travail a prouvé l'efficacité de la transformée en ondelettes continue CWT dans l'analyse des signaux vibratoires. Ensuite, les auteurs ont employés l'algorithme génétique (GA) et la théorie des ensembles approximatifs (Rough Set RS) dont le but est de sélectionner les meilleures entrées et de réduire le temps de calcul. Enfin, à l'aide de deux techniques : le réseau de neurones a propagation arrière (BPNN) et l'algorithme C4.5, ils ont pu de classifier les différents défauts d'engrenages en montrant la précision de classification de ces algorithmes (le BPNN et le GA combiné avec le RS ont prouvé leurs efficacité à la classification mieux que l'algorithme C4.5).

D'autres travaux ont prouvé et présenté l'efficacité de la combinaison des réseaux de neurones artificiels avec les algorithmes génétiques à la détection et diagnostic des défauts [27].

H. M. Ertunc et al. [28] À l'aide des réseaux de neurones artificiels (ANN) et les systèmes d'inférence neuro-floue adaptatifs (ANFIS) les auteurs ont proposé une nouvelle technique en développant un algorithme de décision multi - étapes pour améliorer le diagnostic des défauts de roulements : deux défauts ont été créés l'un est un défaut à la bague extérieure et l'autre à la bague intérieure. Cet algorithme est très efficace à la détection et le diagnostic des défauts de roulements.

Les réseaux de neurones artificiels convolutifs en prouvent leur efficacité à la classification des défauts soit à l'aide du spectre [29-31].

Dans [32], J. Hu et al. ont utilisé l'une des méthodes de classification non supervisée : Les cartes auto-organisatrices (SOM) pour évaluer la dégradation des défauts d'un roulement à billes en la combinée avec la transformée en ondelette discrète pour extraire les caractéristiques des défauts, y compris les défauts faibles, qui sont considérées comme des fissures dans les deux bagues et les billes. Ensuite ces défauts sont cartographiés à l'aide du réseau SOM sous des U-Matrices où la dégradation se suivie la même trajectoire pour les trois modes de défaillances. Cette méthode peut être utilisée en future pour évaluer la durée de vue utile restante du roulement.

En outre, L. Zhang et al. [33] ont prouvé autre fois l'efficacité des cartes auto-organisatrices à classifier les défauts d'un roulement à rouleaux et identifier avec précision ces conditions de santé, ce qui est essentiel et important pour la maintenance. Ils ont utilisé la décomposition en mode empirique EMD pour décomposer les signaux vibratoires et ensuite les cartographier à l'aide de SOM. Les résultats obtenus montrent que les cartes auto-organisatrices ont une précision de 99.28%, ce qui les rend un outil effectif à la détection des défauts de roulements.

Dans [34], S. Alia et al. On met la lumière à l'importance d'utiliser des outils avancés d'apprentissage automatique pour faire un diagnostic précis des défauts de roulements. En première étape, les signaux vibratoires ont été traités à l'aide de la décomposition en mode variationnel (VMD) suivie d'une démodulation d'enveloppe pour les fonctions en mode intrinsèque (IMF) résultantes. Ensuite, Les caractéristiques extraites du signal de vibration sont mappées dans un espace de faible dimension à l'aide de l'algorithme SOM. Cette étude a montré la capacité de SOM à la classification des défauts différents d'un roulement avec précision grâce à l'apprentissage automatique.

En outre, C. Lu et al. [35] ont appliqué une approche qui consiste à réduire le dimensionnement des défauts à classer, le PCA-SOM, les signaux vibratoires collectés sont tout d'abord traités en

utilisant la technique de EMD afin d'obtenir des IMF's. Ensuite, le PCA (Analyse en Composantes Principales) sera appliqué pour réduire le nombre d'entrées de SOM. Deux expériences ont été menées pour valider l'efficacité de cette approche.

6. Conclusion :

Dans ce chapitre, nous avons constaté l'importance de la maintenance prédictive dans le domaine de la mécanique et son utilité au surveillance et diagnostic des défauts de roulements et d'engrenages en se basant de nombreux techniques représentées dans la synthèse bibliographique, ainsi que la capacité et la fiabilité des réseaux de neurones artificiels a classifier ces défauts.

Références Bibliographiques :

- [1] AFNOR. (2001). *Terminologie de la maintenance (NF-EN-13306-X-60-319)*.
- [2] Alia, S. (2020). *Contribution à la détection et au diagnostic des défauts des moteurs par l'application de l'analyse vibratoire* (Thèse de doctorat). Université EL MANNAR, Tunis.
- [3] Benchaabana, C., Djebala, A., Ouelaa, N., & Guenfoud, S. *Diagnostic Vibratoire des Défauts d'Engrenages Basé sur les Indicateurs Scalaires*. Groupe Comportement Dynamique des Structures et Maintenance Industrielle, Laboratoire de Mécanique et Structures, Université de Guelma.
- [4] Boukar, A., & Hamzaoui, N. (2019). Évaluation des indicateurs de surveillance par analyse vibratoire : Application aux engrenages et roulements. *International Journal of Innovation and Applied Studies*, 25(2), 800-808.
- [5] Younes, R., Ouelaa, N., & Hamzaoui, N. (2015). Optimisation d'indicateurs de défauts combinés d'engrenages et de roulements par la perception sonore. *22ème Congrès Français de Mécanique*, Lyon, 24-28 août.
- [6] Chaib, R., Meziani, S., & Verzea, I. (2004). Surveillance des roulements par analyse vibratoire. *Sciences & Technologie B*, 21, 23-27.
- [7] Pauchad, C. (1997). Crest Factor and Kurtosis Contributions to Identify Defects Inducing Periodical Impulsive Forces. *Mechanical Systems and Signal Processing*, 11(6), 903-916.
- [8] Abou El Anouar, B., Elamrani, M., Elkihel, B., & Delaunois, F. Comparaison des différentes méthodes de surveillance et de détection des défauts de roulements. *JMAT-2016 (Conférence Internationale des Matériaux Innovants & Leurs Applications)*.
- [9] Bouamama, M., Reffasi, K., Elmeiche, A., & El hennani, A. (2015). Détection des défauts des roulements par analyse spectrale. *2ème Conférence Internationale de Mécanique (ICM'15)*, Constantine, Algérie, 25-26 novembre.
- [10] Younes, R., Ouelaa, N., Djebala, A., & Alia, A. (2012). Detection of simple and combined faults in ball bearing by spectral, cepstral and time domain analysis. *3ième Colloque "Analyse Vibratoire Expérimentale"*, Blois, 20-21 novembre.
- [11] Abou El Anouar, B., Elamrani, M., Elkihel, B., & Delaunois, F. Surveillance et détection des défauts d'engrenages par analyse vibratoire.
- [12] Li, H., Zhang, Y., & Zheng, H. (2009). Hilbert-Huang transform and marginal spectrum for detection and diagnosis of localized defects in roller bearings. *Journal of Mechanical Science and Technology*, 23, 291-301.
- [13] Mawuena, S., Shao-Ping, W., & Fang, W. (2012). Bearing fault diagnosis with an improved

high frequency resonance technique. *IEEE International Conference on Industrial Informatics (INDIN)*.

[14] Belaid, K., Miloudi, A., & Slimani, M. (2010). Utilisation du Kurtosis dans le diagnostic des défauts combinés d'engrenages par la transformée continue en ondelettes. *Revue Synthèse*, 22.

[15] Yan, R., Gao, R. X., & Chen, X. (2014). Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal Processing*, 96.

[16] Lin, J., & Zuo, M. J. (2003). Gearbox fault diagnosis using adaptive wavelet filter. *Mechanical Systems and Signal Processing*, 17, 1259-1269.

[17] Chikouche, D., Haloui, N., & Bekka, R. E. Analyse des signaux vibratoires d'un réducteur à engrenage par le cepstre synchrone en vue d'un diagnostic précoce.

[18] Mishra, S. K., Shakya, P., Babureddy, V., & Ajay Vignesh, S. (2021). An approach to improve high-frequency resonance technique for bearing fault diagnosis. *Measurement*, 178.

[19] Paya, B. A., Esat, I. I., & Badi, M. N. M. (1997). Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. *Mechanical Systems and Signal Processing*, 11, 751-765.

[20] Ben Ali, J., Fnaiech, N., Saidi, L., Chebel-Morello, B., & Fnaiech, F. (2015). Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Applied Acoustics*, 89, 16-27.

[21] Chenxi, W., Liwei, N., Rong, J., Xing, W., & Junan, L. (2013). Intelligent identification of bearing using time domain features. *Fourth International Conference on Digital Manufacturing and Automation*.

[22] Liu, C., He, D., Chen, Y., & Luo, Z. (2021). Rolling bearing fault diagnosis of train running gear based on optimized deep residual network. *5th International Conference on Automation, Control and Robots*.

[23] Gundewar, S. K., & Kane, P. V. (2022). Rolling element bearing fault diagnosis using supervised learning methods- artificial neural network and discriminant classifier. *International Journal of System Assurance Engineering and Management*, 13, 2876-2894.

[24] Gharesi, N., Arefia, M. M., Razavi-Farb, R., Zarei, J., & Yin, S. (2020). A neuro-wavelet based approach for diagnosing bearing defects. *Advanced Engineering Informatics*.

[25] Kumar, H. S., Srinivasa Pai, P., Sriram, N. S., & Vijay, G. (2013). ANN based evaluation of performance of wavelet transform for condition monitoring of rolling element bearing. *International Conference on Design and Manufacturing, Procedia Engineering*, 64, 805-814.

[26] Rajeswari, C., Sathiyabhama, B., Devendiran, S., & Manivannan, K. (2014). Gear fault identification using wavelet transform, rough set based GA, ANN and C4.5 algorithm. *12th Global Congress on Manufacturing and Management, Procedia Engineering*, 97, 1831-1841.

- [27] Jack, L. B., & Nandi, A. K. (2002). Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms. **Mechanical Systems and Signal Processing**, 16, 373-390.
- [28] Ertunc, H. M., Ocak, H., & Aliustaoglu, C. (2013). ANN- and ANFIS-based multi-staged decision algorithm for the detection and diagnosis of bearing faults. **Neural Computer and Application**, 22, 435-446.
- [29] Khodja, A. Y., Guersi, N., Saadi, M. N., & Boutasseta, N. Rolling element bearing fault diagnosis for rotating machinery using vibration spectrum imaging and convolutional neural networks. **The International Journal of Advanced Manufacturing Technology**.
- [30] Han, B. (2023). A dilated convolution neural network for gear fault diagnosis. **IEEE International Conference on Image Processing and Computer Applications**.
- [31] Kumar, A., Zhou, Y., Gandhi, C. P., Kumar, R., & Xiang, J. Bearing defect size assessment using wavelet transform based deep convolutional neural network (DCNN). **Alexandria Engineering Journal**.
- [32] Hu, J., Zhang, L., & Liang, W. (2011). Degradation assessment of bearing fault using SOM network. **Seventh International Conference on Natural Computation**.
- [33] Zhang, L., Wu, J., Wu, R., Zhen, C., & Lei, B. (2019). Recognition of rolling bearing based on EMD and SOM neural network. **Prognostics and System Health Management Conference**, Qingdao.
- [34] Nouioua, I., Younes, R., Mrabti, A., Meddour, I., & Alia, S. (2023). Self-organizing maps and VMD for accurate diagnosis of bearing defects. **Journal of Vibration Engineering & Technologies**.
- [35] Lu, C., Yuan, H., & Tang, Y. (2014). Bearing performance degradation assessment and prediction based on EMD and PCA-SOM. **Journal of Vibroengineering**, 16.

Chapitre II:

L'analyse vibratoire.

1. Introduction :

Tous les organes mécaniques ont un temps de bon fonctionnement qui peut varier considérablement en fonction de divers facteurs tels que la qualité du matériau (Les matériaux de haute qualité, résistants à la fatigue et à l'usure, prolongent la durée de vie des organes mécaniques), les procédures de fabrication et d'usinage, ainsi que les techniques de montage (Un montage précis et correct est essentiel pour assurer le bon fonctionnement des organes mécaniques. Des erreurs de montage peuvent entraîner des contraintes excessives, des désalignements et des vibrations, réduisant ainsi la durée de vie des composants). Ces facteurs influencent directement la durabilité et la fiabilité des composants mécaniques, rendant certaines pièces plus susceptibles de défaillance que d'autres. Dans ce contexte, la maintenance conditionnelle joue un rôle crucial en permettant une surveillance continue des différents composants et en détectant les anomalies avant qu'elles ne causent des pannes coûteuses ou des accidents.

2. Les techniques d'analyse :

Il existe plusieurs méthodes d'analyse et diagnostic des défauts tel que :

- L'analyse d'huile.
- L'analyse acoustique.
- La thermographie infrarouge.
- L'analyse vibratoire.

Dans notre travail, parmi ces techniques on s'intéresse par **l'analyse vibratoire**.

3. La politique des vibrations :

3.1. Qu'est-ce qu'une vibration ?

On dit qu'un corps vibre lorsqu'il décrit un mouvement oscillant autour d'une position de référence, autrement dit que la vibration est un mouvement autour d'une position d'équilibre.

Selon la norme NFE 90-001[1] : Une Vibration est une variation avec le temps d'une grandeur caractéristique du mouvement ou de la position d'un système mécanique lorsque la grandeur est alternativement plus grande et plus petite qu'une certaine valeur moyenne ou de référence.

L'origine de ces vibrations est les forces excitatrices appliquées sur la structure.

3.2. Les caractéristiques principales des vibrations :

a. L'amplitude :

L'une des caractéristiques principales d'une onde vibratoire est l'amplitude : c'est la valeur de ses écarts par rapport au point d'équilibre et on peut définir :

- L'amplitude maximale par rapport au point d'équilibre appelée amplitude crête (A_c) ou niveau crête.
- L'amplitude double, aussi appelée l'amplitude crête à crête (A_{cc}) (peak to peak, en anglais) ou niveau crête-crête.
- L'amplitude efficace (A_{eff}), aussi appelée RMS (Root Mean Square) ou niveau efficace. [2]

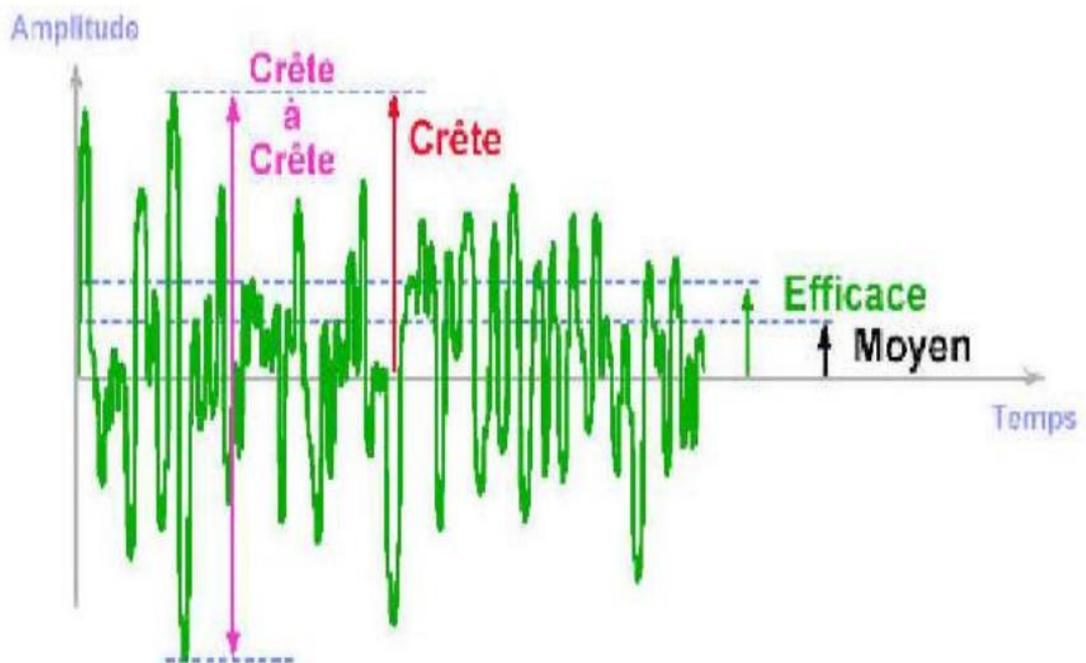


Figure II.1 : Les différentes amplitudes.

b. La période :

La période T d'un signal vibratoire est la durée pour déterminer un cycle, pour une onde progressive périodique : c'est la durée nécessaire pour qu'un élément se retrouve dans le même état vibratoire, son unité est la seconde (s).

c. La fréquence :

La fréquence est l'inverse de la période : $f = 1/T$

Elle peut être définie comme le nombre de répétition d'un phénomène dans un temps donné et est mesurée en **Hertz [Hz]** avec **1 Hz= 1 cycle/seconde**.

3.3. Les types de vibrations :

On peut distinguer trois types différents de vibrations :

a. Vibrations harmoniques :

La forme la plus simple de vibrations, autrement dit vibration périodique sinusoïdale : c'est le cas où un corps quelconque parcourir la même distance avec la même vitesse au bout de le même intervalle de temps de durée T.

Une sinusoïde est une courbe alternative où la valeur moyenne est nulle, représentée par une fonction mathématique simple (figure II.2)

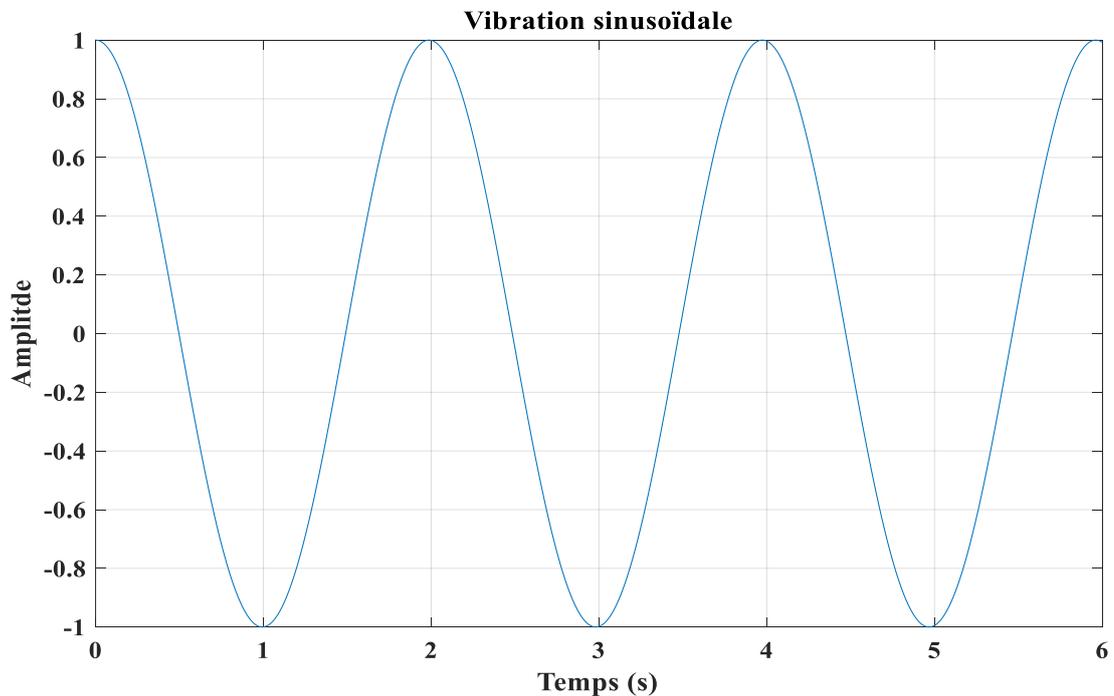


Figure II.2 : vibration sinusoïdale.

Elle est décrite par l'équation suivante :

$$x(t) = X \sin(\omega t + \varphi) \tag{II.1}$$

Avec :

ω : Fréquence angulaire ou pulsation du mouvement ($\omega = 2\pi f$) en [rad/s].

f : Fréquence du mouvement en Hz.

φ : Phase du mouvement par rapport à un repère dans le temps.

b. Vibrations périodiques :

Une vibration périodique est un mouvement oscillatoire qui se répète à intervalles réguliers dans le temps. Cela signifie que les paramètres du mouvement, tels que l'amplitude et la fréquence, suivent un cycle constant et prévisible. (figure II.3). Une telle vibration est créée uniquement par une excitation elle-même périodique.

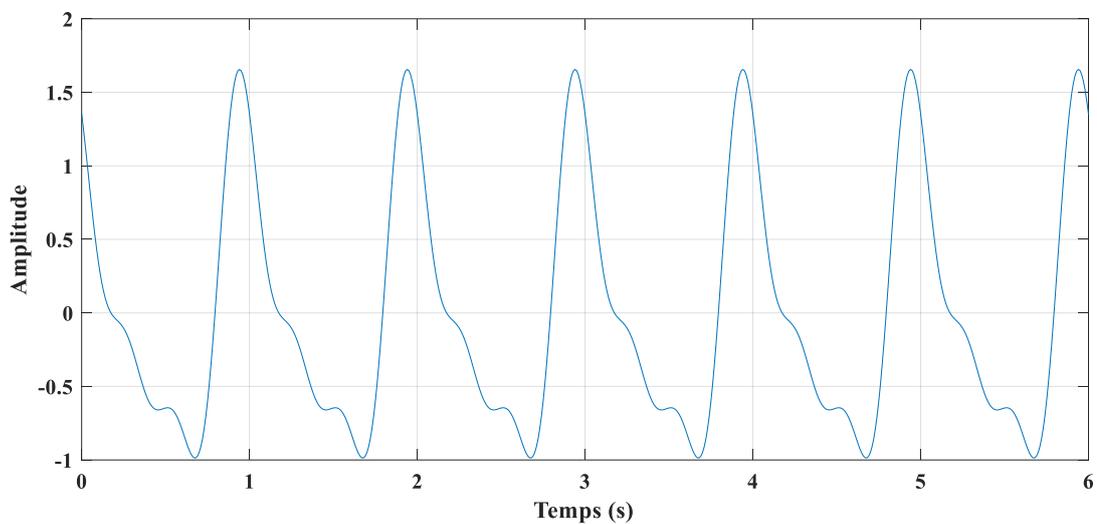


Figure II.3 : vibration périodique.

Elle est décrite par l'équation suivante :

$$x(t) = \sum_{i=1}^{\infty} X_i \sin(\omega_i t + \varphi_i) \quad (\text{II.2})$$

c. Vibrations apériodiques aléatoires (choc) :

Dans certains cas, il n'est pas possible et facile de comprendre le comportement temporel de la vibration d'une structure quelconque, c'est-à-dire que cette vibration n'est pas reproductible avec le temps (figure II.4). Par exemple dans le cas d'un défaut de lubrifiant sur un roulement.

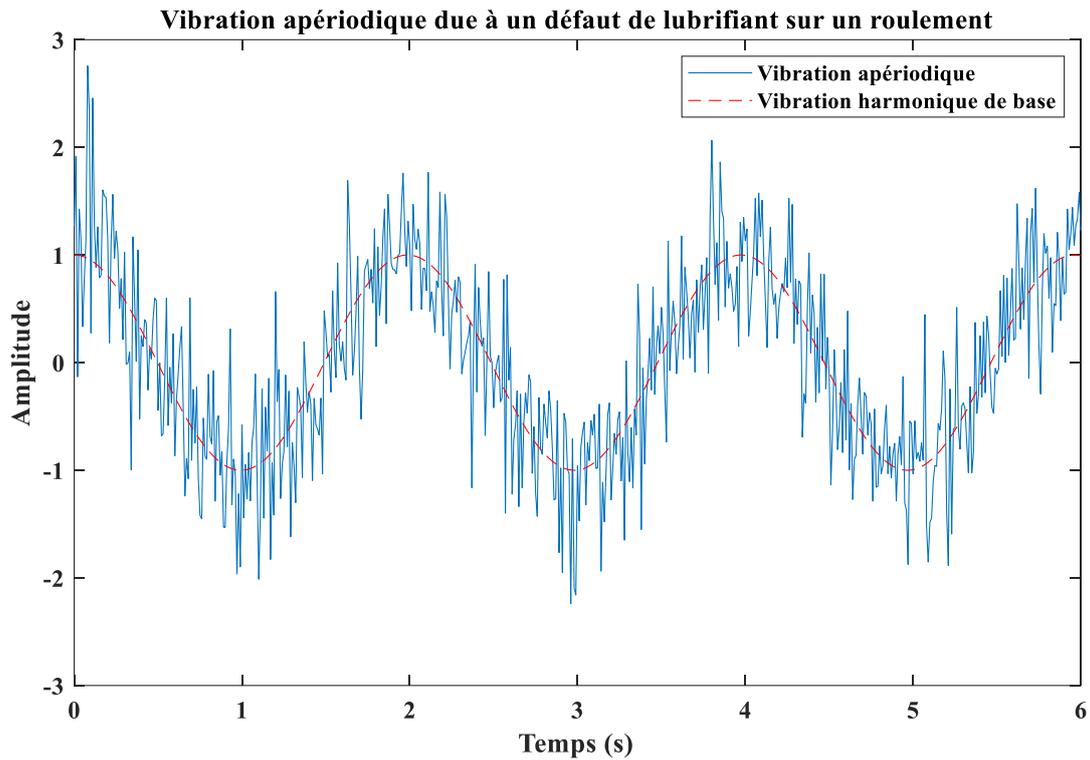


Figure II.4 : vibration aperiodique.

La forme du signal vibratoire nous donne des informations qui servent à détecter et localiser les différents défauts d'engrenages et de roulements.

4. La surveillance et le diagnostic :

La surveillance peut être définie comme étant l'opération de suivre de l'évolution des indicateurs d'anomalie d'une machine tournante. Elle consiste à :

- Collecter périodiquement les mesures permettant l'extraction des informations pertinentes.
- Suivre **l'évolution dans le temps** de ces mesures.
- Comparer ses valeurs à des seuils prédéfinis.

Le diagnostic est la deuxième étape de l'analyse vibratoire, il nous permet à localiser l'élément défectueux d'une machine tournante suite à une évolution anormale des vibrations constatée lors de la surveillance. Pour cela, avant de diagnostiquer un problème il est crucial de comprendre le système ou l'équipement concerné : Quels sont ses composants ? Comment fonctionnent-ils ensemble ? Quelles sont les spécifications et les limites de fonctionnement ? Toutes ces informations servent à faire un diagnostic fiable.

5. L'analyse vibratoire :

5.1. Le principe de l'analyse vibratoire :

L'analyse vibratoire est la méthode de la maintenance préventive conditionnelle la plus utilisée grâce à son efficacité à détecter et diagnostiquer les différents défauts d'engrenages et de roulements dans les machines tournantes.

Une machine tournante, au début de son fonctionnement, a un signal de vibrations régulier mais cela ne cache pas qu'au fil de temps et due à l'usure ses composants notamment les engrenages et les roulements sont sujets à la dégradation ce qui modifie les caractéristiques du signal.

La mesure d'une vibration transmise par la structure d'une machine sous l'effet d'efforts dynamiques sera fonction de multiples paramètres :

- Caractéristiques de fixation de la machine sur le sol qui oppose des réactions aux vibrations et modifie l'amplitude.
- Position et fixation du capteur sur la machine.
- Caractéristiques du capteur : consommation d'énergie, le cout, temps de réponse...etc
- Pré-amplification et transmission du signal.
- Vitesse de rotation et puissance absorbée.
- État des liaisons de la chaîne cinématique (alignement, balourd, engrenages, roulements etc.).

L'analyse vibratoire a comme avantages :

- Les mesures sont faciles à prendre.
- Les défauts sont détectés à un stade précoce.
- Il est possible de réaliser un diagnostic approfondi pour en connaître l'origine. [3]

5.2. Les capteurs des signaux vibratoires :

Pour le diagnostic et la surveillance de défauts de roulements et d'engrenages dans une machine tournante il est nécessaire en premier lieu de convertir le mouvement vibratoire produit à un signal électrique facile à analyser et vu que ce signal vibratoire est caractérisé par trois grandeurs principales (déplacement, vitesse et accélération) alors on distingue trois types des capteurs de vibration :

- Le proximètre (mesure de déplacement).
- Le vélocimètre (mesure de vitesse).
- L'accéléromètre (mesure d'accélération).

En analyse vibratoire des machines tournantes, on utilise principalement des accéléromètres piézoélectriques.

5.2.1. Qu'est-ce que un accéléromètre ?

Un accéléromètre piézoélectrique se compose d'une masse sismique précontrainte qui se repose à un disque en matériau piézoélectrique, c'est-à-dire un matériau qui a la capacité unique de convertir l'énergie mécanique en énergie électrique, ce disque joue le rôle d'un ressort. (Figure II.5)

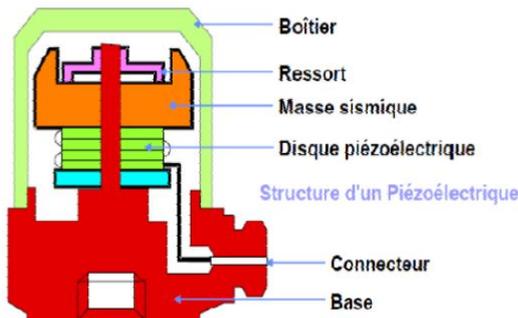


Figure II.5 : coupe longitudinale d'un piézoélectrique. **Figure II.6 :** piézoélectrique.

En cas de dysfonctionnement, la masse sous déplace sous l'effet d'une accélération et exerce des contraintes sur le disque piézoélectrique, induisant à la surface de ce dernier une charge électrique proportionnelle à cette accélération.

5.2.2. Pourquoi l'accéléromètre ?

Ce type de capteurs est le plus utilisé grâce à ces propriétés :

- Utilisables sur de très grandes bandes de fréquences.
- linéarité excellente sur une très grande gamme dynamique (140 dB).
- intégration électronique possible du signal d'accélération pour donner le déplacement et la vitesse.
- Durabilité, car il n'y a aucun élément mobile.

5.3. L'analyse vibratoire dans le domaine temporel :

L'objectif de cette analyse est de détecter le défaut simple ou multiple d'un roulement ou d'un engrenage et d'évaluer sa gravité, en utilisant des indicateurs scalaires qui permettent de suivre l'évolution d'une grandeur dérivant de la puissance ou de l'amplitude crête du signal. Sa valeur peut ne pas avoir de signification intrinsèque, mais c'est son évolution dans le temps qui est significative du défaut. [4]

5.3.1. Le Kurtosis :

Dans [5], le kurtosis a été défini comme étant un paramètre statistique permettant d'analyser la répartition des amplitudes vibratoires contenues dans un signal temporel. Il correspond au moment d'ordre quatre normé. Son expression est de la forme:

$$kurtosis = \frac{M_4}{M_2^2} = \frac{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^4}{\left[\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2 \right]^2} \quad (\text{II.3})$$

Avec M4 et M2 respectivement moments statistiques d'ordre 4 et 2, N le nombre d'échantillons du signal et \bar{s} sa valeur moyenne donnée par :

$$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i \quad (\text{II.4})$$

5.3.2. Facteur de crête :

Le facteur de crête correspond au rapport entre la valeur crête d'un signal (en valeur absolue) et sa valeur efficace [5], il est signe d'une éventuelle dégradation si sa valeur dépasse 6. [10]

Son expression est:
$$FC = \frac{\text{Sup}|s_i|}{\sqrt{\frac{1}{N} \sum_{i=1}^N [s_i]^2}} \quad (\text{II.5})$$

5.3.3. Valeur efficace RMS (Root Mean Square):

C'est un indicateur scalaire très utilisé, bien qu'il présente des inconvénients. Il est sensible à l'effet de masque, c'est-à-dire qu'il peut s'avérer inefficace à l'apparition de certains défauts. Globalement, la valeur efficace ne détecte pas tous les défauts, ce qui représente un inconvénient majeur dans le cadre de la maintenance conditionnelle.

Le RMS a été appliqué avec succès limité pour la détection de défauts localisés. Pour un signal S(t) le RMS est donné par [6] :

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N [s(i)]^2} \quad (\text{II.6})$$

5.3.4. Crête-à-Crête (C-à-C)

Cet indicateur représente la différence entre la valeur max est la valeur min du signal vibratoire.

5.3.5. La valeur crête :

C'est la valeur maximale du signal, pour un signal S(t) la valeur crête est donnée par :

$$valeur\ crête = \text{Sup}|s_i| \quad (\text{II.7})$$

5.3.6. Facteur (FK) :

Le facteur K est défini comme étant le produit entre la valeur crête et a valeur efficace. [4]

$$Facteur\ K = valeur\ crête * valeur\ efficace = \text{Sup}|S_i| * \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i)^2} \quad (\text{II.8})$$

5.4. L'analyse vibratoire dans le domaine fréquentiel :

Dans certains cas et selon la complexité de défauts, l'analyse temporelle n'est pas suffisante pour établir un diagnostic complet. Pour cela on trouve d'autres méthodes plus efficaces et fiables à la détection de défauts qui se reposent sur l'analyse des fréquences.

5.4.1. L'analyse spectrale :

L'analyse spectrale est l'une des méthodes qualitatives qui se basent sur le traitement des données d'un composant quelconque afin d'identifier l'anomalie telle que l'écaillage, le grippage, la corrosion (qui peut entraîner l'écaillage) et d'autres problèmes. Mais elle se concentre sur la recherche des fréquences caractéristiques associées aux éléments constitutifs de roulements et d'engrenages.

Dans ce stade, le signal mesuré est difficile à traiter donc l'en est décomposé en une série de composants élémentaires définis par leurs fréquences et leurs amplitudes. Cette opération sera déterminée à l'aide de **transformée de Fourier** pour nous donner un diagramme appelé **spectre la fréquence et l'amplitude** tel que chaque composant sinusoïdal sera défini par sa fréquence et son amplitude.

La transformation d'un signal $S(t)$ à un spectre $S(f)$ est donnée par la relation mathématique suivante :

$$S(f) = \int_{-\infty}^{+\infty} S(t) \cdot e^{-j2\pi ft} dt \quad (\text{II.9})$$

Nous présentons dans la figure II.7, le spectre d'accélération mesuré sur le palier 3 d'un réducteur dans la direction axiale dans la bande de fréquence [0-25600Hz] tel que la fréquence de rotation d'entrée est de 150 Hz et la fréquence de rotation de sortie est de 25 Hz .Le spectre montre l'apparition de la fréquence d'engrènement $F_e=6125$ Hz et ces harmoniques $2F_e=12250$ Hz et $3F_e=18375$ Hz. La décroissance des amplitudes de F_e et ces harmoniques $2F_e$ et $3F_e$, confirme qu'on a un défaut.

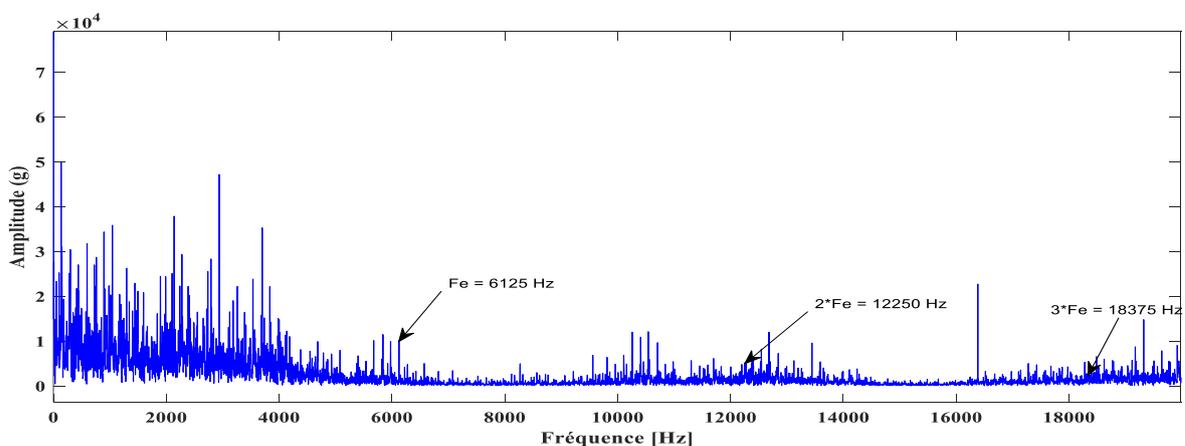


Figure II.7 : Spectre du signal avec un défaut d'engrenages.

5.4.2. L'analyse cepstrale :

Le cepstrum est un outil mathématique qui permet la détection de fréquences dans un spectre de fréquences. Il résulte de la transformée de Fourier inverse d'un spectre de puissance. Le cepstrum harmonique, dans sa représentation graphique, est associé à une famille de lignes ou d'un ensemble d'une seule raie de la bande latérale. Il est utilisé pour le diagnostic des chocs périodiques ou en fréquence de modulation et de phénomènes d'amplitude. [7]

Le cepstre est défini comme étant la Transformée de Fourier inverse du logarithme du spectre de puissance, cette dernière est définie par la relation mathématique suivante :

$$C(\tau) = TF^{-1}[\log_{10}(S(f))] \quad (II.10)$$

- La représentation cepstrale du même signal S(t) sur la figure II.8 montre clairement l'apparition des deux harmoniques des fréquences d'entrée et de sortie du réducteur avec un peignes décroissant de ces harmoniques, ce qui confirme la présence du défaut sur la denture de la roue et du pignon.

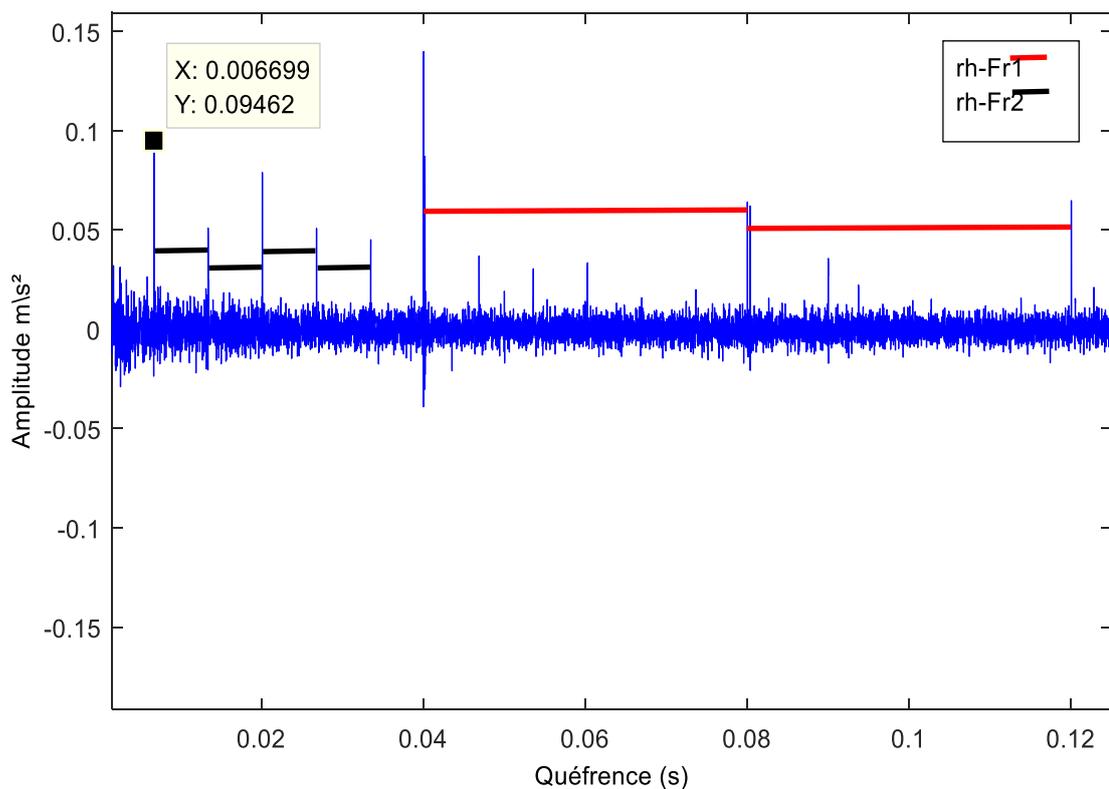


Figure II.8 : Zoom sur le cepstre du signal.

5.4.3. L'analyse d'enveloppe HFRT :

Comme le cepstre, l'analyse d'enveloppe ou la HFRT (High frequency Resonance Technique) est une technique de détection précoce des défauts de type choc qui se repose sur l'étude d'un signal enveloppe obtenu grâce à la transformée de Hilbert [8], qui est définie mathématiquement par la relation suivante :

$$H[S(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{S(\tau)}{t-\tau} d\tau \quad (\text{II.11})$$

À cet effet, les signaux vibratoires sont enregistrés dans une large bande de fréquences et filtrés autour de la fréquence de résonance. Le signal est ensuite redressé « en mettant au positive toutes les valeurs négatives », et la transformée d'Hilbert est appliquée afin de relever son enveloppe et ainsi dissocier, le signal modulé (fréquences de résonance) du signal modulant correspondant au défaut recherché. Le diagnostic final pourra par la suite être rendu après analyse spectrale de l'enveloppe. [9]

La figure II.9 montre le spectre d'enveloppe du même signal S(t), il apparaît clairement sur le spectre, Les fréquences de rotation Fr1 et Fr2 et plusieurs de ses harmoniques, ce qui confirme la présence de défaut sur la roue et le pignon. [10]

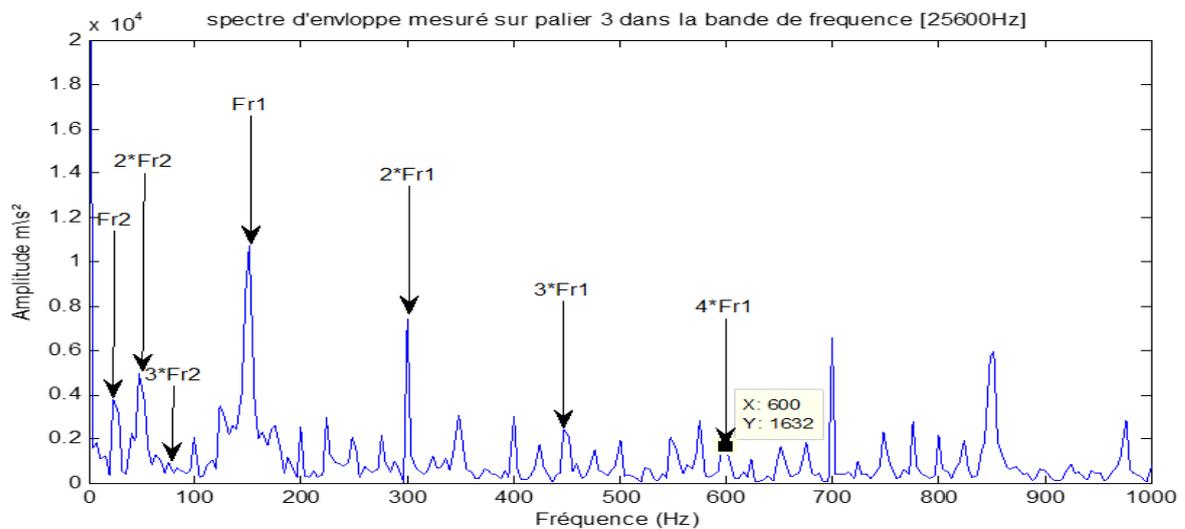


Figure II.9 : Spectre d'enveloppe du signal S(t).

5.5. L'analyse temps-fréquence :

Une analyse spectrale classique basée sur la transformée de Fourier présente un inconvénient sérieux, vu qu'elle suppose que la majorité des signaux sont infinis dans le temps ou périodiques, alors qu'en réalité ils peuvent être de courtes durées comporter des variations au cours du temps d'acquisition. Dans ce contexte, des techniques ont été développées analysant les variations fréquentielles au cours du temps. Parmi ces techniques on trouve : la transformée de Fourier à Court Terme et les techniques à base d'ondelettes.

5.5.1. Transformée de Fourier à court terme -STFT- :

Développée par Gabor en 1946, elle consiste à multiplier le signal ou la fonction à analyser $S(t)$ par une fonction $w(t)$ qui porte le nom 'fenêtre'. L'idée de la transformée de Fourier à court terme « STFT » est de diviser un signal temporel en intervalles à court terme, et de supposer que, dans chaque segment ou intervalle, le signal est stationnaire. En suite en calculant pour chaque portion du signal ou chaque intervalle sa transformée de Fourier grâce à la translation ou le glissement de la fenêtre $w(t)$, un tel signal $S_w(t)$, divisé en segments, appelé «signal fenêtré». [3]

Mathématiquement est donnée par :

$$S_w(t) = S(t) * w(t - \varepsilon) \quad (\text{II.12})$$

Sa transformée de Fourier à court terme donné par :

$$STFT(f, \varepsilon) = \int_{-\infty}^{+\infty} S_w(t) e^{-j2\pi ft} dt = \int_{-\infty}^{+\infty} S(t) * w(t - \varepsilon) e^{-j2\pi ft} dt \quad (\text{II.13})$$

Où STFT (f, ε) est une fonction de la fréquence f et de la position de la fenêtre ε .

La figure II.10 montre un exemple de l'analyse de Fourier fenêtrée du même signal $S(t)$. On voit bien la coloration différente en rouge correspondant à la fréquence de rotation d'entrée $Fr1=150$ Hz et en jaune correspondant à la fréquence de sortie $Fr2=25$ Hz.

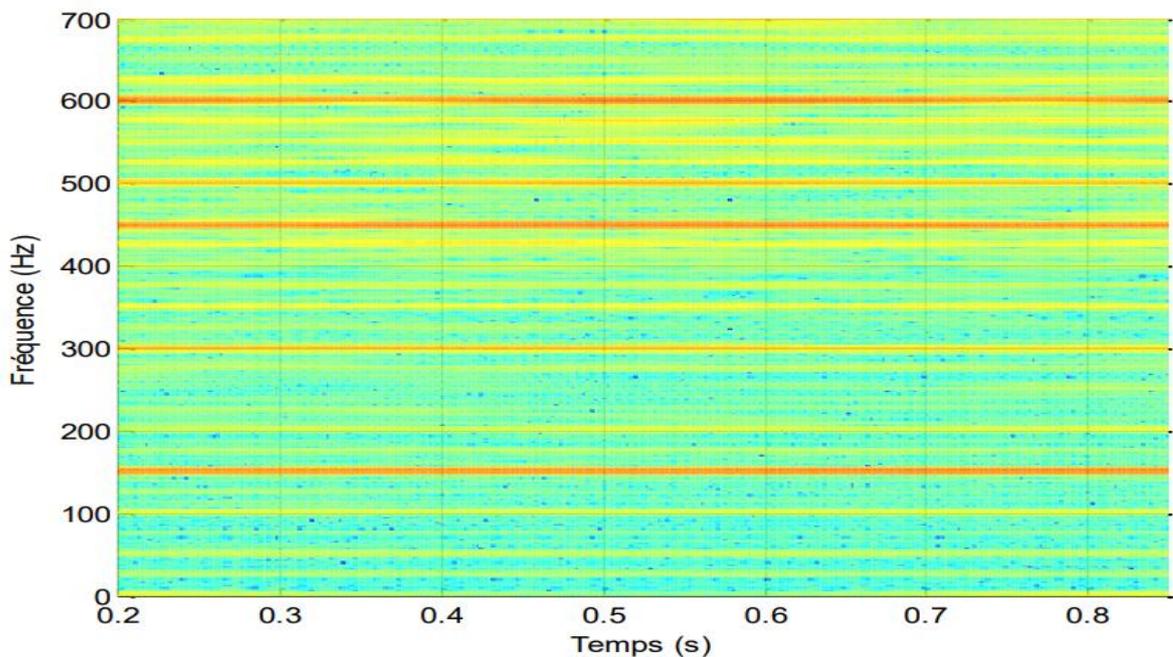


Figure II.10 : STFT du signal S(t).

L'inconvénient de cette méthode est que la longueur de la fenêtre est fixe cela signifie que les résolutions de temps et de fréquence sont fixes pour toute la longueur du signal c'est-à-dire une fenêtre de temps courte se traduit par une bonne résolution temporelle mais une mauvaise résolution en fréquence et vice versa, ceci est décrit par l'inégalité d'Heisenberg

qui est connue sous le nom de principe d'incertitude et est donné par : [11]

$$\Delta t \Delta f \geq \frac{1}{4\pi} \quad (\text{II.14})$$

Pour cela une autre méthode a été inventée, c'est la transformée en ondelettes.

5.5.2. La transformée en ondelettes :

En 1980, J. Morlet proposa une nouvelle analyse peu différente de celle de Gabor. Au lieu d'utiliser une fenêtre qu'on fait coulisser le long d'un signal, Morlet proposa d'utiliser des ondelettes qui sont des fonctions copies les unes des autres mais qui ne diffèrent que par leur taille. Cette technique possède le pouvoir de dilatation et de translation de la fonction analysante que la fenêtre ne possède pas. Un signal peut s'écrire alors sous forme d'une superposition de telles ondelettes décalées et dilatées. Les poids de ces ondelettes dans la décomposition, appelés coefficients d'ondelettes, forment la transformée en ondelettes. [12]

Mathématiquement la famille d'ondelettes se met sous la forme :

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (\text{II.15})$$

Avec a paramètre d'échelle ou de dilatation et b paramètre de translation. En notant ψ^* la conjuguée de ψ la transformée en ondelettes d'une fonction S(t) est définie par :

$$CWT(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} S(t) * \Psi^*\left(\frac{t-b}{a}\right) dt \quad (\text{II.16})$$

Cette transformée est dite continue, notée CWT « Continuous Wavelet Transform », en anglais. La transformée correspondante est souvent nommée TOR (Transformée en Ondelettes Rapide).

La transformée en ondelettes discrète (DWT) est une discrétisation de la transformée en ondelettes continue (CWT). En remplaçant respectivement a et b par 2^m et $n2^m$, avec m et n des entiers, son expression devient :

$$DWT(m,n) = 2^{\frac{-m}{2}} \int_{-\infty}^{+\infty} S(t) * \Psi^*(2^{-m}t - n) dt \quad (\text{II.17})$$

- Une autre version pratique de la transformée en ondelettes connue sous le nom d'Analyse Multirésolution en Ondelettes (AMRO). La première utilisation de cette transformation a été présentée par Mallat en 1989. Cette méthode implique de faire passer la fonction f(t), ou plus précisément le signal s(t), à travers deux filtres passe-bas (L) et passe-haut (H). À ce stade, on obtiendra deux vecteurs : cA1 et cD1. Les coefficients d'approximation du vecteur cA1 correspondent aux fréquences les plus basses du signal, tandis que les coefficients de détail du vecteur cD1 correspondent aux fréquences les plus élevées d'entre elles. On peut répéter la procédure avec les éléments du vecteur cA1 et ensuite avec chaque nouveau vecteur cAk obtenu et ensuite.

Au cours de la décomposition, le signal $s(t)$ et les vecteurs cAk sont sous-échantillonnés, c'est la raison pour laquelle les coefficients d'approximation cAk et de détail cDk passent à nouveaux à travers deux filtres de reconstruction (LR) et (HR). Il en résulte deux vecteurs : Ak , qui sont des approximations, et Dk , qui sont des détails, satisfaisant la relation :

$$A_{k-1} = A_k + D_k \quad (\text{II.18})$$

$$s = A_k + \sum_{i \leq k} D_i \quad (\text{II.19})$$

Où i et k sont des entiers.

Prenant le même signal précède $S(t)$, la figure II.11 représente les différents détails et approximations issus de la décomposition en ondelettes. La figure II.12 montre le spectre d'enveloppe des coefficients d'ondelettes du signal reconstruit ($D2$). Les fréquences de rotation $Fr1$ et $Fr2$ et plusieurs de leurs harmoniques apparaissent clairement sur le spectre, ce qui confirme aussi la présence de défaut sur la roue et le pignon.

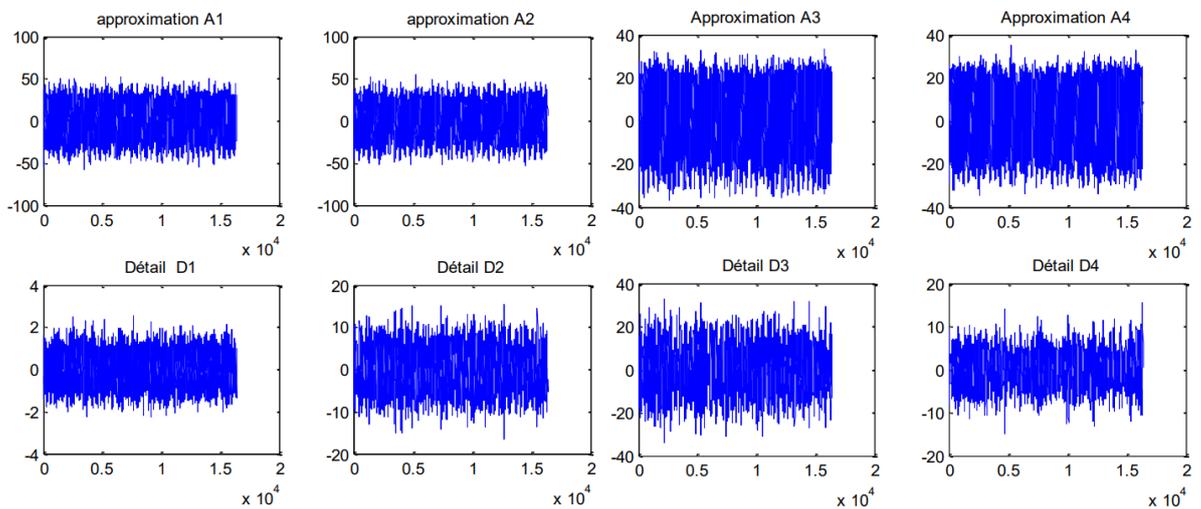


Figure II.11 : Différents détails et approximations issus de l'analyse d'ondelettes du signal $S(t)$.

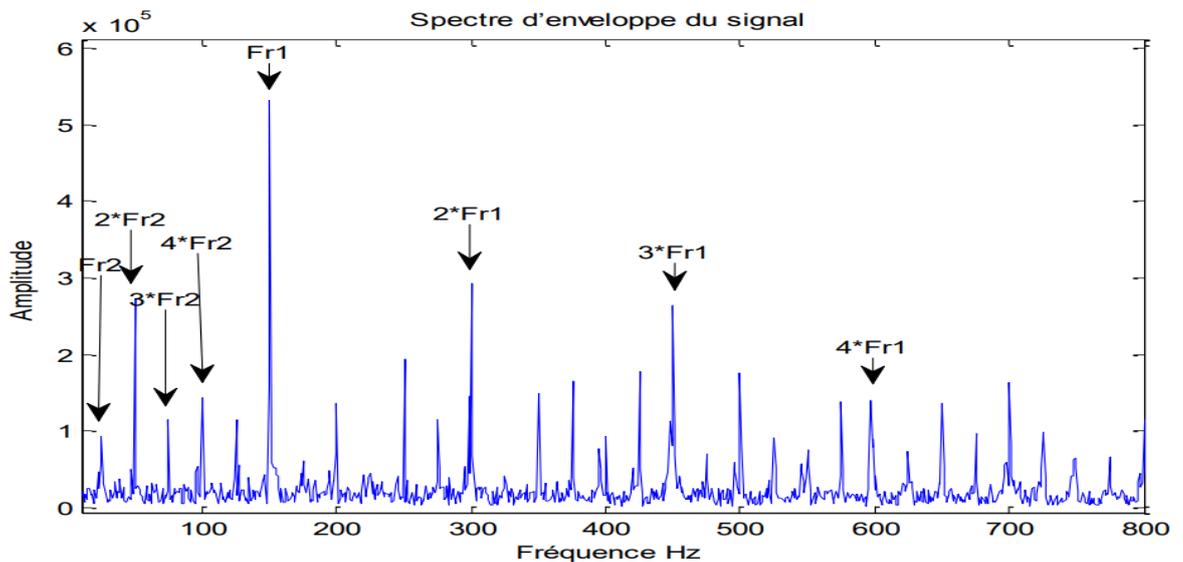


Figure II.12 : Spectre d'enveloppe du signal $S(t)$.

6. Les fréquences caractéristiques :

Chaque composant a des fréquences caractéristiques de référence sur lesquelles nous nous appuyons par rapport à celles capturées en cas de défaut, cette comparaison nous permet à effectuer un diagnostic fiable, ces fréquences peuvent être calculées à partir de les dimensions du composant et de la fréquence de rotation de l'arbre.

6.1. Les fréquences caractéristiques d'un roulement :

Pour un roulement, et en fonction de ses cotes de fabrication, on peut considérer quatre fréquences caractéristiques :

1. BPFO = Ball Pas Fréquence Outre Race = fréquence de passage d'une bille sur un défaut de piste externe.
2. BRFI = Ball Pas Fréquence Inné Race = fréquence de passage d'une bille sur un défaut de piste interne.
3. FTF = Fondamental 1 train Fréquence = fréquence de passage d'un défaut de cage.
4. BSF = Ball Spin fréquence = fréquence de passage d'un défaut de bille sur la bague interne ou externe.

Ces quatre fréquences caractéristiques sont données respectivement par les équations suivantes :

$$BPFO = \frac{N}{2} f_r \left(1 - \frac{D_B}{D_R} \cos\beta \right) \quad (\text{II.20})$$

$$BRFI = \frac{N}{2} f_r \left(1 + \frac{D_B}{D_R} \cos\beta \right) \quad (\text{II.21})$$

$$FTF = \frac{1}{2} f_r \left(1 - \frac{D_B}{D_R} \cos\beta \right) \quad (\text{II.22})$$

$$BSF = f_r \frac{D_B}{D_R} \left(1 - \left(\frac{D_B}{D_R} \cos\beta \right)^2 \right) \quad (\text{II.23})$$

Avec :

N : le nombre de billes ou de rouleaux.

f_r : la vitesse de rotation [tr/s].

D_R : le diamètre moyen du roulement [m], tel que :

$$D_R = \frac{D_1 + D_2}{2} \quad (\text{II.24})$$

D_B : le diamètre de la bille [m].

β : L'angle de contact [rad], correspond à l'angle entre la ligne d'action de la charge, qui joint les points de contact de la bille et les pistes du roulement dans un plan radial, et une ligne perpendiculaire à l'axe du roulement.

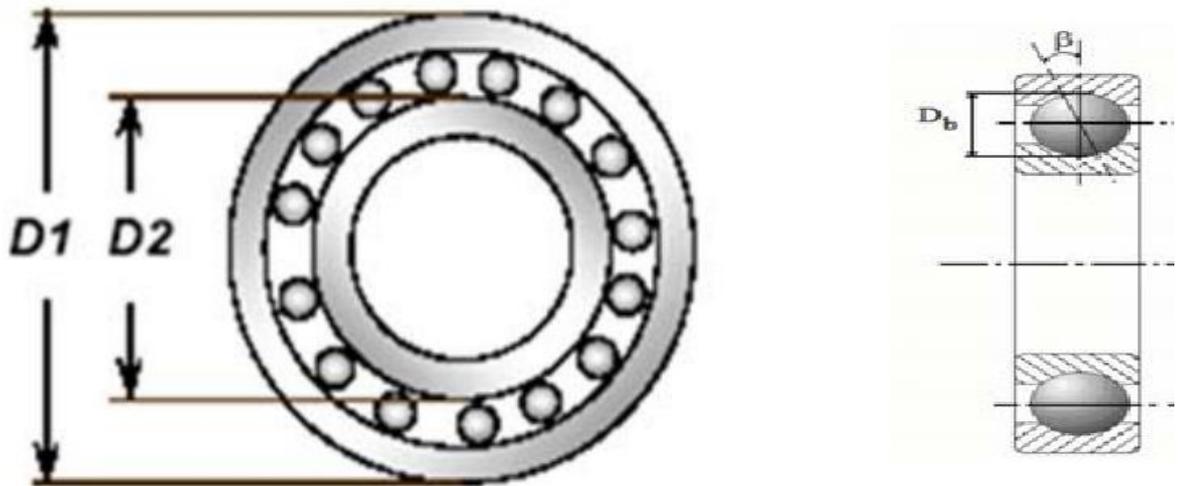


Figure II.13 : Caractéristiques géométriques du roulement.

6.2. La fréquence caractéristique d'un engrenage :

La fréquence caractéristique d'un engrenage est donnée par l'équation suivante :

$$F_c = Nf_r \pm kf_r \quad (\text{II.25})$$

Avec :

N : nombre de dents.

k = 0,1,2,3,...

7. Conclusion :

L'analyse vibratoire est la technique la plus utilisée depuis longtemps grâce à son performance au diagnostic des défauts divers d'engrenages et roulements, et ce chapitre présente une brève théorie des différentes méthodes de cette technique.

Références bibliographiques :

- [1] AFNOR. (1972). *Norme AFNOR NFE 90-001*.
- [2] Kerrouche, Kh. (2020). *Détection des défauts des roulements par analyse spectrale vibratoire* (Mémoire de master). Université Badji Mokhtar Annaba.
- [3] Younes, R. (2015). *Perception sonore au service de l'optimisation du diagnostic des défauts mécaniques de machines tournantes* (Thèse de doctorat). Université de 08 Mai 1945 Guelma.
- [4] Augeix, D. (2005). *Analyse vibratoire des machines tournantes, traité mesure et contrôle*. Techniques de l'Ingénieur BM 5145.
- [5] Djebala, A., Ouelaa, N., Hamzaoui, N., & Guenfoud, S. (2007, avril). Optimisation de l'utilisation des indicateurs scalaires dans le cadre de la maintenance prédictive des paliers à roulements. *Congrès Algérien de Mécanique de Construction*, Alger, 29-30 avril.
- [6] Pachaud, C., Salvétat, R., & Fray, C. (1997). Crest factor and kurtosis contributions to identify defects inducing periodical impulsive forces. *Mechanical Systems and Signal Processing*, 11, 903-916.
- [7] Oulmane, A. (2014). *Surveillance et diagnostic des défauts des machines tournantes dans le domaine temps-fréquences utilisant les réseaux de neurones et la logique floue* (Thèse de doctorat). École Polytechnique de Montréal.
- [8] Fan, X., & Zuo, M. J. (2006). Gearbox fault detection using Hilbert and wavelet packet transform. *Mechanical Systems and Signal Processing*, 20(4), 966-982.
- [9] Trajin, B. (2009). *Analyse et traitement de grandeurs électriques pour la détection et le diagnostic de défauts mécaniques dans les entraînements asynchrones. Application à la surveillance des roulements à billes* (Doctoral dissertation). Institut National Polytechnique de Toulouse-INPT.
- [10] Alia, S. (2020, décembre). *Contribution à la détection et au diagnostic des défauts des moteurs par l'application de l'analyse vibratoire* (Thèse de doctorat). Université EL MANNAR, Tunis.
- [11] Brennan, M. J., & Reynolds, A. G. (1997, mai). *Use of Vibration Measurements to Detect Local Tooth Defects in Gears – an Experimental Study*. ISVR Technical Report No 267.
- [12] Djebala, A. (2008). *Application de transforme par ondelettes à l'étude et l'analyse vibratoire des systèmes mécaniques* (Thèse de doctorat). Construction Mécanique, Université Badji Mokhtar Annaba.

Chapitre III :

Les réseaux de neurones artificiels.

1. Introduction :

Le développement des études et de la recherche et l'explosion de la puissance de calcul et du volume des données ces dernières années ont poussés les chercheurs d'atteindre et développer une nouvelle technologie qui facilitera tout ce qui est difficile, en s'inspirant de cette technologie du modèle neuronal humain : c'est les réseaux de neurones artificiels, la base de l'intelligence artificielle.

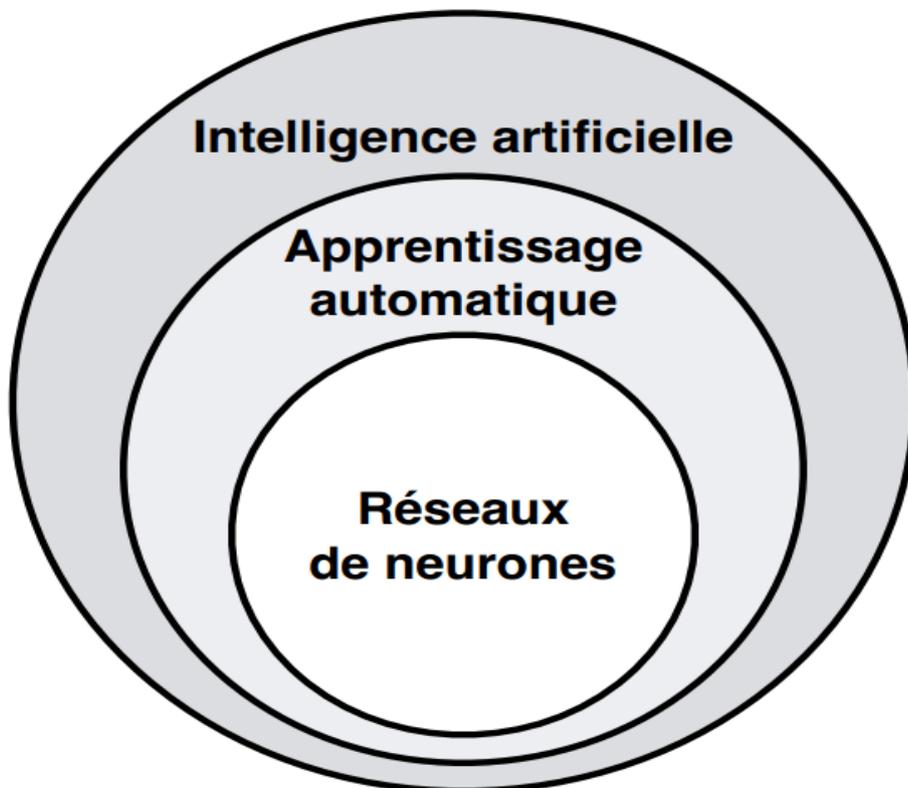


Figure III.1 : Les réseaux de neurones artificiels et l'IA.

2. L'intelligence artificielle :

2.1. Qu'est-ce que l'intelligence artificielle IA ?

En 1956, l'informaticien américain John McCarthy et trois autres chercheurs ont été inventé le concept de l'intelligence artificielle : c'est l'ensemble de théories, de méthodes, de techniques et d'applications d'une machine qui peut imiter et étendre le comportement humain tels que le raisonnement, la planification et la créativité.

2.2. Les domaines d'application de l'intelligence artificielle :

Grâce à la capacité de l'intelligence artificielle à résoudre de nombreux problèmes et à son efficacité à traiter celles complexes, on la retrouve dans de nombreux domaines, notamment :

2.2.1. La santé :

Aujourd'hui, l'intelligence artificielle peut analyser notre état de santé à l'aide des smartwatches qui peuvent surveiller nos données de santé telles que l'électrocardiographie, le taux d'oxygène dans le sang et l'état du sommeil.

Dans le diagnostic du cancer, l'IA est capable d'étudier un nombre considérable de données de tomographie assistée par ordinateur et de prédire avec une grande précision les cancers, comparable à celle d'experts dans ce domaine.

2.2.2. La finance :

L'intelligence artificielle (IA) est un domaine en constante évolution, et son application dans la finance suscite un grand intérêt, [1] explore l'utilisation de l'apprentissage automatique (Machine Learning) pour améliorer les stratégies trading et la prédiction des mouvements des marchés financiers.

2.2.3. La mécanique :

À l'heure actuelle, l'intelligence artificielle est souvent utilisée dans le diagnostic des défauts de l'ingénierie mécanique à l'aide d'une structure généralisée montrée dans la figure III.2, son processus de fonctionnement est le suivi :

1. Saisir des données par l'utilisateur via l'interface homme-machine.
2. Traiter les données à travers la machine à raisonner et trouver le cas la plus similaire dans la base des données ce qui lui permet de faire et établir un diagnostic fiable et efficace.
3. Permettre d'améliorer encore le système de diagnostic expert en ajoutant de

nouveaux cas. [2]

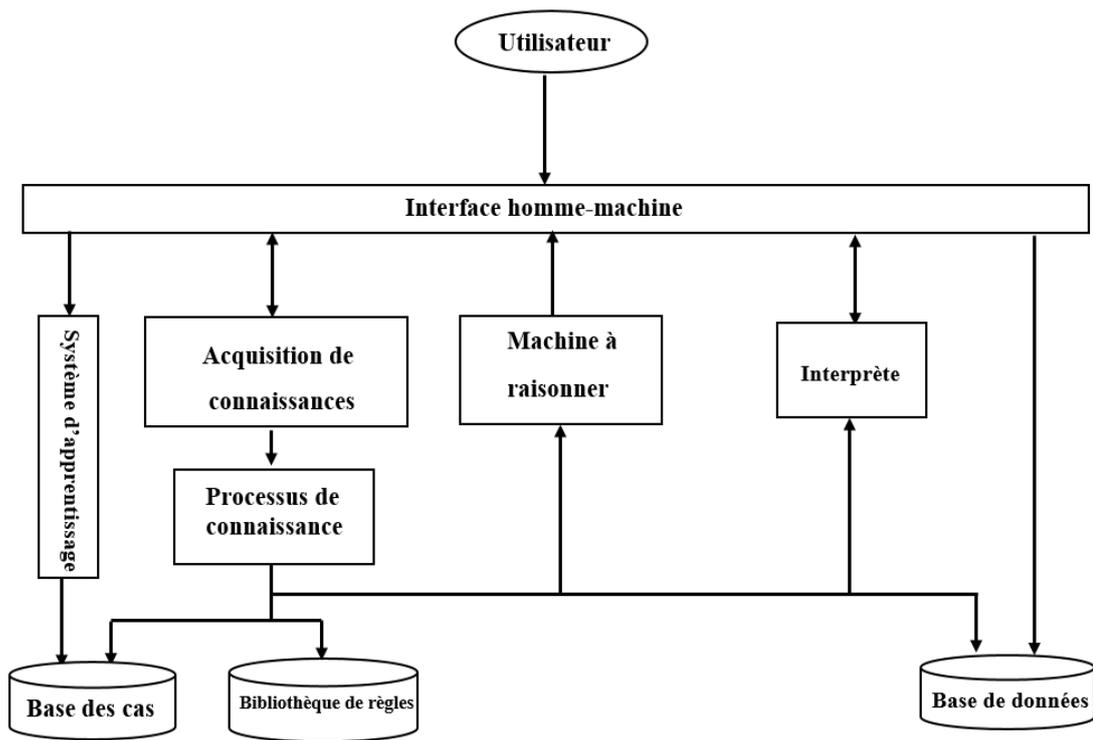


Figure III.2 : La structure généralisée au diagnostic des défauts.

D'autres domaines tels que l'éducation, la culture, le tourisme et la logistique connaissent également des changements grâce à l'intelligence artificielle.

2.3. L'apprentissage automatique : La méthode de l'IA la plus célèbre.

L'apprentissage automatique est la méthode qui permet à un système ou à un logiciel d'apprendre des connaissances à partir des données acquises.

Selon l'algorithme utilisé on peut classer l'apprentissage automatique en trois catégories :

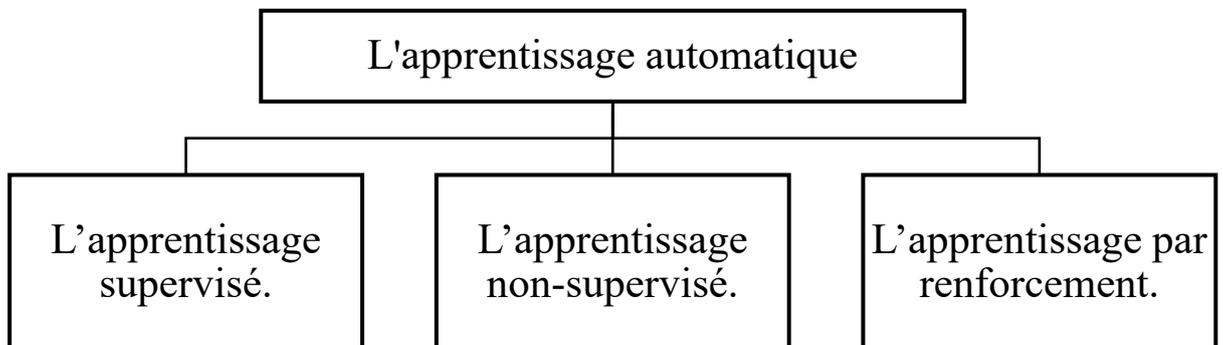


Figure III.3 : Les trois principaux algorithmes d'apprentissage automatique.

2.3.1. L'apprentissage supervisé :

L'apprentissage supervisé est l'entraînement des algorithmes sur un ensemble d'entrée-sortie et établir un modèle de correspondance entre eux pour être capable à prédire la sortie correcte pour des nouvelles entrées. L'ensemble de données d'entraînement appelé l'ensemble de données étiquetés.

L'apprentissage supervisé a deux buts : la classification et la régression, la classification s'intéresse aux problèmes avec des sorties catégoriques alors que la régression nous donne des sorties numériques.

2.3.2. L'apprentissage non-supervisé :

Contrairement à l'apprentissage supervisé, l'apprentissage non supervisé utilise des données non étiquetés ou les sorties correctes ne sont pas fournies. Le but de cette méthode est d'identifier des relations entre les données et les classer sous des catégories qui ne sont pas immédiatement évidents.

Le but de l'apprentissage non-supervisé est de regrouper les données en divers clusters, d'identifier des règles d'association et de réduire les dimensions pour réaliser des tâches spécifiques telles que la classification de défauts d'engrenages et de roulements.

	Apprentissage supervisé	Apprentissage non supervisé
Données d'entrée	Utilise les données connues et étiquetées comme entrées	Données inconnues en entrée
Complexité informatique	Très complexe	Moins de complexité informatique
Sous-domaines	Classification et régression	Exploitation de règles de clustering et d'association
Précision	Produit des résultats précis	Génère des résultats modérés
Nombre de classes	Nombre de classes connues	Le nombre de classes n'est pas connu

Tableau III.1 : comparaison entre l'apprentissage supervisé et non-supervisé. [3]

2.3.3. L'apprentissage par renforcement :

On peut définir l'apprentissage par renforcement comme étant la relation entre un agent et son environnement, ou il apprend à prendre des décisions et reçoit des récompenses ou des punitions en fonction de ses actions. Cette méthode est particulièrement utilisée dans les applications qui ont des conséquences à long terme.

3. Les réseaux de neurones artificiels :

3.1. Bref historique :

Les réseaux de neurones artificiels, une branche de l'informatique qui a été inventée afin de simuler le comportement d'un cerveau humain. En : [4]

- 1943 : Le nom de John Mc Culloch et Walter Pitts est attribué à une représentation du neurone biologique (un neurone à comportement binaire). Ceux-ci ont été les premiers à démontrer que des réseaux de neurones formels simples peuvent effectuer des fonctions logiques, arithmétiques et symboliques complexes (au moins au niveau théorique).
- 1957 : Frank Rosenblatt développe le modèle du Perceptron. Il développe le premier neuro-ordinateur à partir de ce modèle et l'applique à la reconnaissance de formes. Il est à noter qu'à cette époque, les ressources à sa disposition sont restreintes et c'est une prouesse technologique que de faire fonctionner cette machine avec un bon fonctionnement pendant plus de quelques minutes.
- 1960 : Un automatisateur, Bernard Widrow, élabore le modèle ADALINE (ADaptive LInear NEuron). Le modèle présente une structure similaire au Perceptron, mais la loi d'apprentissage diffère. L'algorithme de rétro-propagation de gradient, largement utilisé aujourd'hui avec les Perceptrons multicouches, est à l'origine de cette idée.
- 1972 : Teuvo Kohonen présente ses travaux sur les mémoires associatives et propose des applications à la reconnaissance de formes.
- 1982 : John Joseph Hopfield est un physicien reconnu à qui l'on doit le renouveau d'intérêt pour les réseaux de neurones artificiels. Il présente une théorie du fonctionnement et des possibilités des réseaux de neurones.
- 1985 : La rétro-propagation de gradient apparaît. Il s'agit d'un algorithme d'apprentissage conçu spécifiquement pour les réseaux de neurones multicouches (ou Perceptrons multicouches). Sa découverte réalisée par trois groupes de chercheurs indépendants. Dès cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau en décomposant cette fonction en une suite d'étapes linéairement séparables.

De nos jours, les réseaux multicouches et la rétro-propagation de gradient reste le modèle le plus productif au niveau des applications.

3.2. L'origine de RNA, analogie entre neurone biologique et neurone formel :

La capacité des neurones biologiques à traiter de nombreuses données à pousser les chercheurs pour créer un réseau de neurones artificiel qui simuler celui de l'humain.

3.2.1. Le neurone biologique :

Un neurone biologique, l'unité fondamentale du système nerveux, possède une structure complexe qui lui permet de recevoir, traiter et transmettre des informations. Structurellement, il peut être divisé en quatre parties : Le corps cellulaire, les dendrites, l'axone et la synapse. (Figure III.4)

1. Le corps cellulaire (Soma) est le centre de commande du neurone, il contient le noyau et d'autres organes essentiels.
2. Les dendrites sont la partie qui reçoit les signaux provenant d'autres neurones, ils sont les branches d'entrée.
3. L'axone présente la longue fibre qui transmet les signaux électriques du corps cellulaire vers d'autres neurones, il est recouvert de la myéline : un matériau riche en lipides qui entoure les axones pour les isoler et augmenter la vitesse à laquelle les impulsions électriques passent le long de l'axone.
4. La synapse peut être considérée comme étant le point de connexion entre deux neurones, c'est là que les signaux passent d'un neurone à l'autre.

Grace à cette structure complexe, les neurones peuvent former des circuits qui nous permettent de percevoir, de penser et d'agir.

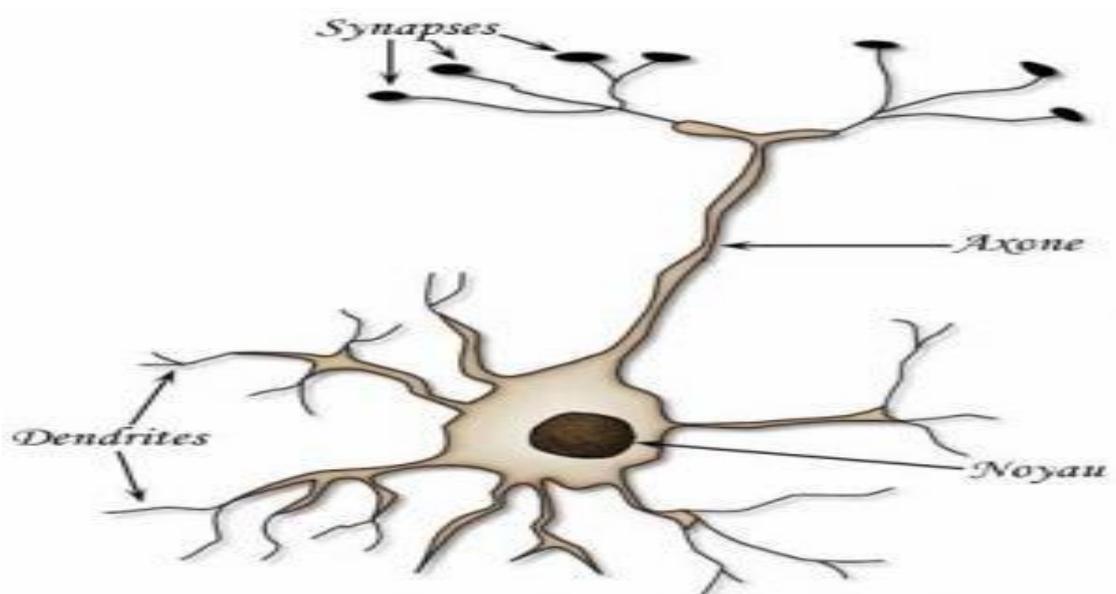


Figure III.4 : La structure d'un neurone biologique.

3.2.2. Le neurone formel :

Également appelé neurone Mc Culloch-Pitts, est l'unité de base d'un réseau de neurones artificiel qui représente mathématiquement et informatiquement le neurone biologique.

3.2.2.1. La structure d'un neurone formel :

Il possède plusieurs entrées qui correspondent aux dendrites et une seule sortie qui correspond au cône d'émergence (le point de contact entre le soma et le début de l'axone).

Chaque entrée a un poids synaptique associé, ces poids synaptiques sont les coefficients de l'équation à résoudre. Ainsi, pour un neurone formel on trouve ce que l'on appelle le biais qui est une valeur constante qui s'ajoute au produit des entrées et des poids synaptiques pour compenser le résultat.

La figure III.5 présente la structure d'un neurone formel avec :

$\{x_1, x_2, \dots, x_n\}^t$ est le vecteur d'entrées.

$\{w_1, w_2, \dots, w_n\}^t$ est le vecteur de poids synaptiques associés aux entrées.

w_0 est le biais du neurone formel.

y présente la seule sortie.

g est la fonction d'activation.

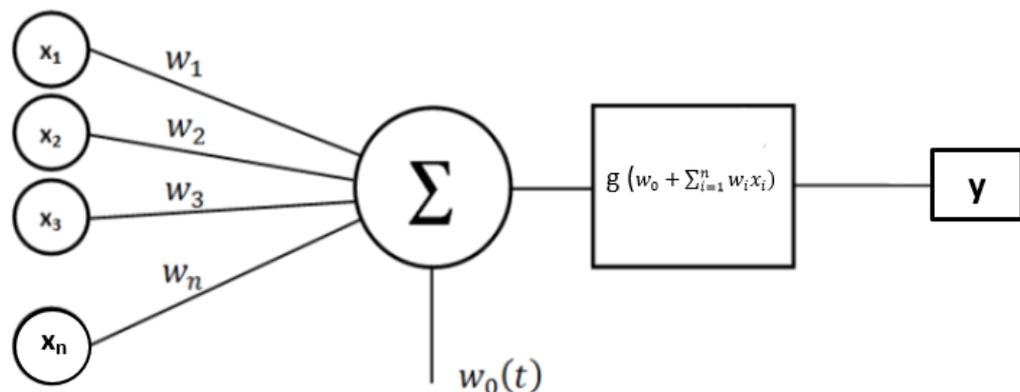


Figure III.5 : La structure d'un neurone formel.

3.2.2.2. Comment un neurone formel se fonctionne ?

Les actions excitatrices et inhibitrices des synapses sont représentées par des coefficients numériques (les poids synaptiques) associés aux entrées.

Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues. Ensuite, il applique à cette valeur une fonction d'activation,

généralement non linéaire, la valeur finale obtenue est la sortie du neurone qui doit être compris entre 0 et 1. [5]

Le tableau III.2 présente une comparaison entre le neurone biologique et le neurone formel :

Neurone biologique :	Neurone formel :
Synapses	Poids de connexions
Dendrites	Signal d'entrée
Axones	Signal de sortie
Soma	Fonction d'activation

Tableau III.2 : Tableau comparatif entre le neurone biologique et le neurone formel.

3.3. Le modèle le plus simple d'un neurone formel, le perceptron :

En janvier 1957, Frank Rosenblatt a inventé le premier perceptron pour imiter mathématiquement les principes de fonctionnement du neurone biologique, il est limité à la résolution de problèmes linéairement séparables, ce qui signifie qu'il ne peut pas apprendre des fonctions non linéaires complexes. Il a une seule couche de neurones (entrée) avec des poids associés à chaque connexion entre l'entrée et la sortie.

La sortie du perceptron est basée sur une fonction seuil : Si la somme pondérée des entrées dépasse un seuil, la sortie est activée (1), sinon elle est désactivée (0).

3.4. La fonction d'activation :

La fonction d'activation joue un rôle crucial dans le fonctionnement d'un RNA, citons :

- **Introduire de la non-linéarité :**

L'un des rôles principaux de la fonction d'activation est d'introduire de la non-linéarité dans le modèle. Si les neurones utilisaient simplement une combinaison linéaire des entrées pondérées, même avec plusieurs couches, l'ensemble du réseau serait équivalent à un seul neurone. La non-linéarité introduite par la fonction d'activation permet au réseau de capturer des relations complexes et non linéaires entre les variables d'entrée et de sortie.

- **Permettre l'apprentissage de représentations complexes :**

La non-linéarité introduite par la fonction d'activation est essentielle pour que le réseau puisse apprendre et représenter des modèles complexes. Les tâches d'apprentissage, notamment la classification d'images, la reconnaissance vocale et d'autres tâches complexes, nécessitent la capacité de modéliser des relations non linéaires, ce que permet la fonction d'activation.

- **Normaliser les sorties :**

La fonction d'activation normalise la sortie du neurone, souvent dans une plage spécifique. Par exemple, la fonction sigmoïde normalise les sorties dans l'intervalle (0, 1). Cela rend les sorties des neurones plus interprétables et évite des valeurs qui divergent vers l'infini, facilitant ainsi la stabilité numérique lors de l'apprentissage.

- **Filtrer l'information :**

La fonction d'activation agit également comme un filtre pour contrôler la quantité d'information qui est transmise à la couche suivante du réseau. Elle détermine quelles informations sont importantes et activent les neurones en conséquence, contribuant ainsi à la sélectivité du réseau.

- **Faciliter la rétro-propagation du gradient :**

Lors de l'apprentissage supervisé par rétro-propagation du gradient, la dérivée de la fonction d'activation est utilisée pour calculer les gradients nécessaires pour ajuster les poids du réseau. La dérivée de la fonction d'activation est un facteur crucial dans la mise à jour des poids pour minimiser la fonction de coût lors de l'entraînement du réseau.

En notant g la fonction d'activation, on obtient donc la formule donnant la sortie y d'un neurone de n entrées tel que chaque entrée x_i possède un poids synaptique w_i :

$$y = g(z) = g(w_0 + \sum_{i=1}^n w_i x_i) \quad (\text{III.1})$$

Avec :

w_0 est le biais

z est la somme pondérée.

Selon la situation et le problème pose on trouve de nombreuses fonctions d'activation, les plus courantes et utilisées sont citées dans le tableau III.3 suivant :

La fonction	Relation d'entrée-sortie
Seuil	$y = 0$ si $z < 0$ $y = 1$ si $z \geq 0$
Seuil symétrique	$y = -1$ si $z < 0$ $y = 1$ si $z \geq 0$
Linéaire	$y = z$
Linéaire saturée	$y = 0$ si $z < 0$ $y = z$ si $-1 \leq z \leq 1$ $y = 1$ si $z > 1$

Linéaire saturée symétrique	$y = -1$ si $z < -1$ $y = z$ si $-1 \leq z \leq 1$ $y = 1$ si $z > 1$
Linéaire positive	$y = 0$ si $z < 0$ $y = z$ si $z \geq 0$
Sigmoïde	$y = \frac{1}{1 + e^{-z}}$
Tangente hyperbolique	$y = \frac{e^z - e^{-z}}{e^z + e^{-z}}$
Compétitive	$y = 1$ si z maximum $y = 0$ si autrement
L'unité linéaire rectifiée	$y = z$ si $z > 0$ $y = 0$ si autrement

Tableau III.3 : Les fonctions d'activations les plus courantes.

Le choix de la fonction d'activation dépend souvent de la nature de la tâche, des propriétés des données et des caractéristiques du modèle. Dans le domaine de l'ingénierie, les quatre fonctions d'activation les plus utilisées sont :

3.4.1. La fonction linéaire :

Également appelée la fonction identité est souvent utilisée dans certaines parties spécifiques d'un réseau de neurones, en particulier dans la couche de sortie pour les tâches de régression. L'objectif principal de cette fonction d'activation est de fournir une sortie qui est une simple transformation linéaire de l'entrée.

3.4.2. La fonction sigmoïde :

La fonction d'activation sigmoïde souvent appelée la fonction logistique, est une fonction non-linéaire qui transforme une valeur réelle en une plage de 0 jusqu'à 1 et sa dérivée peut être exprimée en termes de lui-même, ce qui facilite l'utilisation de méthodes de rétro-propagation du gradient lors de l'entraînement des réseaux de neurones. On donne :

$$g'(z) = \frac{e^{-z}}{(1+e^{-z})^2} = g(z) \times (1 - g(z)) \quad (\text{III.2})$$

3.4.3. La fonction tangente hyperbolique :

La fonction d'activation tangente hyperbolique, notée \tanh , est l'une des fonctions non-linéaires les plus utilisées tel que la sortie doit être comprise sur un intervalle de -1 à 1 ce qui on fait une fonction symétrique autour de 0, ainsi que sa dérivée est facile à calculer en fonction de lui-même et est donnée par la relation mathématique suivante :

$$(\tanh(z))' = 1 - \left(\frac{e^z - e^{-z}}{e^z + e^{-z}}\right)^2 = 1 - \tanh^2(z) \quad (\text{III.3})$$

3.4.4. La fonction d'unité linéaire rectifiée ReLU :

La fonction d'activation ReLU (Rectified Linear Unit) est actuellement la fonction la plus utilisée dans les RNA grâce à son simplicité et sa propriété d'éviter le gradient qui disparaît.

Ces quatre fonctions sont représentées graphiquement comme suit :



Figure III.6 : Fonction linéaire.

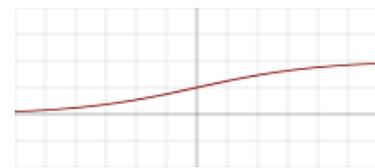


Figure III.7 : Fonction sigmoïde.

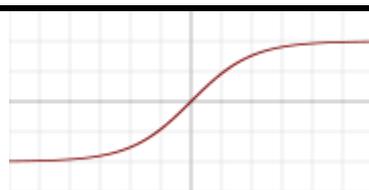


Figure III.8 : Fonction Tanh.



Figure III.9 : Fonction ReLU.

3.5. La classification des RNA :

L'architecture des réseaux de neurones artificiels (RNA) constitue la structure fondamentale qui permet à ces modèles d'apprendre à partir de données et de réaliser des tâches complexes. Selon le sens de circulation de l'information pendant la phase d'apprentissage on peut classifier les RNA en deux catégories :

3.5.1. Les réseaux FEED-FORWARD :

Les réseaux de neurones feed-forward, également appelés les réseaux de neurones à propagation avant, ce sont des réseaux dans lesquels l'information se propage de couche en couche sans retour en arrière possible. On trouve :

- **Le perceptron** : le modèle le plus simple, composé généralement d'une seule couche de neurones et utilisé pour des tâches de classification binaire.

- **Réseau de neurones à couches multiples MLP** : également appelé le perceptron multicouches, il se compose d'une couche d'entrée et d'une de sortie et entre eux on trouve plusieurs couches cachées.
- **Réseau de neurones convolutif CNN** : ce type concerne le traitement d'image, il a une structure différente d'autres réseaux où il se compose de :
 - Une couche de convolution qui utilise des filtres agissant tous au long l'image pour extraire des caractéristiques locales.
 - Les couches de pooling : pour but de réduire la dimensionnalité et la taille des entrées.
 - Les couches entièrement connectées : il peut être une ou plusieurs couches, ce sont les couches responsables à la classification.

Ce type des réseaux utilise la fonction ReLU (Rectified Linear Unit) comme une fonction d'activation. Ainsi qu'il est un réseau pré-entraîné et utilise la technique de transfert d'apprentissage : un modèle pré-entraîné sur une tâche peut être utilisé comme point de départ pour une tâche similaire avec un ensemble de données plus petit.

- **Réseau de neurones récurrent RNN** : généralement utilisé dans le traitement des données séquentielles tel que chaque couche cachée maintient une mémoire des entrées antérieures.
- **Réseau de neurones à propagation avant profond DNN** : Le DNN est un réseau avec grand nombre de couches cachées.

3.5.2. Les réseaux FEED-BACK :

Les réseaux de neurones feed-back, aussi appelés les réseaux récurrents, ce sont des réseaux dans lesquels il y a retour en arrière de l'information avec un apprentissage non supervisé. On trouve :

- **Les réseaux de Hopfield** : inventés par John Hopfield en 1982, ils représentent des réseaux interconnectés c'est-à-dire chaque neurone est connecté avec tous les autres neurones de réseau et ils ont fonctionné comme une mémoire associative. Ce type de réseau est généralement appliqué aux problèmes d'optimisation.
- **Self-Organizing Maps SOM** : Self-Organizing maps a été inventé par Teuvo Kohonen dans les années 1980, ce modèle est conçu pour l'apprentissage non supervisé et la visualisation de données multidimensionnelles complexes. La partie ci-dessous sera consacrée pour parler de ce type de réseaux de neurones artificiels.

4. Les cartes auto-organisatrices de Kohonen :

4.1. Définition :

Les cartes auto-organisatrices (SOM) est l'un des réseaux de neurones artificiels qui se fonctionne d'une façon non-supervisée, elles ont été inventé par Teuvo Kohonen en 1982 en s'inspirant par le principe neuronal du cerveau des mammifères. L'idée principale des cartes auto-organisatrices est la classification des données dont le but essentiel est de réduire la dimensionnalité des entrées. (Figure III.10).

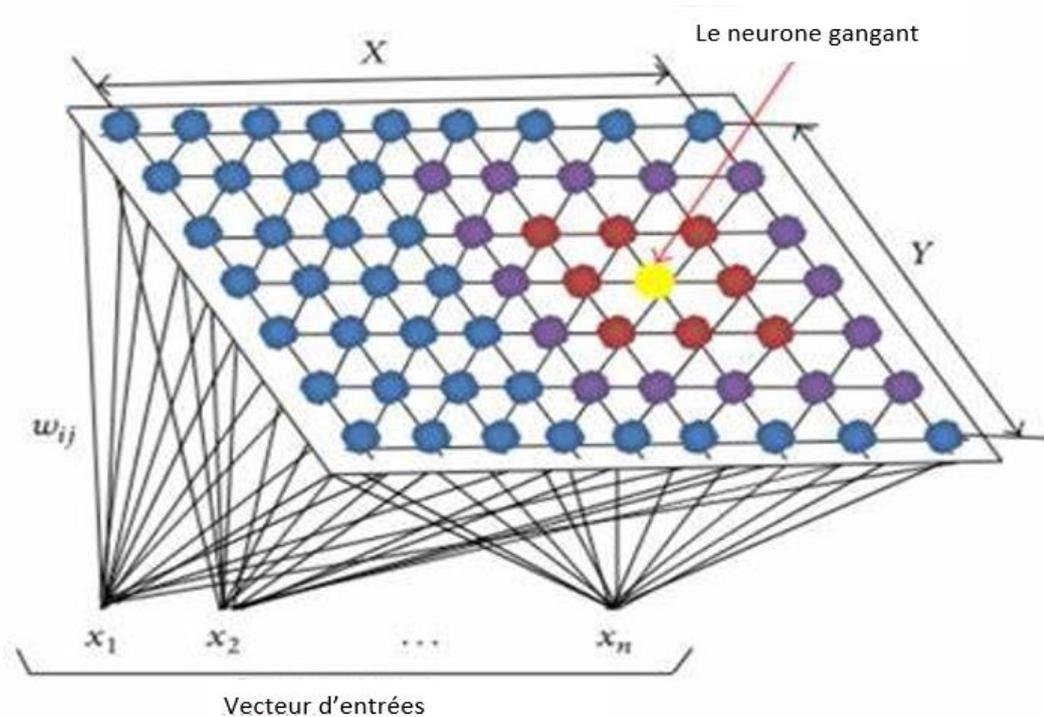


Figure III.10 : Schéma d'une carte auto-organisatrice.

4.2. L'algorithme des cartes auto-organisatrices :

Les cartes auto-organisatrices sont souvent utilisées pour la visualisation des données et la détection de motifs dans des ensembles de données complexes et multidimensionnels. Elles peuvent également être appliquées dans des domaines tels que la classification et la compression de données en suivant cet algorithme :

- **Étape 1 - Phase d'initialisation :** Chaque neurone sur la carte est associé à un vecteur de poids qui a la même dimension que les données d'entrée.
- **Étape 2 - Présentation des données :** Un échantillon de données est présenté au réseau.
- **Étape 3 - Sélection du neurone gagnant :** Le neurone dont le vecteur de poids est le plus similaire aux données d'entrée est désigné comme le neurone gagnant (en

anglais : Best Matching Unit BMU). Ce neurone sera choisi en calculant le carrée la distance euclidienne qui est donné par :

$$D^2(j) = \sum_{i=1}^n \sum_{j=1}^m (x_i - w_{ij})^2 \quad (\text{III.4})$$

Le neurone qui a la plus moins distance est le neurone gagnant.

- **Étape 4 - Mise à jour des poids :** Les poids du neurone gagnant et éventuellement ceux de ses voisins proches sur la carte sont mis à jour en utilisant l'équation (III.5). Les poids sont ajustés pour se rapprocher des valeurs des données d'entrée.

$$w_{ij}(\text{nouveau}) = w_{ij}(\text{ancien}) + \eta[x_i - w_{ij}(\text{ancien})] \quad (\text{III.5})$$

Tel que : η est le taux d'apprentissage

- **Étape 5 - Répétition :** Les étapes de présentation des données, sélection du neurone gagnant et mise à jour des poids sont répétées pour plusieurs itérations.

5. Conclusion :

Les réseaux de neurones ont montré leur efficacité à diagnostiquer les différents défauts d'engrenages et de roulements et les classifier avec succès grâce à leur grande capacité de calcul et d'apprentissage.

Références bibliographiques :

- [1] Lanbouri, Z. (2020). *Vers une approche machine learning pour le trading et la prédiction de défaillance financière* (Thèse de doctorat). École Nationale Supérieure d'Informatique et d'Analyse des Systèmes, Université Mohammed V de Rabat, Maroc.
- [2] Huang, Q. (2017). Application of artificial intelligence in mechanical engineering. In *2nd International Conference on Computer Engineering, Information Science & Application Technology*.
- [3] Alia, S. (2020, décembre). *Contribution à la détection et au diagnostic des défauts des moteurs par l'application de l'analyse vibratoire* (Thèse de doctorat). Université EL MANNAR, Tunis.
- [4] Djeridi, Y. (2017, septembre). Chapitre intitulé : Les réseaux neurones artificiels. Université Sidi Belabbes.
- [5] Mermillod, M. (2016). *Réseaux de neurones biologiques et artificiels : Vers l'émergence de systèmes artificiels conscients ?* (p. 129).

Chapitre IV:

L'AMRO et les cartes auto-organisées SOM dans le suivi de la dégradation des roulements

1. Introduction:

Dans le domaine de la maintenance conditionnelle, les roulements occupent une place centrale en raison de leur rôle critique dans de nombreuses machines tournantes. En surveillant attentivement l'état de roulements à l'aide de l'analyse vibratoire, les équipes de maintenance peuvent détecter les signes de défaillance imminente et planifier des interventions préventives.

L'analyse multi-résolution en ondelettes AMRO est l'une des techniques de l'analyse vibratoire qui a prouvé leur performance à la détection des défauts de roulements, elle permet une analyse approfondie à différentes résolutions.

Par ailleurs, on utilise également les réseaux de neurones artificiels (ANN) pour surveiller et diagnostiquer les machines tournantes : un réseau neuronal artificiel est un système initialement développé pour imiter le fonctionnement des neurones biologiques.

La carte auto-organisée (SOM) est un type spécifique d'ANN qui regroupe de grands vecteurs de données en fonction de leur similarité.

Dans ce chapitre, nous allons valider la performance de ces deux techniques en étudiant un ensemble de signaux vibratoires mesurés pendant 50 jours consécutifs d'une éolienne avec un défaut initié à la bague intérieure du roulement.

2. Plan expérimental :

2.1. Présentation du banc d'essai :

Les signaux vibratoires ont été obtenus à partir d'un système de surveillance en ligne fourni par Green Power Monitoring Systems USA lors de la surveillance des roulements à grande vitesse d'une éolienne dans le but de prédire sa durée de vie utile restante (Remaining Useful Life RUL), l'ensemble de données est collecté à partir d'un arbre à grande vitesse d'éolienne de 2 MW entraîné par un pignon à 20 dents.

Un signal vibratoire de 6 secondes et d'une fréquence d'échantillonnage de 97,656 KHz a été acquis chaque jour pendant 50 jours consécutifs. Un défaut de bague interne s'est développé et a causé la défaillance du roulement pendant la période de 50 jours.

La figure IV.1 montre la représentation temporelle des signaux vibratoires pendant cette période, il est clair que l'amplitude s'augmente avec le temps ce qui indique la présence d'un défaut et pour localiser ce défaut on va utiliser des techniques fiables et performantes : L'analyse multi-résolution en ondelettes AMRO et une carte auto-organisée SOM.

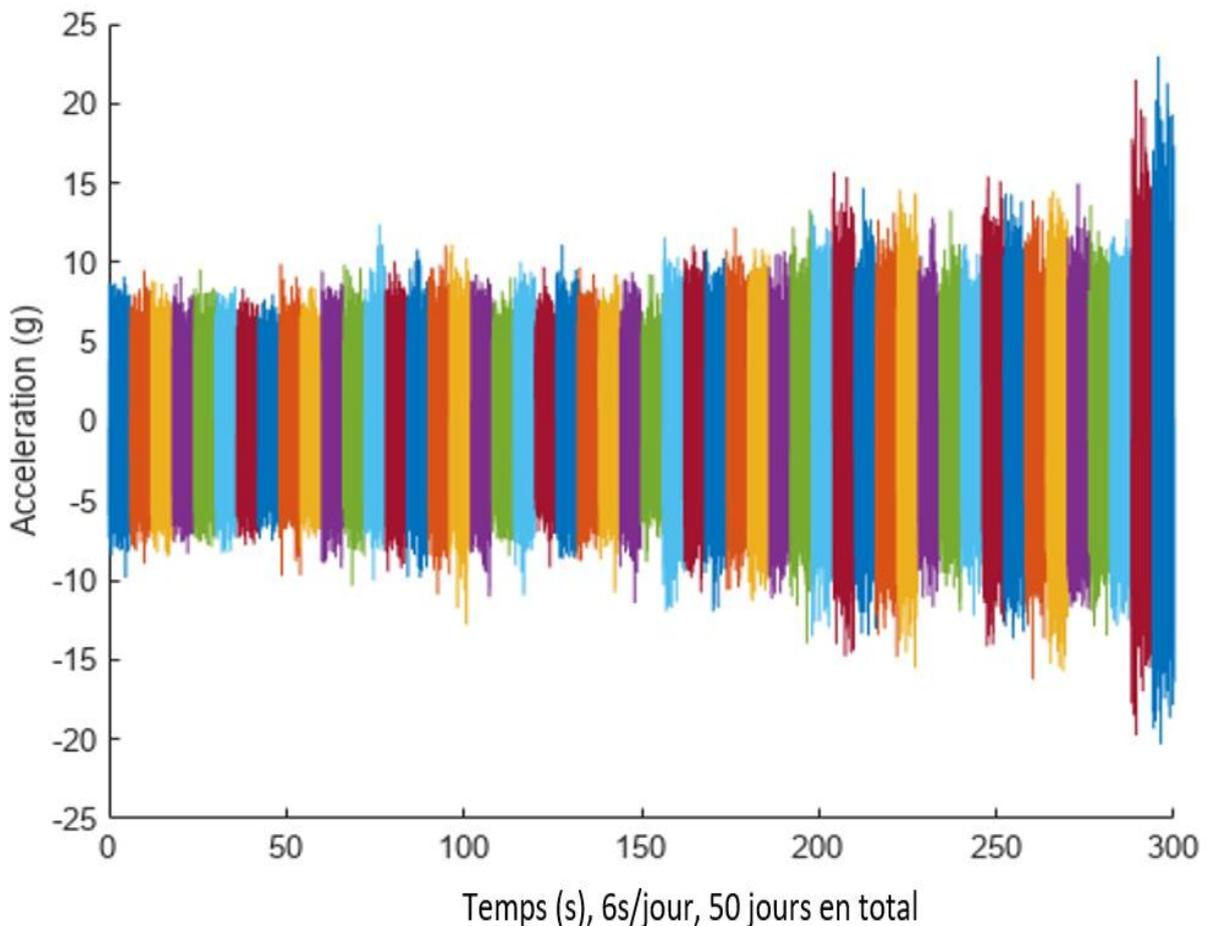


Figure IV.1 : Les signaux temporels.

Le roulement utilisé dans ce système est un roulement à rouleaux coniques de type SKF 32222 J2 110×200×56 (figure IV.2).



Figure IV.2 : Roulement à rouleaux coniques SKF 32222 J2.

2.2. Les fréquences caractéristiques des défauts de roulement :

Pour une fréquence de rotation de 30 Hz, les fréquences caractéristiques des défauts de roulements sont présentées dans le tableau IV.1 :

Défait :	Coefficient de défaut :	Fréquence de défaut [Hz] :
FTF	0.42	12.6
BPFO	6.72	201.6
BPFI	9.47	283.2
BSF	1.435	43.05

Tableau IV.1 : Les fréquences caractéristiques des défauts de roulement.

3. Traitement des signaux par l'AMRO:

Parmi les 50 signaux vibratoires capturés, nous avons choisi 8 signaux pour les traiter par l'analyse multi-résolution en ondelette (L'AMRO) à l'aide d'un programme Matlab [1], développé par le Professeur Abderrazak DJEBALA, du Laboratoire de Mécanique et Structures Groupe Comportement Dynamique des Structures et Maintenance Industrielle de l'Université de Guelma.

Le programme nous permet de suivre les étapes suivantes :

1. Identifier les vecteurs d'approximations qui représentent les fréquences les plus basses et de détails qui représentent les fréquences les plus hautes.
2. Sélectionner le vecteur optimal de la décomposition qui est celui permettant la détection des défauts avec la meilleure résolution, impliquant le choix du vecteur le mieux filtré et l'utilisation de critères tels que le kurtosis (l'indicateur scalaire le plus sensible aux chocs).
3. Le vecteur présentant le plus grand kurtosis, soit le détail ou l'approximation pertinente.
4. Obtenir le spectre d'enveloppe du vecteur optimal en appliquant la transformée d'Hilbert.

Nous présentons dans ce qui suit l'application de l'analyse multirésolution en ondelettes sur les signaux choisis (les jours : 1, 7, 38, 49, 50).

- **Le 1^{er} jour :**

La figure IV.3 présente le signal mesuré le 1^{er} jour de surveillance, on observe qu'aucune information ne s'apparaît.

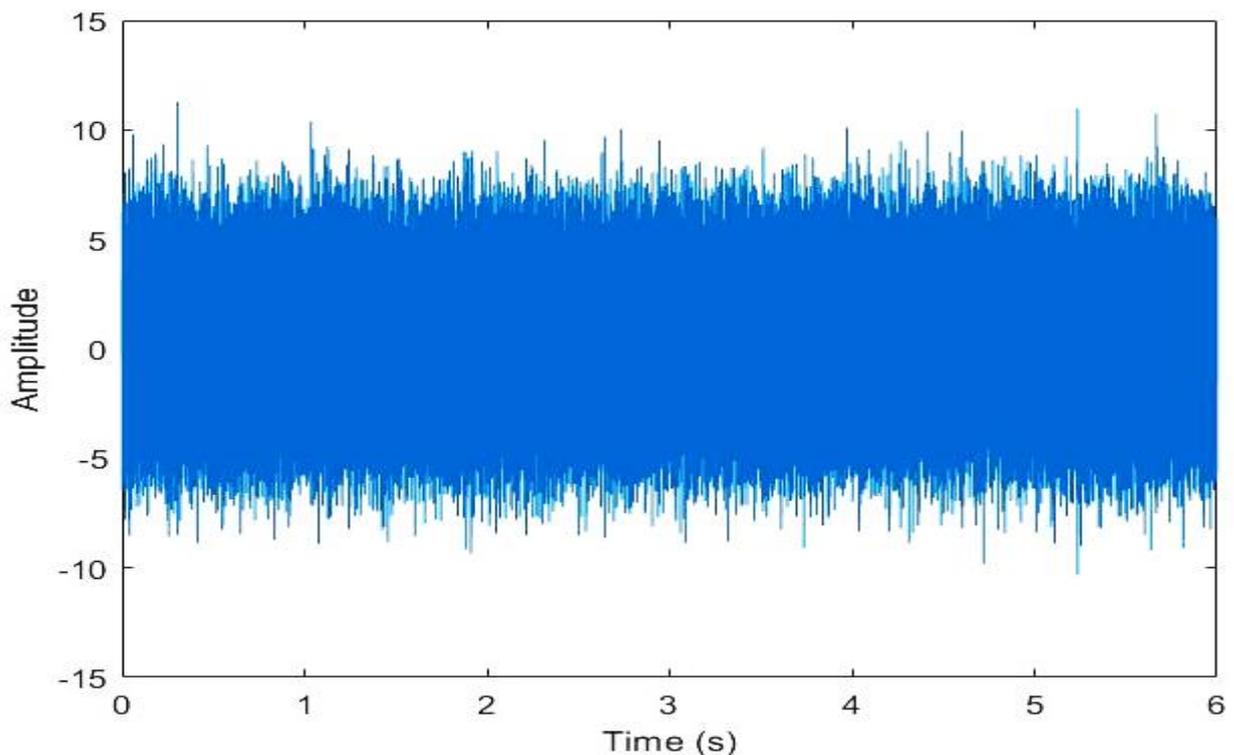


Figure IV.3 : La représentation temporelle de signal du 1^{er} jour 07/03/2013.

Pour plus d'informations on applique L'AMRO dans lequel le signal sera divisé en 4 vecteurs de détails et 4 vecteurs d'approximations. (Figure IV.4)

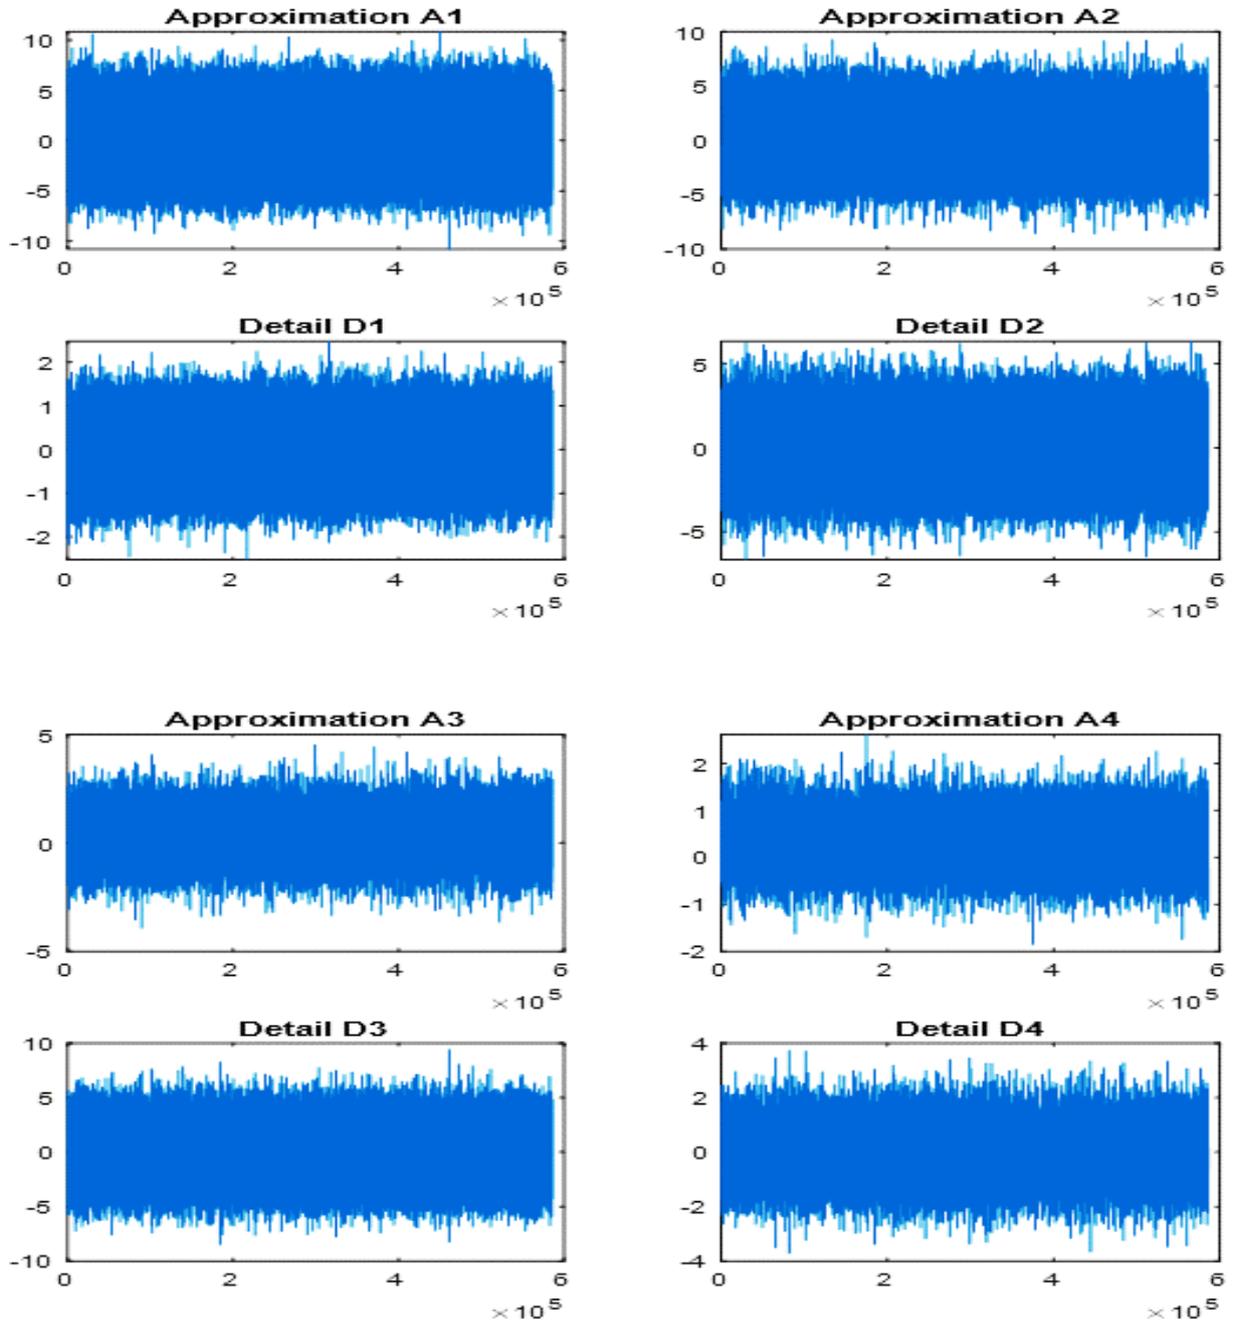


Figure IV.4 : Les approximations et les détails de signal du 1^{er} jour.

Le vecteur de détail D2 et D3 sont les vecteurs optimaux avec un kurtosis respectivement de 3,7822 et 3,6477.

La figure suivante présente le spectre d'enveloppe des coefficients d'ondelettes de deux détails D2 et D3 respectivement. On observe que l'apparition de la fréquence de rotation ($F_r=30\text{Hz}$) ainsi que leurs harmoniques.

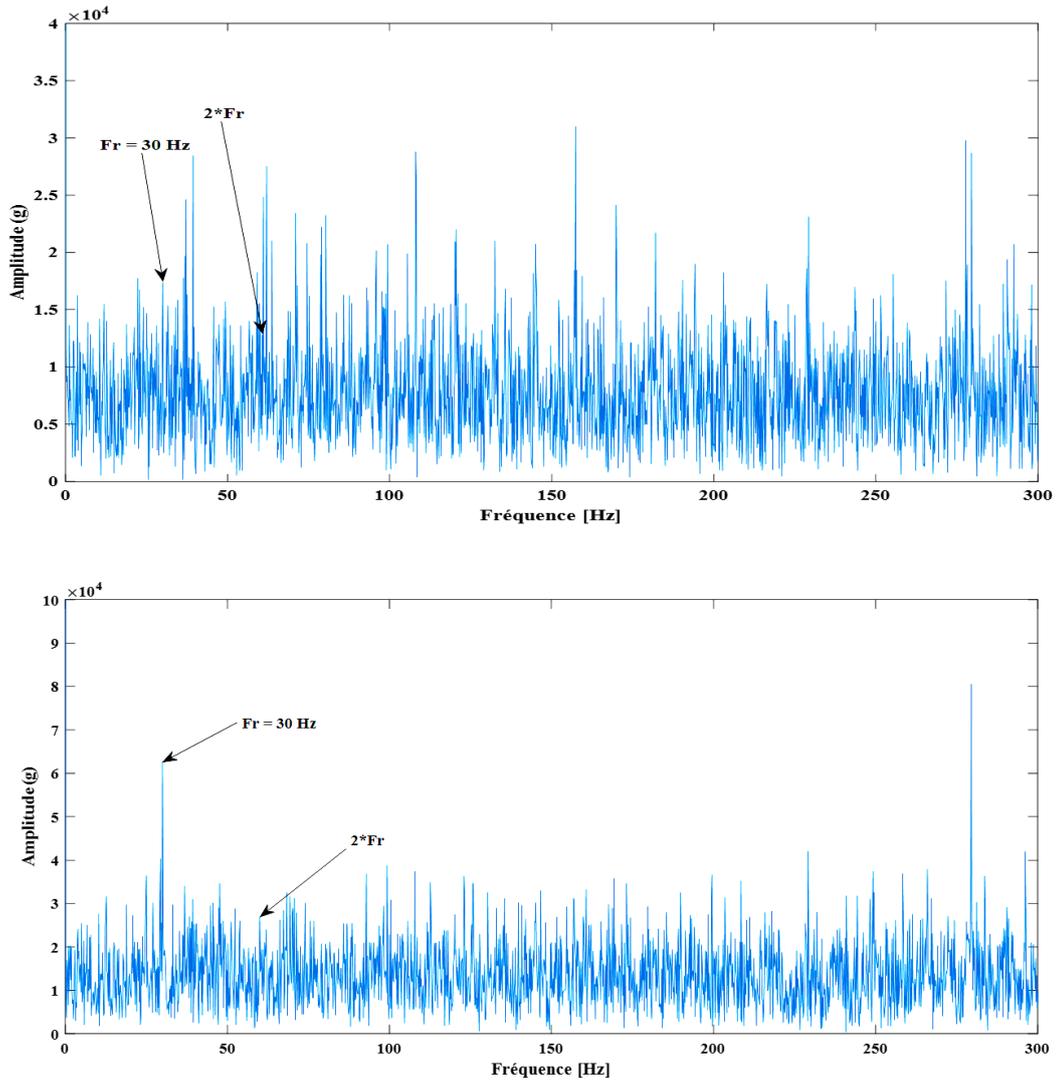


Figure IV.5 : Le spectre d'enveloppe de deux vecteurs de détails D2 et D3.

- Le 7^{ème} jour :

La figure IV.6 présente le signal mesuré le 7^{ème} jour :

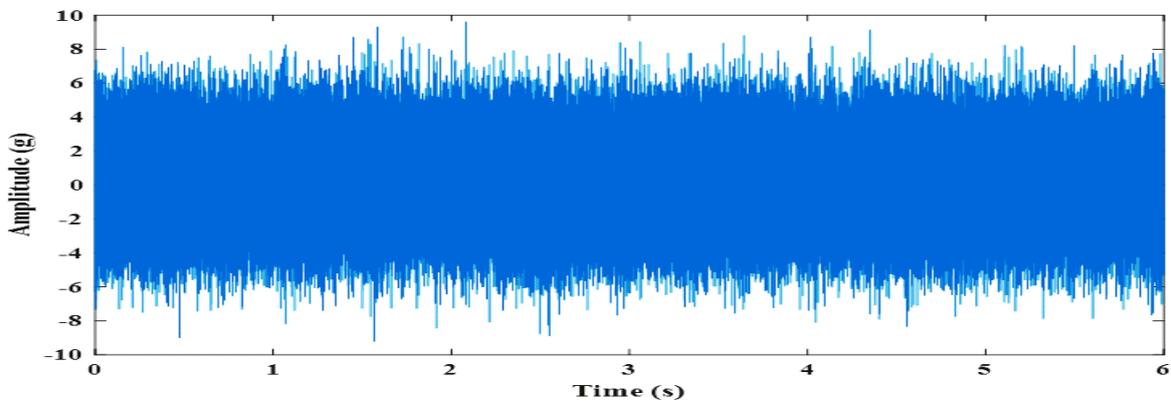


Figure IV.6 : La représentation temporelle de signal de 7^{ème} jour 13/03/2013.

La figure IV.7 représente le vecteur de détail D2 et D3 issu de la décomposition en ondelettes du signal mesuré le 7^{ème} jour.

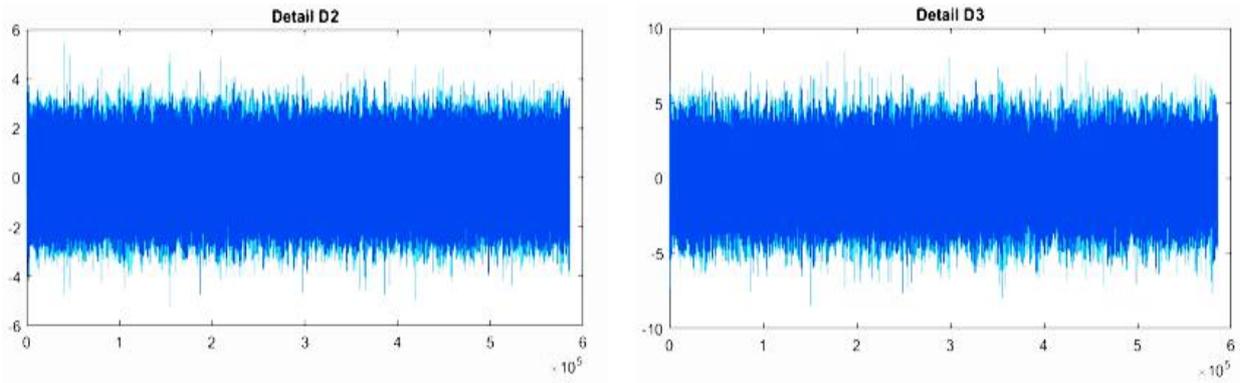
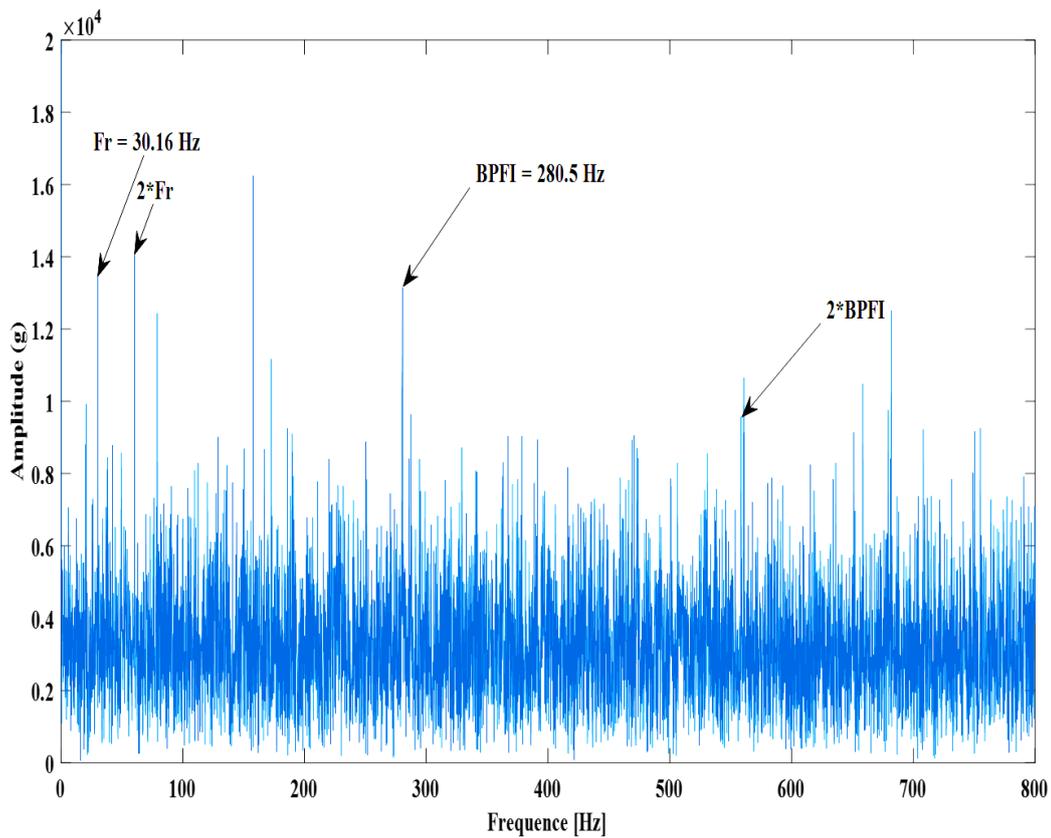


Figure IV.7 : Les vecteurs des détails D2 et D3 du 7^{ème} jour de mesure.

La figure ci-dessous montre les spectres d'enveloppe des coefficients d'ondelettes des détails D2 et D3 du signal mesuré le 7eme jour. Après le traitement des signaux D2 et D3 on observe l'apparition des pics correspondant à la fréquence de rotation réelle $Fr = 30.1667$ Hz et leurs harmoniques. Ainsi que l'apparition des pics correspondant au défaut de la bague intérieur, $BPFI=280.5$ Hz et leur harmonique. Cela confirme la présence du défaut sur la bague intérieure du roulement.



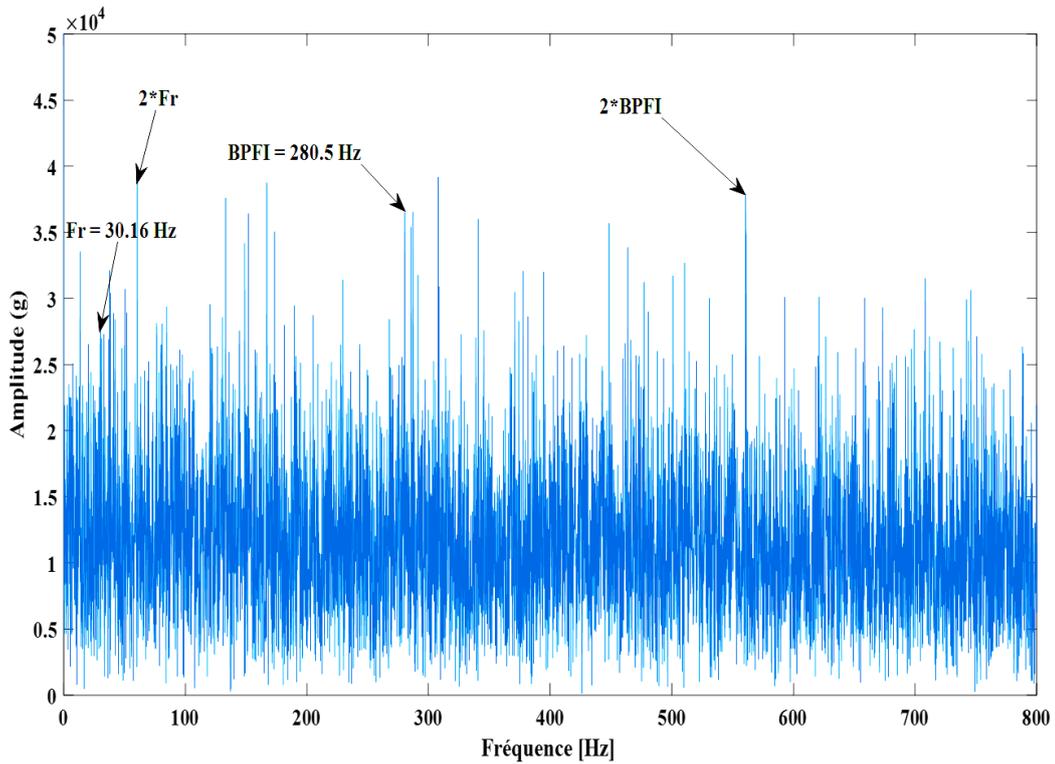


Figure IV.8 : Spectre d'enveloppe de deux vecteurs de détails D2 et D3.

- **38^{ème} jour :**

La figure IV.9 présente le signal temporel mesuré le jour 38 de surveillance, alors que la figure IV.10 présente le vecteur optimal obtenue qui correspond au vecteur de détail D3.

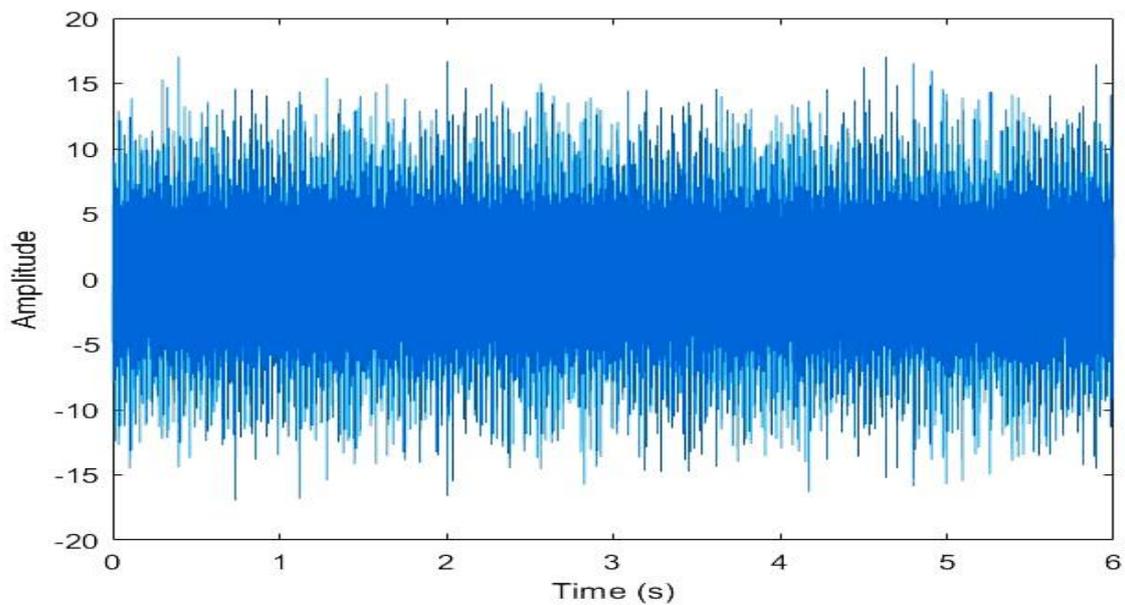


Figure IV.9 : La représentation temporelle de signal du 38^{ème} jour 13/04/2013.

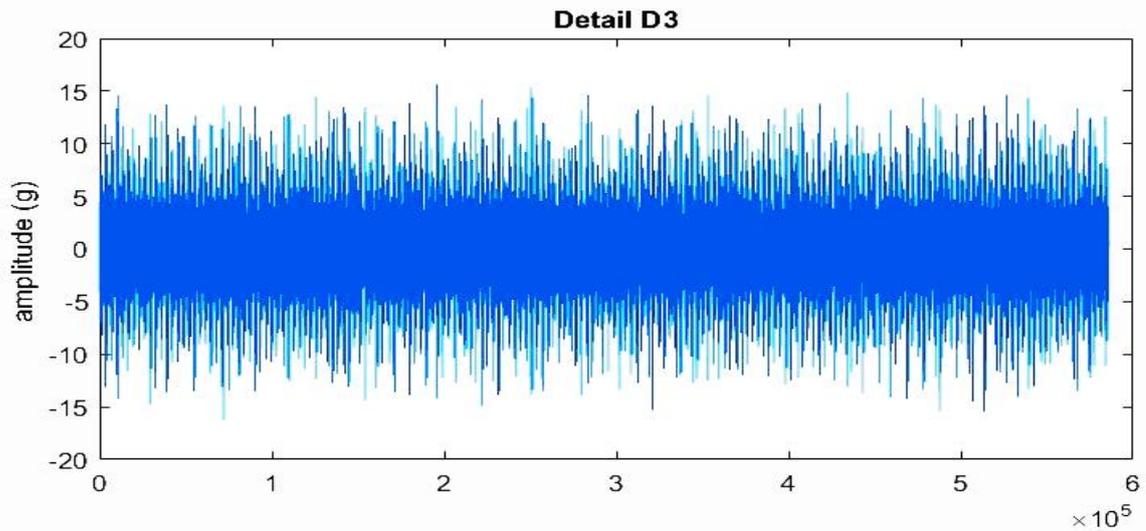


Figure IV.10 : Le vecteur de détail D3 du 38^{ème} jour.

La figure IV.11 présente le spectre d'enveloppe des coefficients d'ondelettes de détail D3. Les résultats montrent l'apparition du pic correspondant à la fréquence de rotation réel $Fr=30.5$ Hz., Ainsi que le pic correspondant à 285 Hz et ses harmoniques ce qui confirme la présence du défaut sur la bague intérieure (BPFI).

On comparant les deux amplitudes de défauts entre le 7^{ème} jour de mesure ($A=1.4 \times 10^4$ m/s²) et le 38^{ème} jour de mesure ($A=8 \times 10^5$ m/s²), on observe qu'il augmente presque 57 fois ce qui implique que la taille de défaut a été augmentée.

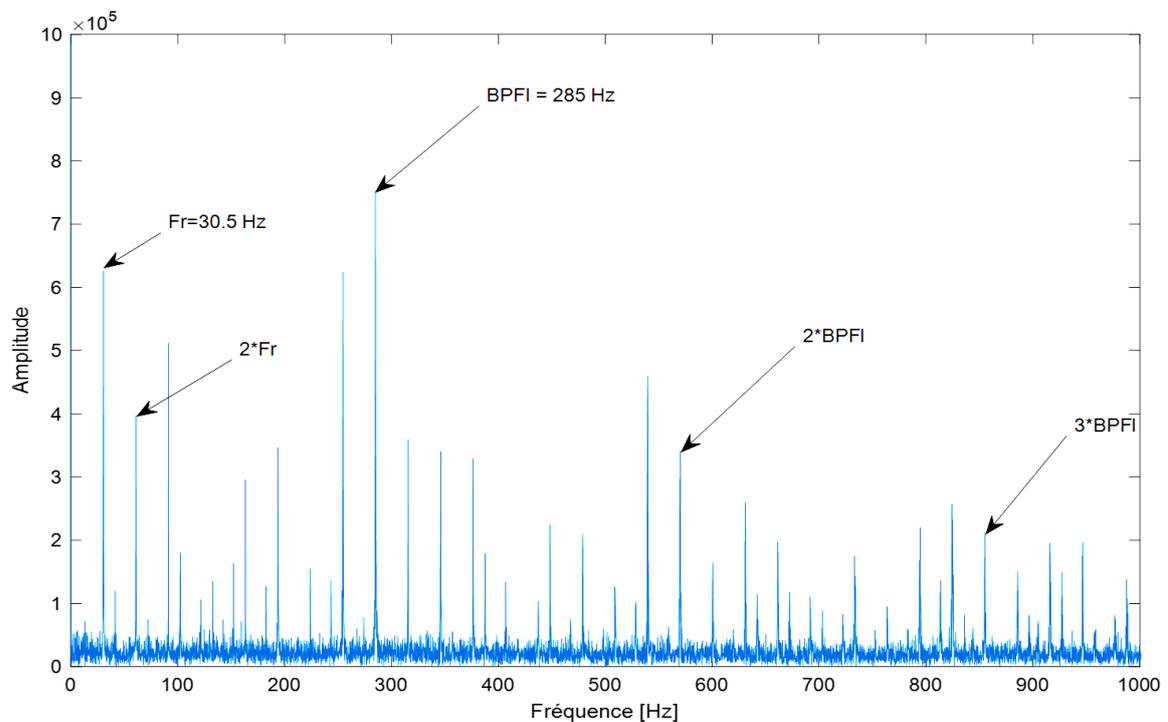


Figure IV.11 : Le spectre d'enveloppe du vecteur de détail D3.

- **49^{ème} jour :**

La figure IV.12 présente le signal temporel de 49^{ème} jour, alors que la figure IV.13 montre le vecteur optimal obtenue lors de l'application de nos critères de choix.

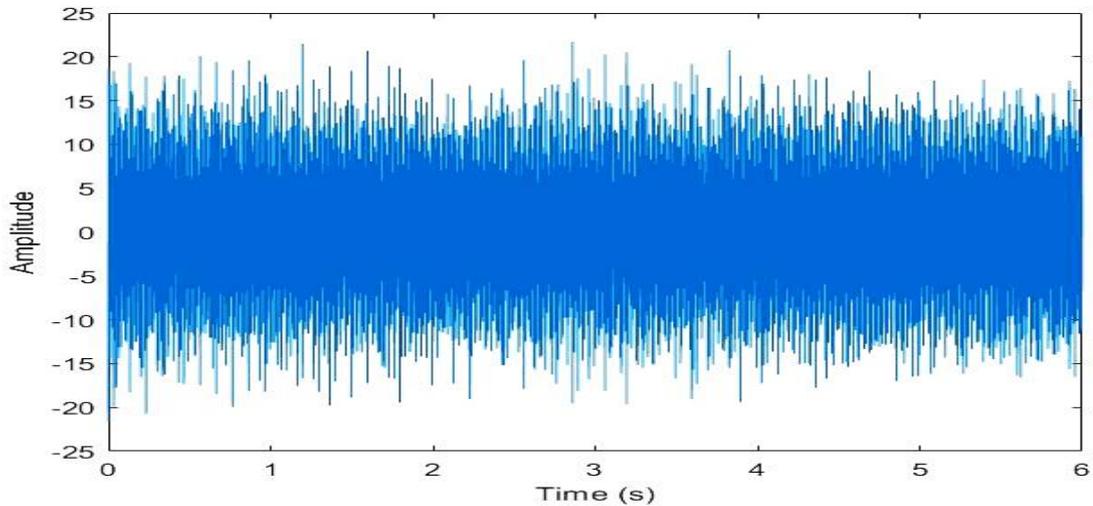


Figure IV.12 : La représentation temporelle de signal du 49^{ème} jour 24/04/2013.

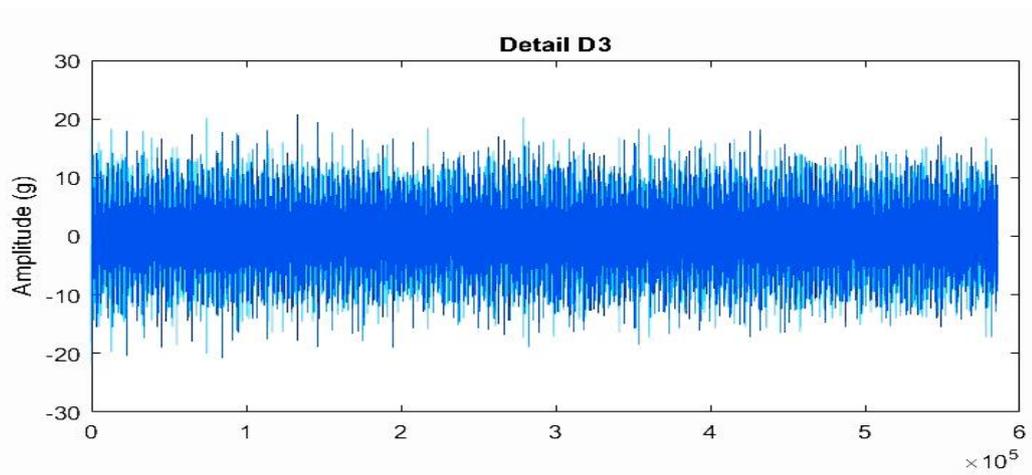


Figure IV.13 : Le vecteur de détail D3.

La figure IV.14 suivante montre le spectre d'enveloppe des coefficients d'ondelettes de vecteur optimal D3 : On remarque l'apparition de la fréquence de rotation ($F_r=30$ Hz) et leurs harmoniques, alors que l'apparition claire des pics correspond au défaut dans la bague intérieure de roulement ($BPFI = 280$ Hz).

On observe aussi que l'amplitude de défaut a été augmentée de 8×10^5 m/s² jusqu'à 2×10^6 m/s² cela implique que la taille de défaut augmente de jour à l'autre.

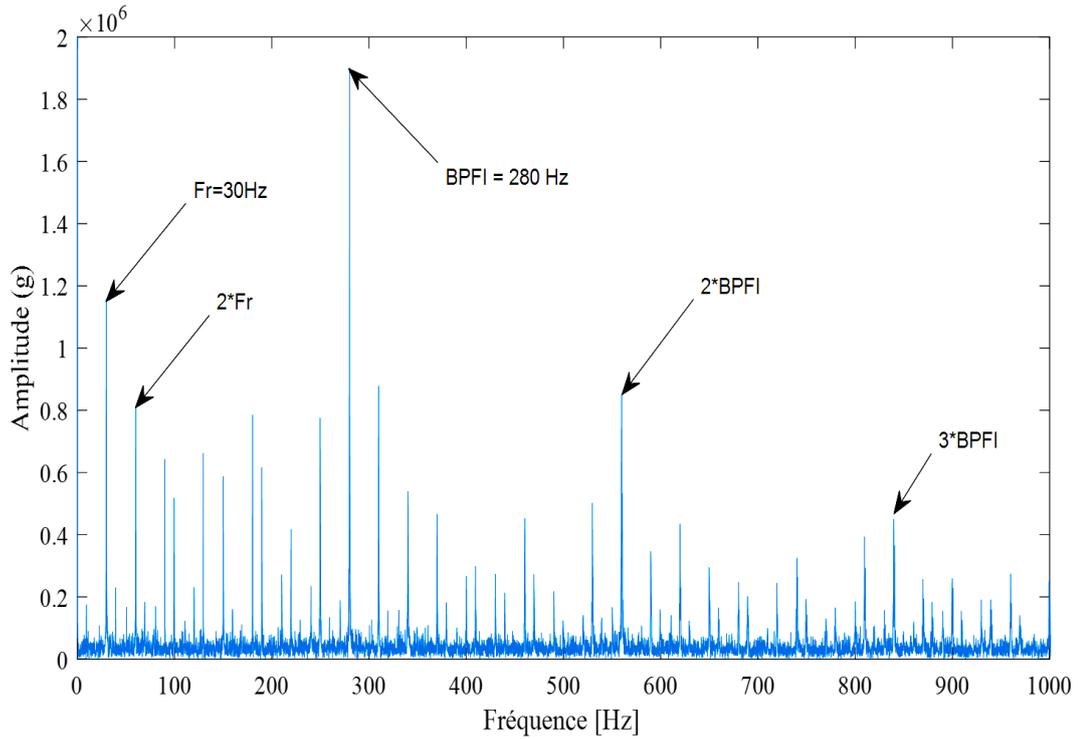


Figure IV.14 : Le spectre d'enveloppe du vecteur de détail D3.

• 50^{ème} jour :

La figure IV.15 montre le signal temporel de dernier jour de mesure alors que la figure IV.16 présente le vecteur optimal après traitement qui correspond au détail D3.

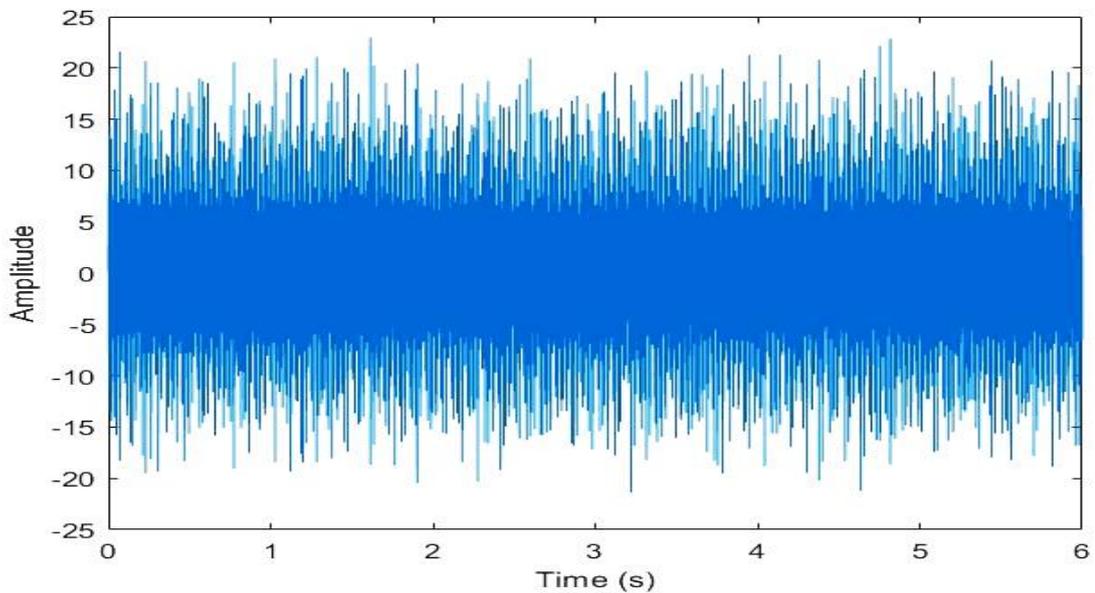


Figure IV.15 : La représentation temporelle de signal du 50^{ème} jour 25/04/2013.

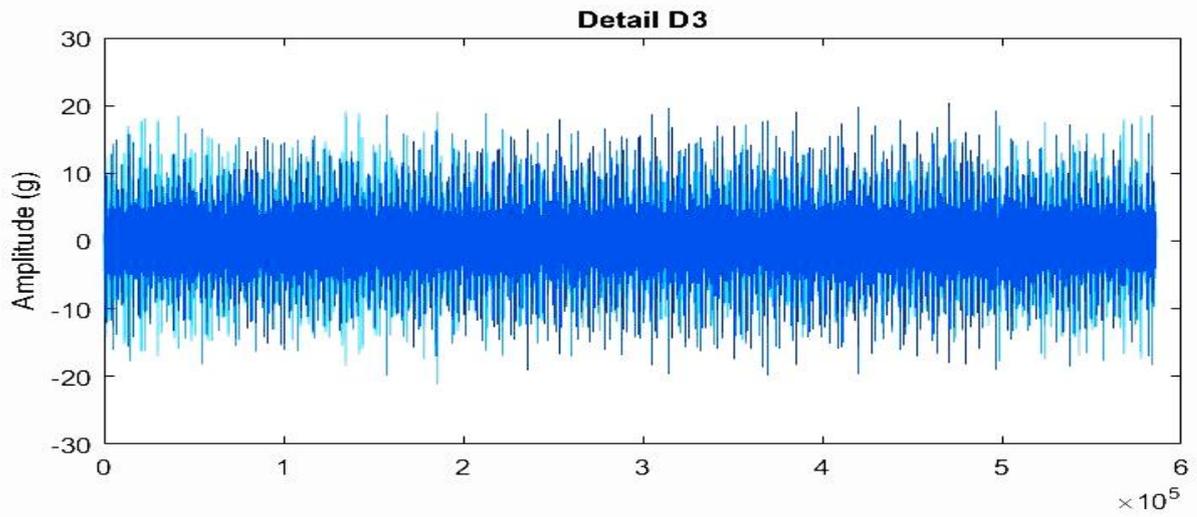


Figure IV.16 : Le vecteur de détail D3.

La figure IV.17 montre spectre d'enveloppe des coefficients d'ondelettes du vecteur de détail D3. Les résultats montrent l'apparition des pics correspondant à la fréquence de rotation ($Fr=31.1667$ Hz). Aussi des pics correspondant au défaut de la bague intérieur (BPFI = 290.333 Hz).

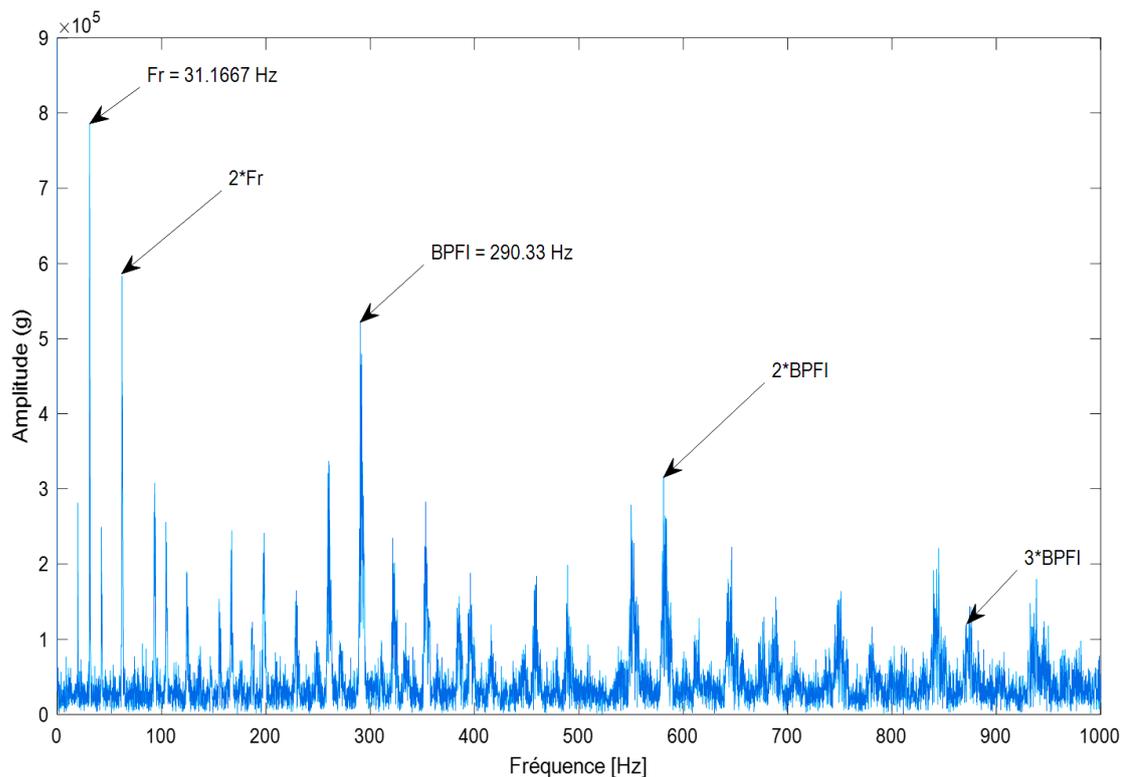


Figure IV.17 : Le spectre d'enveloppe de vecteur de détail D3.

À la fin de la période de surveillance, une défaillance du roulement survient, entraînant un signal considérablement bruité et rendant le diagnostic plus difficile.

5. Traitement des signaux par SOM :

Dans la partie ci-dessous, à partir d'un programme Matlab nous allons traiter les mêmes signaux à l'aide d'une carte auto-organisée en utilisant comme des entrées les valeurs du Kurtosis vu qu'il est l'indicateur scalaire le plus sensible aux chocs que les autres.

Le tableau suivant présente les valeurs de Kurtosis pendant les 50 jours de surveillance et la figure IV.18 présente son comportement durant cette période :

Jour	1	2	3	4	5	6	7	8	9	10
Kurtosis	3.00	3.02	3.02	3.04	3.04	3.02	3.02	3.01	3.07	3.01
Jour	11	12	13	14	15	16	17	18	19	20
Kurtosis	3.12	3.09	3.16	3.08	3.15	3.27	3.35	3.11	3.03	3.09
Jour	21	22	23	24	25	26	27	28	29	30
Kurtosis	3.14	3.13	3.11	3.16	3.11	3.05	3.72	3.35	3.28	3.36
Jour	31	32	33	34	35	36	37	38	39	40
Kurtosis	3.37	3.54	3.74	3.57	3.90	3.90	3.70	4.65	3.41	3.87
Jour	41	42	43	44	45	46	47	48	49	50
Kurtosis	3.40	4.83	4.38	4.30	4.64	4.03	3.85	3.95	5.09	5.56

Tableau IV.2 : Les valeurs de Kurtosis pendant 50 jours.

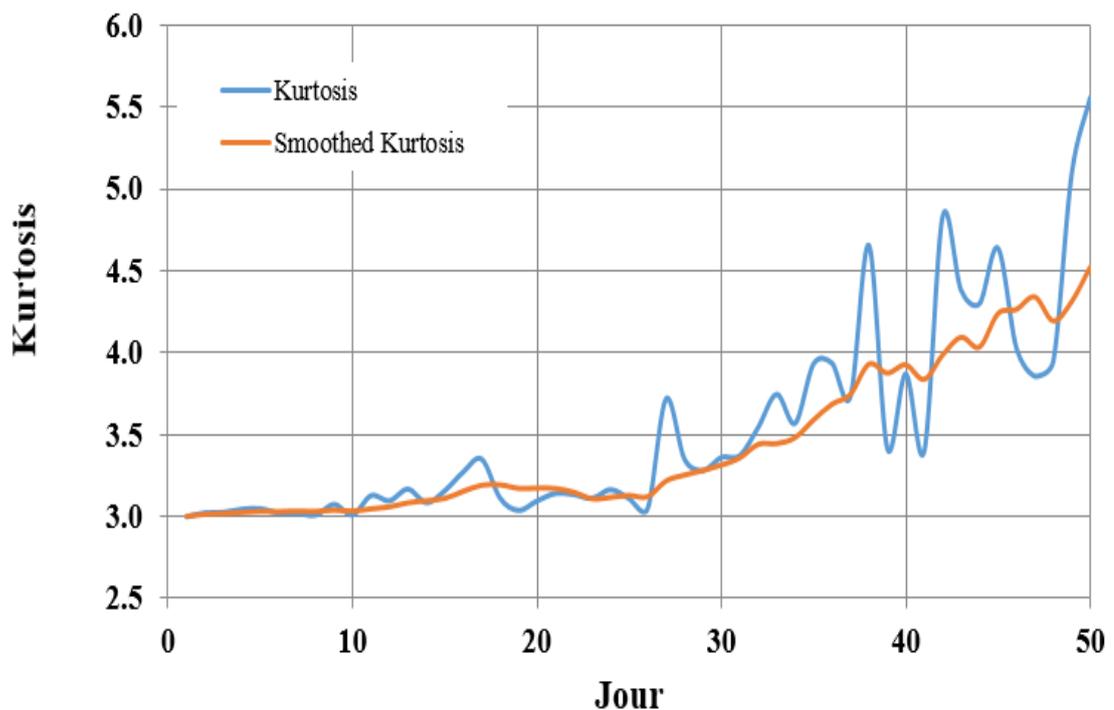


Figure IV. 18 : Évolution du kurtosis pendant la durée de surveillance.

Il est très clair que les valeurs de kurtosis suivent une tendance croissante ce qui implique que la gravité de défaut augmente jour par jour.

Le but de SOM est de classer ces valeurs en des groupes selon le niveau de gravité de défaut ce qui nous faciliter de distinguer les différents états du roulement.

Pour cet exemple, on observe que la carte auto-organisée a regroupée les valeurs de Kurtosis en quatre catégories, chaque catégorie correspond à un stade de vie du roulement : état normal, défaut naissant, défaut grave et la défaillance du roulement.

Il a été constaté que l'état normal représente 50% de la vie entière (du 1^{er} jour jusqu'à le jour 26). Il est suivi par la phase de défaut naissant (16% de la vie entière), puis le défaut devient plus grave. Ce stade sévère est plus long et représente environ 28 % de la vie entière. Enfin, la défaillance du roulement se produit, où des valeurs plus élevées de Kurtosis sont enregistrées.

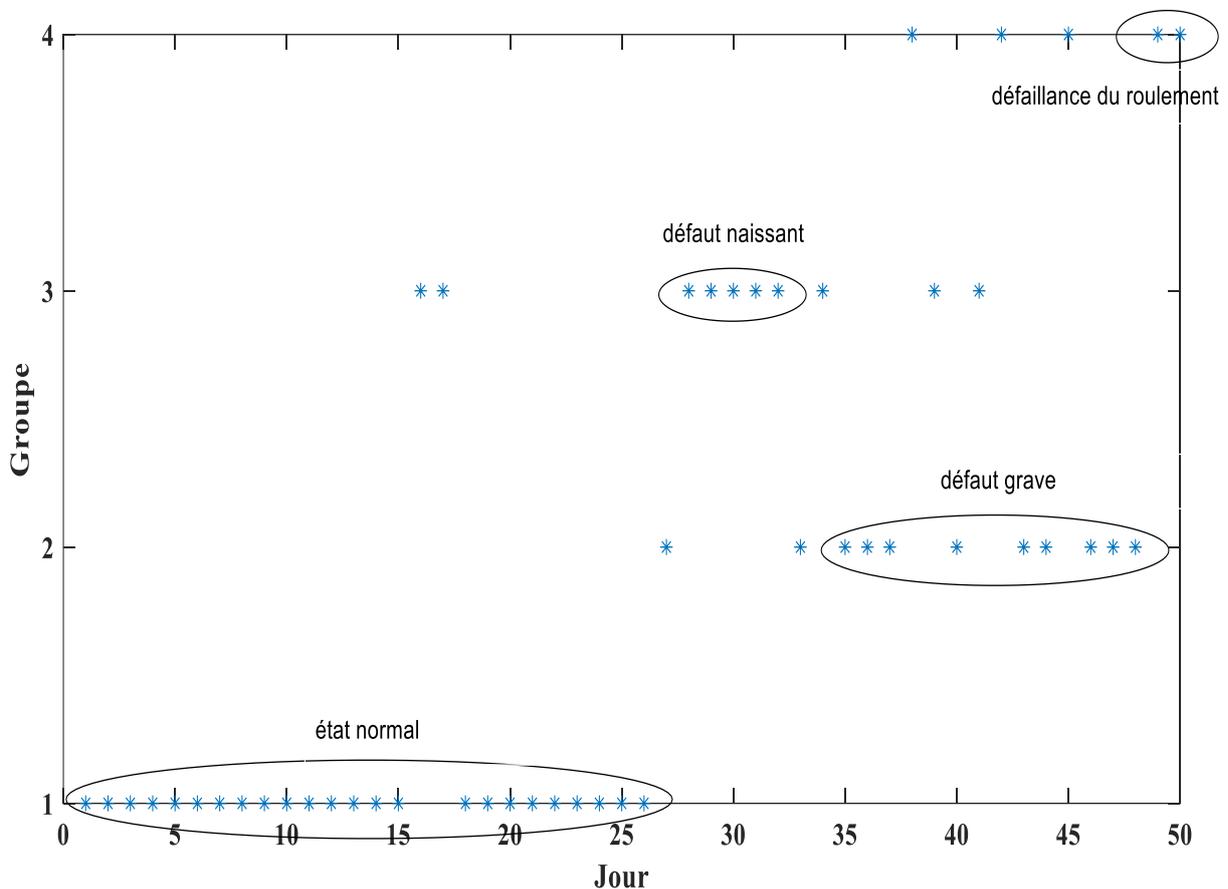


Figure IV.19 : Classification de l'état des roulements par SOM sur la base des valeurs de Kurtosis.

On conclure que les cartes auto-organisatrices (SOM) se révèlent être des outils puissants dans la surveillance des roulements. Grâce à leur capacité à organiser des données complexes en structures visuellement interprétables.

6. Conclusion :

D'après les résultats obtenues dans ce chapitre on peut dire que :

- Le suivi par des indicateurs scalaires (K, RMS, CF, etc.) ou le diagnostic par des indicateurs spectraux (spectre, cepstre, enveloppe) ne permettent pas de déterminer la présence ou l'aggravation des défauts, pour cela nous avons utilisé l'analyse multi-résolution L'AMRO en ondelettes et les cartes auto-organisées SOM.
- L'analyse multi-résolution en ondelettes L'AMRO offre une approche puissante et un outil efficace pour la surveillance des roulements grâce à sa capacité à détecter les signaux vibratoires à différentes échelles de temps et de fréquences permettant une maintenance préventive et une réduction des temps d'arrêt non planifiés.
- Les cartes auto-organisées ont une grande capacité à détecter les changements subtils dans les caractéristiques des signaux qui permet de prédire les défaillances potentielles des roulements avant qu'elles ne se produisent.

Références bibliographiques :

- [1] Djebala, A. Laboratoire de Mécanique et Structures Groupe Comportement Dynamique des Structures et Maintenance Industrielle. Université 8 Mai 1945 Guelma.

Conclusion générale

La combinaison de l'analyse vibratoire et les réseaux de neurones artificiels offre une approche puissante et proactive pour la surveillance et le diagnostic des défauts d'engrenages et de roulements. En intégrant ces technologies dans les processus de maintenance préventive, les entreprises peuvent améliorer la fiabilité de leurs équipements, réduire les temps d'arrêt non planifiés et optimiser leurs opérations globales.

Dans le premier chapitre nous avons fait une étude théorique sur la maintenance en présentant ses différents types avec une étude bibliographique dans le cadre du diagnostic de défauts d'engrenages et de roulements par l'analyse vibratoire et les réseaux de neurones artificiels.

Dans le deuxième chapitre nous avons mis en lumière de l'analyse vibratoire et ses différents domaines d'analyses.

Le troisième chapitre a été une brève théorie sur les réseaux de neurones artificiels RNA en mettant l'accent sur les cartes auto-organisatrices qui ont prouvé leur efficacité à la classification de nombreux de données.

Le dernier chapitre contient les différents résultats obtenus qui montrent l'efficacité de l'analyse multi-résolution en ondelettes à détecter les défauts du roulement ainsi que la fiabilité de la carte auto-organisée à classifier ces défauts en se basant aux valeurs du Kurtosis comme des données d'entrée.