

**Université 8 mai 1945 - Guelma -  
Faculté des Sciences et de la Technologie  
Département de Génie Mécanique**



**MEMOIRE DE FIN D'ETUDE  
Pour l'obtention du diplôme de Master**

**Option : Construction Mécanique**

**Présenté par : NECAIBIA Yasser**

---

---

**Conception d'un système expert basé sur l'approche SOM  
(Self-Organizing Maps) pour l'automatisation du diagnostic  
vibratoire des défauts de roulements**

---

---

Sous la Direction de :

Pr. DJEBALA Abderrazek

**JUIN 2023**

# Remerciements

Je voudrais profiter de cette occasion pour exprimer ma sincère gratitude à toutes les personnes qui ont contribué à la réalisation de ce mémoire de fin d'étude.

Tout d'abord, je tiens à remercier mon directeur de mémoire, **Pr. Abderrazek Djebala**, pour son soutien, son encadrement et ses précieux conseils tout au long de ce projet. Son expertise et son expérience ont été d'une grande valeur pour moi, et j'apprécie énormément le temps et l'énergie qu'il a consacrés à mon travail.

Un grand merci à mes amis et collègues qui m'ont soutenu tout au long de cette aventure académique. Leurs encouragements et leur soutien moral ont été d'une importance capitale, et j'apprécie énormément leur présence à mes côtés.

Je souhaite également exprimer ma gratitude à ma famille pour leur soutien inconditionnel et leur amour. Leur encouragement constant et leur compréhension ont été une source d'inspiration et de motivation tout au long de ce parcours académique.

Enfin, je voudrais exprimer ma reconnaissance envers toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce mémoire. Leurs conseils, leurs critiques constructives et leurs encouragements ont grandement enrichi mon travail.

Merci à tous pour votre soutien et votre contribution précieuse. Votre aide a été inestimable dans la réalisation de ce mémoire de fin d'étude, et je suis profondément reconnaissant pour votre présence et votre collaboration.

# Dédicace

Je dédie ce mémoire de fin d'étude à mes parents, pour leur amour, leur soutien indéfectible et leur confiance en moi tout au long de mon parcours académique. Votre encouragement constant et vos sacrifices ont été ma source de motivation et de détermination. Cette réalisation est également un hommage à votre dévouement et à vos valeurs qui m'ont guidé tout au long de ma vie.

Je souhaite également dédier ce mémoire à **Billel Necaibia**, qui a été ma source d'inspiration et de force pendant cette période. Votre présence et votre soutien inconditionnel ont été essentiels pour surmonter les défis et pour m'encourager à atteindre mes objectifs. Votre confiance en moi a été un moteur pour persévérer et me surpasser.

Je dédie également ce mémoire à mes amis et collègues qui ont partagé cette aventure avec moi. Votre amitié, votre soutien mutuel et nos moments de partage ont rendu cette expérience étudiante inoubliable. Votre présence à mes côtés a été une source de joie et de motivation.

# SOMMAIRE

	<b>Page</b>
<b>Introduction</b>	<b>01</b>
<b>Chapitre 1 : Notions fondamentales et concepts de Base</b>	
1. Maintenance des équipements industriels	<b>02</b>
2. Notion de maintenance conditionnelle	<b>02</b>
3. Analyse vibratoire	<b>03</b>
4. Principaux défauts dans les machines tournantes et leurs images vibratoires	<b>03</b>
4.1. Défauts liés aux arbres	<b>03</b>
4.2. Les défauts des engrenages	<b>04</b>
4.3. Défauts de roulements	<b>04</b>
5. Méthodes de détection des défauts de roulements	<b>06</b>
5.1. L'analyse du lubrifiant	<b>06</b>
5.2. La thermographie infrarouge	<b>06</b>
5.3. L'émission acoustique	<b>07</b>
5.4. L'analyse vibratoire	<b>07</b>
6. Automatisation de la détection des défauts de roulements	<b>09</b>
<b>Chapitre 2 : Détection des défauts de roulements par analyse statistique</b>	
1. Introduction	<b>11</b>
2. Présentation de la base de données	<b>11</b>
3. Analyse statistique des défauts de roulements	<b>12</b>
3.1. Influence de la charge	<b>12</b>
3.2. Influence de la gravité du défaut	<b>20</b>
3.3. Influence de l'orientation du défaut	<b>26</b>
4. Conclusion du chapitre	<b>29</b>
<b>Chapitre 3 : Détection des défauts de roulements par application de la méthode d'enveloppe</b>	
1. Introduction	<b>30</b>
2. Principe de la méthode d'enveloppe	<b>30</b>
3. Résultats obtenus	<b>31</b>
3.1. Cas d'un défaut sur la bague extérieure	<b>31</b>
3.2. Cas d'un défaut sur la bague intérieure	<b>34</b>
3.3. Cas d'un défaut sur la bille	<b>37</b>
4. Conclusion du chapitre	<b>41</b>

## **Chapitre 4 : Automatisation de la détection des défauts de roulements par utilisation de l'algorithme SOM (Self Organizing Maps)**

1. Introduction	42
2. Apprentissage supervisé ou non supervisé ?	42
2.1. Apprentissage supervisé	42
2.2. Apprentissage non-supervisé	43
3. L'algorithme SOM : Self Organizing Maps	43
3.1. Architecture d'un SOM	44
3.2. Etapes de l'algorithme SOM	44
4. Application de l'approche SOM pour automatiser la détection des défauts de roulements	45
4.1. Désignation des indicateurs retenus comme attributs pour l'algorithme SOM	45
5. Application sur les douze signaux	49
5.1. Groupement sur la base du RMS	49
5.2. Groupement sur la base du facteur de crête	49
5.3. Groupement sur la base du kurtosis	50
5.4. Groupement sur la base du Skewness	50
5.5. Groupement sur la base du RMS+ kurtosis	51
5.6. Groupement sur la base du Kurtosis + Facteur de crête	51
5.7. Groupement sur la base du RMS+Kurtosis + Facteur de crête+ Skewness	52
5.8. Groupement sur la base de l'indicateur proposé	52
5.9. Groupement sur la base des 5 indicateurs	53
5.10. Groupement sur la base de l'Indicateur + Kurtosis + facteur de crête	53
5.11. Groupement sur la base de l'Indicateur + RMS	54
5.12. Groupement sur la base de l'Indicateur + RMS+Skewness	54
6. Conclusion du chapitre	56
<b>Conclusion Générale</b>	<b>57</b>
<b>Références bibliographiques</b>	<b>61</b>

# Introduction générale

Les systèmes experts sont de puissants outils d'intelligence artificielle qui permettent de modéliser et de reproduire les connaissances et l'expertise d'un spécialiste humain dans un domaine particulier. Ils sont largement utilisés dans de nombreux domaines, y compris la maintenance prédictive et le diagnostic de défauts.

Dans le domaine de la maintenance industrielle, la détection précoce et précise des défauts de roulements est d'une importance capitale pour assurer un fonctionnement optimal des machines et éviter des pannes coûteuses. Les méthodes traditionnelles de diagnostic reposent souvent sur des techniques manuelles de surveillance vibratoire, ce qui peut être fastidieux et sujet à des erreurs humaines.

Dans ce mémoire, nous proposons la conception d'un système expert basé sur l'approche des Self-Organizing Maps (SOM) pour l'automatisation du diagnostic vibratoire des défauts de roulements. Les SOM sont des algorithmes d'apprentissage non supervisés largement utilisés dans le domaine de la reconnaissance de formes et du traitement des signaux.

L'objectif principal de ce système expert est de fournir une méthode automatisée et précise pour détecter et diagnostiquer les défauts de roulements à partir des données vibratoires collectées sur les machines. En utilisant les SOM, le système sera capable d'apprendre les schémas et les caractéristiques spécifiques associés à chaque type de défaut de roulement, et de les utiliser pour classifier et identifier les défauts dans de nouvelles données.

Le présent mémoire comporte deux volets principaux ; le premier est consacré à l'utilisation des approches classiques pour la détection des défauts de roulements. Ce volet est composé en lui-même de deux parties. La première comporte l'utilisation des indicateurs statistiques pour la détection des défauts de roulements dans différentes configurations à partir de signaux expérimentaux d'une base de données. La deuxième partie est l'application de la célèbre méthode d'enveloppe. Le deuxième volet porte sur la conception d'un système expert pour l'automatisation de la détection des défauts de roulements à partir d'attributs déjà discutés et étudiés dans le premier volet.

Ce mémoire vise enfin à démontrer l'efficacité et l'importance de l'utilisation de l'intelligence artificielle dans le domaine de la maintenance prédictive. Une telle solution automatisée peut contribuer à améliorer la fiabilité et la disponibilité des machines, réduire les coûts de maintenance et augmenter la productivité dans les industries où les roulements jouent un rôle crucial.

# Chapitre 1

## Notions fondamentales et concepts de base

Ce chapitre est consacré à la présentation de quelques notions de base sur la maintenance notamment celle par analyse vibratoire. Des notions sur le traitement du signal et ses applications dans le domaine de la détection des défauts de machines tournantes notamment ceux des roulements est également présenté.

### 1. Maintenance des équipements industriels

La maintenance des équipements industriels est un ensemble de processus visant à maintenir les équipements en bon état de fonctionnement et à prolonger leur durée de vie. Il existe plusieurs types de maintenance, chacun ayant des objectifs et des méthodes spécifiques :

- La maintenance préventive : Elle consiste à effectuer des inspections régulières et des entretiens préventifs pour détecter les défauts potentiels avant qu'ils ne causent des pannes.
- La maintenance corrective : Elle consiste à réparer les équipements après une panne ou un défaut.
- La maintenance prédictive : Elle utilise des techniques avancées de surveillance des équipements pour prédire les défauts et planifier les interventions de maintenance avant qu'ils ne causent des pannes.
- La maintenance conditionnelle : Elle utilise des techniques de surveillance des équipements pour évaluer l'état des équipements et planifier les interventions de maintenance en fonction de l'état réel des équipements.

Il est important de mettre en place un système de maintenance efficace pour prolonger la durée de vie des équipements, réduire les temps d'arrêt, les coûts d'exploitation et les risques pour la sécurité des travailleurs [1].

### 2. Notion de maintenance conditionnelle

La maintenance conditionnelle est une méthode de maintenance qui utilise des données collectées en continu par des capteurs pour évaluer l'état des équipements et planifier les opérations de maintenance en conséquence. Cette méthode permet de remplacer les opérations de maintenance planifiées par des opérations basées sur l'état réel des équipements, et de réduire les temps d'arrêt et les coûts d'exploitation.

La maintenance conditionnelle repose sur l'utilisation de capteurs pour collecter des données sur les paramètres de performance des équipements, tels que les vibrations, le bruit, la température, les courants, les fréquences, les tensions, etc. Ces données sont ensuite analysées pour détecter les anomalies et identifier les défauts potentiels. Les informations collectées sont utilisées pour établir des modèles de performance des équipements, qui permettent de déterminer l'état de santé des équipements et de planifier les opérations de maintenance en conséquence.

La maintenance conditionnelle permet d'optimiser les opérations de maintenance en évitant les arrêts inutiles et en évitant les réparations prématurées. Elle est souvent utilisée en conjonction avec d'autres méthodes de maintenance, telles que la maintenance préventive et la maintenance prédictive, pour fournir une surveillance continue des équipements et une planification efficace des opérations de maintenance.

### 3. Analyse vibratoire

Les vibrations des machines sont considérées comme la réponse de la fonction de transfert de leurs structures aux différents efforts auxquels elles sont sollicitées. La surveillance des vibrations de ces structures peut permettre donc de déceler l'apparition d'efforts perturbateurs à un stade précoce, permettant par la même occasion, de détecter ou d'avorter l'apparition de défaillances. En plus de son efficacité, la facilité relative de son installation rend l'analyse des signaux vibratoires une des techniques les plus utilisées pour la surveillance et le diagnostic des défauts des machines tournantes dans l'industrie. Il existe plusieurs techniques pour analyser les vibrations générées par la machine tournante.

### 4. Principaux défauts dans les machines tournantes et leurs images vibratoires

Une machine tournante n'est en fait qu'un jeu de mécanismes mobiles entre eux, et d'organes combinés dans le but d'effectuer une tâche précise, transformer une énergie, transmettre un mouvement ... etc. Une panne dans une machine tournante n'est que la résultante d'une avarie ou d'une suite d'avarie sur l'un ou plusieurs de ses organes. Dans ce qui suit nous allons voir les défauts les plus courants pouvant se manifester sur quelques organes de machines classés importants.

Paramètre Défauts	Température	Pression	Débit	Analyse d'huile	Vibration
Déséquilibre					●
Arbre non aligné – Flexion d'arbre	●				●
Roulement	●			●	●
Palier	●	●	●	●	●
Engrenage	●			●	●
Frottement	●				●

Tableau 1.1. Paramètres permettant de détecter un défaut sur une machine [1]

#### 4.1. Défauts liés aux arbres

##### 4.1.1. Le balourd

Un balourd est caractérisé par un déséquilibre massique autour de l'axe de rotation qui produit des forces d'inertie. Ces forces agissent sur les corps en rotation et surtout sur les roulements et excitent les paliers.



#### 4.1.2. Le désalignement

Le défaut d'alignement est l'une des principales causes de réduction de la durée de vie des équipements. Il concerne soit deux arbres liés par un accouplement, soit deux paliers soutenant le même axe.

### 4.2. Les défauts des engrenages

#### 4.2.1. Détérioration d'une dent

Si l'une des roues présente une dent détériorée, il se produit un choc dur à chaque tour du pignon.

#### 4.2.2. Détérioration de deux dents sur les deux roues

Si les deux roues dentées présentent chacune une dent détériorée, les chocs peuvent être importants lorsque les deux défauts se rencontrent. La rencontre s'effectue à la fréquence appelée fréquence de coïncidence [2].

#### 4.2.3. Ecaillage

Il s'agit également de trous mais ceux-ci sont moins nombreux, plus profonds et plus étendus que ceux du Pitting. L'écaillage est lié à l'absence de film d'huile entre les surfaces ; cette absence est causée par l'échauffement créé par la vitesse de frottement et de glissement entre les profils des dents [2].

#### 4.2.4. Fissuration

Elle progresse à chaque mise en charge, et elle est située en pied de dent. Elle apparaît sur des aciers fins et durcis superficiellement, qui sont sujets aux concentrations de contraintes. Leur apparition est due à un dépassement de la limite élastique en contrainte au pied de dent du côté de la dent en traction [2].

### 4.3. Défauts de roulements

Les paliers sont des composants critiques des machines tournantes et la surveillance de leur état est importante pour éviter les défaillances catastrophiques et réduire les temps d'arrêt des machines. Douze avaries principales peuvent être retenues et proviennent de quatre familles de causes : Avaries liées à la charge et à la vitesse appliquée : écaillage, grippage, coloration et détérioration des cages. Avaries liées à la lubrification : grippage, rupture des bagues par contraintes thermiques, coloration, détérioration des cages et écaillage. Avaries liées au montage : empreintes des corps roulants par déformation plastique, traces de coups, certaines détériorations des cages, corrosion par contact, certains écaillages provenant des défauts d'alignement et de circularité. Avaries liées à l'environnement : usure, empreintes, corrosion, cratères, cannelures créés par le passage d'un courant électrique [3].



Figure 1.1. Défauts de roulements [3]

Les pistes des roulements et les billes sont chargées cycliquement, ce qui engendre à la surface une dégradation par fatigue qui se présente sous la forme de fissures qui conduisent à l'écaillage et puis à la ruine du roulement. Ces fissures peuvent être d'origine superficielle ou provenir de la dégradation de la sous couche du matériau. Cette ruine peut être détectée sur un spectre à partir de l'identification des fréquences caractéristiques du roulement. Celles-ci correspondent aux fréquences des impacts lorsqu'un élément roulant rencontre un défaut. Elles sont données en écrivant que les vitesses aux points de contact entre billes et bagues sont nulles. Elles dépendent du diamètre des éléments roulants ( $d$ ), du diamètre moyen du roulement ( $D$ ), du nombre d'éléments roulants ( $n$ ), de l'angle de contact ( $\alpha$ ) et de la fréquence de rotation ( $f_r$ ). Elles sont données par les formules suivantes [3]:

Défaut	Fréquence
Un défaut localisé sur la bague externe	$F_{b_{ext}} = 0.5 Fr n \left[ 1 - \left\{ \frac{d}{D} \cos \alpha \right\} \right]$
Un défaut localisé sur la bague interne	$F_{b_{int}} = 0.5 Fr n \left[ 1 + \left\{ \frac{d}{D} \cos \alpha \right\} \right]$
Un défaut localisé sur un élément roulant	$F_{bille} = Fr \frac{D}{d} \left[ 1 - \left\{ \frac{d}{D} \cos \alpha \right\}^2 \right]$
Un défaut localisé sur la cage	$F_{cage} = 0.5 Fr \left[ 1 - \left\{ \frac{d}{D} \cos \alpha \right\} \right]$

**Tableau 1.2. Les fréquences caractéristiques des défauts de roulements**

## 5. Méthodes de détection des défauts de roulements

Une machine idéale ne vibrerait pas car toute l'énergie serait employée pour effectuer le travail demandé. La détérioration d'un ou plusieurs éléments de cette machine se traduit par une augmentation de l'énergie vibratoire qui, puisqu'elle est dissipée à travers la machine, excite les résonances et ajoute une charge dynamique considérable aux paliers. Cause et effet se renforce mutuellement jusqu'à la rupture définitive. Pour la surveillance et le diagnostic des machines tournantes plusieurs technique sont disponibles, le choix de la technique de surveillance et de diagnostic dépend des paramètres tels que : les paramètres de cout d'installation, les paramètres relatifs à la dynamique et la cinématique de la machine, les paramètres environnementaux et d'encombrement et le niveau de criticité de l'application. Dans ce qui suit seront décrites les principales techniques de surveillance et diagnostique [2].

### 5.1. L'analyse du lubrifiant

Le rôle principal du lubrifiant est d'assurer un contact fluide entre les différents composants d'une machine et ainsi diminuer le risque d'usure. Dans le cas d'apparition d'une défaillance dans un organe de la machine, le suivi des caractéristiques physico-chimiques du lubrifiant peut contenir des informations sur son type et son niveau de dégradation, notamment dans le cas de dégradation liée à l'oxydation du lubrifiant, ou de contamination liée à la présence de débris d'usure. Les principaux inconvénients de l'utilisation de l'analyse des lubrifiants pour le diagnostic des défauts dans les machines tournantes sont la difficulté de localisation et d'isolation de l'organe défaillant [2].

### 5.2. La thermographie infrarouge

La thermographie infrarouge part du principe que tout corps dont la température est supérieure à 0°C émet une énergie sous forme de rayonnement électromécanique. Cette énergie est fortement corrélée avec sa température de surface. La thermographie infrarouge consiste à relever ce rayonnement, le quantifier et, s'il est bien calibré, le reconstituer avec une cartographie des températures à la surface de l'objet observé. La thermographie infrarouge est plus généralement utilisée pour la surveillance des installations électriques sous tension, des réseaux de chauffage, ou de

certaines procédés industriels tels que le soudage et le laminage. Son application pour le suivi de l'état de fonctionnement des machines tournantes est plus réduite. Une des principales raisons est l'obligation de ne rencontrer aucun obstacle entre la camera et la surface de l'organe à surveiller [2].

### 5.3. L'émission acoustique

L'émission acoustique est une technique de surveillance qui tend à se généraliser, surtout avec l'apport de techniques avancées pour le traitement et le débruitage des signaux. Bien qu'elle se soit avérée efficace, notamment pour le diagnostic des défauts de roulements et d'engrenages à un stade précoce, elle a aussi montré certains inconvénients. En plus de sa forte sensibilité au bruit, l'émission acoustique s'atténue à travers les différentes interfaces, ce qui requiert un placement des capteurs au plus près de l'installation à surveiller pour une acquisition fiable [2].

### 5.4. L'analyse vibratoire

Les vibrations des machines sont considérées comme la réponse de la fonction de transfert de leurs structures aux différents efforts auxquels elles sont sollicitées. La surveillance des vibrations de ces structures peut permettre donc de déceler l'apparition d'efforts perturbateurs à un stade précoce, permettant par la même occasion, de détecter ou d'avorter l'apparition de défaillances. En plus de son efficacité, la facilité relative de son installation rend l'analyse des signaux vibratoires une des techniques les plus utilisées pour la surveillance et le diagnostic des défauts des machines tournantes dans l'industrie. Il existe plusieurs techniques pour analyser les vibrations générées par la machine tournante [2] :

#### 5.4.1. Indicateurs scalaires

Cette technique rapide, extrait des indicateurs, pour la plupart statistiques, résumant l'information contenue dans le signal et permettant de générer un repère. Le suivi d'évolution du repère donne une information plus ou moins précise et complète sur son état de fonctionnement. Une multitude d'indicateurs existent plus ou moins performants et adéquats pour le dépistage de certaines défaillances plus que d'autres. Les indicateurs les plus utilisés sont décrits comme suit :

**a) RMS :** Le RMS, nommée aussi valeur efficace ou moyenne quadratique d'un signal. Le RMS est un des premiers indicateurs utilisés en industrie, dû notamment à sa simplicité et à sa rapidité d'exécution. Une variation excessive du niveau RMS signifie en général un changement de l'état de fonctionnement et donc une défaillance.

$$\text{RMS} = \sqrt{\frac{1}{N_e} \sum_{n=1}^{N_e} [s(t)]^2} \quad (1.1)$$

**b) Facteur de crête :** c'est un indicateur de surveillance simple à calculer, car c'est le rapport entre la valeur de crête du signal et sa valeur efficace (RMS), comme il peut se calculer par le rapport entre la valeur maximale du signal et son écart type.

$$F_c = \frac{V_{crete}}{RMS} \quad (1.2)$$

Cet indicateur est utilisé pour la détection spécifique d'impulsions ou de choc présents dans le signal vibratoire.

c) **Kurtosis** : Plus spécifique au dépistage des défauts de roulements. Le Kurtosis approche la valeur de 3 pour un fonctionnement sans défauts de roulement, et augmente de façon remarquable dès l'apparition d'impulsions dues à la naissance d'un défaut. Le Kurtosis tend à revenir à 3 dès que la dégradation entre en phase terminale.

$$\text{Kurtosis} = \frac{\frac{1}{N_e} \sum_{n=1}^{N_e} [S(t) - \bar{S}]^4}{\left[ \frac{1}{N_e} \sum_{n=1}^{N_e} [S(t) - \bar{S}]^2 \right]^2} \quad (1.3)$$

d) **Moment d'ordre 3** : couramment appelé « Skewness », représente le taux de dissymétrie de la distribution d'amplitudes du signal par rapport à la valeur moyenne:

$$M_3 = S_k = \frac{1}{\sigma^3} \int_{-\infty}^{+\infty} (x - \bar{x})^3 p(x) dx \quad (1.4)$$

#### 5.4.2. Analyse spectrale

Le signal vibratoire extrait d'une machine tournante est très complexe, originaire des différents organes la composant. La transformée de Fourier est un outil mathématique permettant de transformer ces signaux complexes, de les décomposer en une multitude de composantes élémentaires sinusoïdales et de les représenter sous forme d'un spectre «Amplitudes-fréquence ». La transformée de Fourier rapide FFT développée par James Cooley et John Tukey, ne requiert qu'un temps de calcul minimale pour appliquer la transformée de Fourier Discrète. La FFT a été largement implémentée dans les systèmes de diagnostic des machines tournantes.

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \quad (1.5)$$

Où : X(f) est la transformée de Fourier, x(t) est le signal temporel, t est la variable temps, f est la variable fréquence.

Dans des conditions de fonctionnement stationnaires « vitesses de rotations et chargements stationnaires », chaque organe de la machine émet des vibrations à un certain niveau d'amplitude, et à une cadence « fréquence » constante dans le temps.

L'apparition de défauts dans les organes de la machine tournante génère des efforts supplémentaires qui se traduisent par des vibrations se répétant à une cadence « fréquence » constante (fbint, fbext, f bille dans le cas des roulements), relative à la fréquence de rotation. Suivre les amplitudes des vibrations à ces fréquences, permet de suivre les conditions de fonctionnement des différents organes de la machine tournante.

### 5.4.3. Analyse cepstrale

L'analyse cepstrale est une technique complémentaire d'analyse, développée sur plusieurs variantes, dont les plus utilisées sont le cepstre complexe défini comme la transformée de Fourier inverse du logarithme décimal de la transformée de Fourier, s'exprime selon une variable uniforme au temps, et est représentée par la formule :

$$C = TF^{-1}[\text{Ln}|X(f)|] \quad (1.6)$$

De même que la transformée de Fourier permet de mettre en évidence les périodicités d'un signal temporel, le cepstre met en évidence les périodicités de sa transformée de Fourier. Opinant par la même occasion, de rechercher, d'identifier et de quantifier rapidement toutes les familles de composantes périodiques qui peuvent se manifester dans le spectre sous forme de peignes de raies ou bandes latérales de modulation autour d'une fréquence caractéristique ce qui n'est pas toujours évident dans le cadre de l'analyse spectrale. Les unités et grandeurs sont autres dans le cepstre que ceux utilisés dans l'analyse spectrale, ainsi on trouve entre autres; les périodicités qui sont appelées « Quéfrences » et sont exprimées en secondes ou millisecondes et les harmoniques qui deviennent des « Rahmoniques ».

### 5.4.4. Analyse d'enveloppe

L'analyse d'enveloppe est une technique de détection précoce des défauts de type choc. Pour ce faire le signal vibratoire est relevé dans une bande fréquentielle large, et filtré autour d'une fréquence de résonance. Le signal est ensuite redressé « en mettant au positif 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.

### 5.4.5. Analyse Temps-Fréquence

L'analyse spectrale classique basée sur la transformée de Fourier présente un sérieux inconvénient, vu qu'elle suppose que la majorité des signaux sont infinis dans le temps ou périodiques, alors qu'en réalité ils peuvent être de courte durée et comporter des variations au cours du temps d'acquisition. Pour pallier cet inconvénient, 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, la Distribution de Wigner-Ville, ou les techniques à base d'ondelettes.

## 6. Automatisation de la détection des défauts de roulements

La multitude des images vibratoires des défauts rencontrés sur les machines tournantes a rendu la fonction de diagnostic difficile, dépassant de loin les capacités intellectuelles du maintenicien, d'où l'intégration de l'intelligence artificielle dans le domaine du diagnostic vibratoire. La nécessité d'automatiser cette fonction par l'intégration de systèmes experts est devenue l'une des priorités de la maintenance. Le problème avec ces systèmes, dits experts ou automatiques, c'est qu'ils dépendent étroitement de l'utilisateur ou du programmeur. Le résultat obtenu dépend donc

directement du choix des entrées choisies comme attributs. Le point crucial reste donc le choix optimal d'attributs pertinents permettant une détection automatique efficace en fonction du (des) type(s) de défaut(s) rencontrés [4].

Deux grandes classes de méthodes existent ; celles basées sur un apprentissage supervisé et celles basées sur un apprentissage non-supervisé. Dans les méthodes basées sur l'apprentissage supervisé le résultat final est déjà connu, le système est guidé par l'utilisateur durant la phase d'apprentissage et les différentes classes sont connues d'avance. En diagnostic vibratoire, l'utilisateur va apprendre le système à reconnaître chaque type de défaut à partir d'un certain nombre d'attributs. Plusieurs signaux seront donc utilisés dans cette phase à titre d'entraînement. Une fois le résultat de la phase d'entraînement est satisfaisant, le système sera théoriquement capable de reconnaître n'importe quel type de défaut à partir des attributs dont il connaît d'avance la variation, et peut donc le mettre dans sa classe correspondante. Le point faible de ces méthodes c'est la nécessité d'un grand nombre de données d'entrée pour l'entraînement et pour le test. En plus, et ceci dans un contexte plus pratique, le système peut conduire à un faux classement et donc à un faux diagnostic dans le cas où il rencontre un type de défaut pour lequel il n'a pas été entraîné pour le reconnaître [4].

Pour les méthodes à apprentissage non-supervisé, le résultat attendu n'est pas connu à priori. Le système tend à grouper les données, plutôt que de les classer, sur la base de leur similitude. Cette méthode ne requiert pas beaucoup de signaux comme c'est le cas pour les méthodes supervisées. En plus, le système n'étant pas influencé par l'utilisateur, est capable de grouper plusieurs types de défauts qu'il ne connaît pas à priori. Le plus difficile dans cette approche est le choix d'attributs pertinents permettant la tâche de groupement sans erreur possible.

Pour les méthodes non-supervisées, le groupement par l'algorithme SOM (Self Organizing Maps) est sans doute la technique la plus utilisée. Appartenant aux ANN, elle est nommée aussi cartes de Kohonen du nom du statisticien Finlandais ayant développé cette approche en 1982. Cette méthode est utilisée notamment pour le groupement, la visualisation, et l'exploration dans l'analyse des données. Comme il s'agit d'une approche non-supervisée, la SOM permet le groupement des données sans connaissance préalable des classes de sortie. L'algorithme est basé sur la mesure de la similitude entre les échantillons par le calcul de la distance Euclidienne. Les échantillons jugés similaires sont donc classés ensemble [4-5]. Cette méthode a été utilisée dans quelques articles pour la détection des défauts de roulements, mais leur nombre reste relativement faible par rapport aux autres approches d'automatisation, notamment les réseaux de neurone [6-8]

## Chapitre 2


# Détection des défauts de roulements par analyse statistique

### 1. Introduction

Dans ce chapitre nous allons entamer une étude paramétrique portant sur l'analyse de la sensibilité de quatre indicateurs scalaires en fonction de plusieurs paramètres. Le kurtosis, le facteur de crête, le RMS et le skewness sont les quatre indicateurs pris en considération dans cette étude. Les paramètres étudiés sont la gravité du défaut, la charge appliquée sur le roulement, le type du défaut et son orientation. Pour réaliser ce travail nous avons utilisé les signaux disponibles dans la base de données Américaine « Bearing Data Center » qui permet une étude paramétrique complète vu les différents paramètres pris en considération lors de la mesure des différents signaux.

### 2. Présentation de la base de données

C'est une base de données Américaine permettant d'accéder à des signaux de roulements sains et endommagés sous différentes configurations (différentes tailles du défaut, différents couples, différents types de défaut, ...etc.). Le banc d'essai se compose principalement d'un moteur (à gauche), d'un accouplement « transducteur/encodeur » (au centre), d'un dynamomètre (à droite) et des circuits de commande (non montrés). Les signaux ont été enregistrés à l'aide d'accéléromètres fixés à la cage du moteur par aimant.



**Figure 2.1.** Banc d'essai de roulement de « Bearing Data Center »



Les paramètres des mesures sont les suivants :

- Les couples résistants sont respectivement 0, 1, 2, 3 Hp ce qui donne des vitesses respectives de 1797, 1772, 1750, 1730 tr/min ;
- La fréquence d'échantillonnage est  $F_e = 48 \text{ KHz}$  ;
- La taille des défauts de roulements sont: 0.007 inch, 0.014 inch, 0.021 inch ;
- Les roulements que nous avons considérés dans notre travail sont les roulements du côté accouplement. Les fréquences caractéristiques sont :
  - Fréquence de la bague intérieure :  $F_{bi} = 5,4152 \times F_r$ .
  - Fréquence de la bague extérieure :  $F_{be} = 3,5848 \times F_r$ .
  - Fréquence de la bille :  $F_b = 4,7135 \times F_r$ .
  - Fréquence de la cage :  $F_c = 0,3982 \times F_r$ .

	29,95 Hz (0 Hp)	29,53 Hz (1 Hp)	29,16 Hz (2 HP)	28,83 Hz (3 Hp)
Bague intérieure	162,18 Hz	159,91 Hz	157,90 Hz	156,12 Hz
Bague extérieure	107,36 Hz	105,85 Hz	104,53 Hz	103,34 Hz
La bille	141,16 Hz	139,18 Hz	137,44 Hz	135,89 Hz
La cage	11,92 Hz	11,75 Hz	11,61 Hz	11,48 Hz

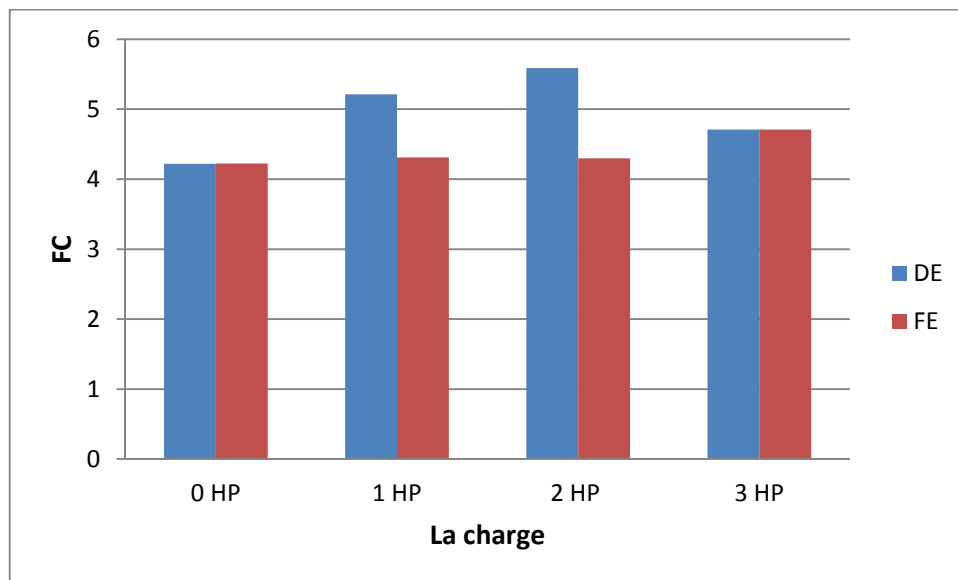

### **3. Analyse statistique des défauts de roulements**

#### **3.1. Influence de la charge**

##### **3.1.1. Sans défaut**

La figure (2.2) montre les quatre indicateurs scalaires (RMS, Facteur de crête, Kurtosis, Skewness) en fonction de la charge appliquée sur le roulement. On constate que la charge n'a pas d'influence notable sur le RMS, le FC et le Skewness. Par ailleurs, le Kurtosis augmente avec l'augmentation de la charge mais avec des proportions très faibles.

## Chapitre 2 : Détection des défauts de roulements par analyse statistique








Figure 2.2. Indicateurs scalaires en fonction de la charge dans le cas sans défaut


### 3.1.2. Défaut sur la bague intérieure 0.014 Inch

Dans ce cas le RMS augmente légèrement avec l'augmentation de la charge, alors que le FC et le Kurtosis augmentent considérablement avec la charge, surtout le Kurtosis, puis ils diminuent pour la plus grande charge (3HP).

Le Skewness dans ce cas se montre sensible à la charge puisqu'il augmente avec son augmentation (figure 2.3).

## Chapitre 2 : Détection des défauts de roulements par analyse statistique







**Figure 2.3. Indicateurs scalaires en fonction de la charge dans le cas d'un défaut sur la bague intérieure**

### 3.1.3. Défaut sur la bague extérieure 0.007 Inch à 6H

Pour le cas d'un défaut sur la bague extérieure, la figure (2.4) montre que les valeurs des quatre indicateurs scalaires sont beaucoup plus importants dans le cas où le capteur est placé directement sur le roulement défectueux (DE) ce qui est logique. La charge se montre sans effet sur le RMS qui reste presque constant, le facteur de crête augmente avec l'augmentation de la charge mais dans de faibles proportions, la même remarque est valable pour le Kurtosis et le Skewness qui eux aussi augmentent avec l'augmentation de la charge mais dans de faibles proportions (6.74 jusqu'à 7.39) pour le Kurtosis et (0.076 jusqu'à 0.079).




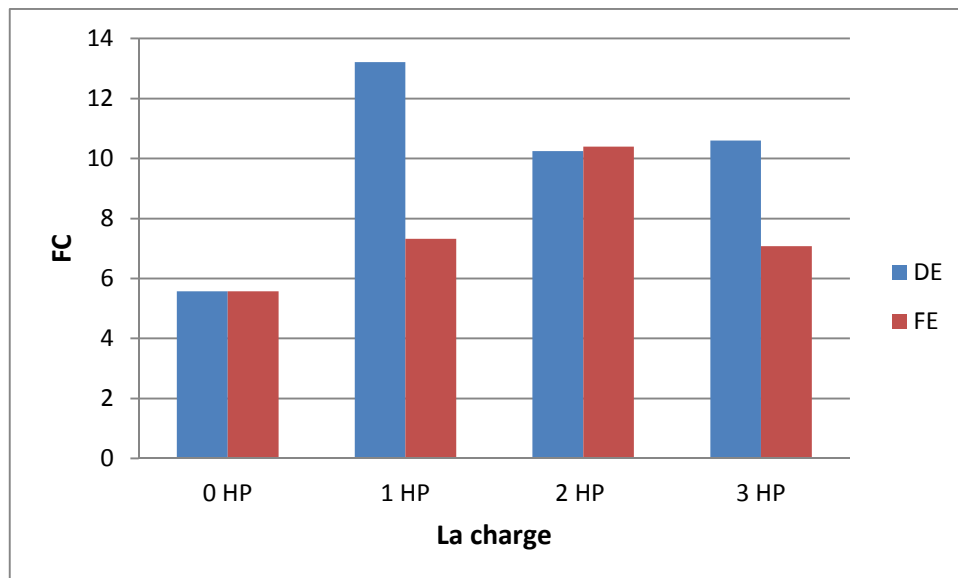



Figure 2.4. Indicateurs scalaires en fonction de la charge dans le cas d'un défaut sur la bague extérieure

### 3.1.4. Défaut sur la bille 0.021 Inch

Pour le défaut de bille, le RMS décroît légèrement avec l'augmentation de la charge, tandis que le FC et le Skewness augmentent considérablement avec la charge puis affichent une légère baisse.

## Chapitre 2 : Détection des défauts de roulements par analyse statistique






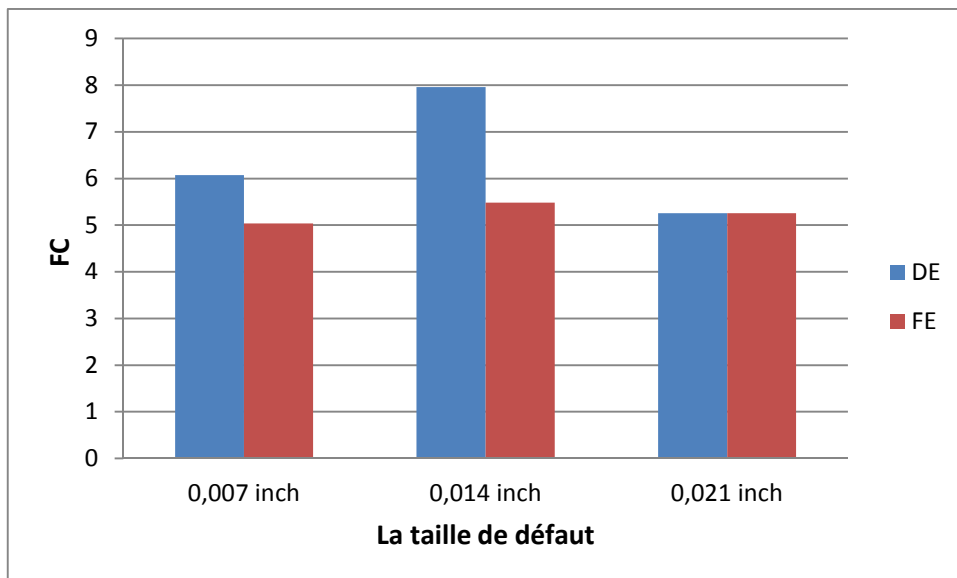




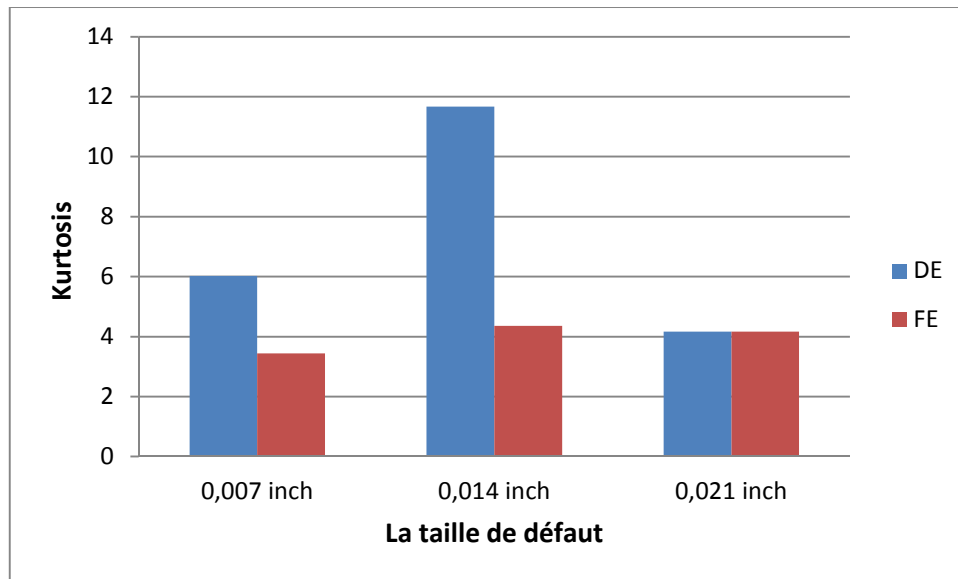
Figure 2.5. Indicateurs scalaires en fonction de la charge dans le Cas d'un défaut sur la bille

### 3.2. Influence de la gravité du défaut

#### 3.2.1. Défaut sur la bague intérieure 0 HP

Dans ce cas le RMS a une tendance parabolique alors que le Kurtosis et le facteur de crête augment avec la taille du défaut puis diminuent pour la plus grande taille de défaut (0.021 inch). Ceci concorde avec la littérature car ces deux indicateurs, notamment le kurtosis, affichent une tendance baissière si la gravité du défaut devient excessive, et c'est d'ailleurs leur point faible. Par ailleurs le Skewness augmente avec l'augmentation de la taille du défaut.









## 2.6. Indicateurs scalaires en fonction de la gravité du défaut dans le cas d'un défaut sur la bague intérieure

### 3.2.2. Défaut sur la bague extérieure 2 HP à 6H

Dans ce cas on considéré le cas d'un défaut sur la bague extérieure avec une charge (2 HP) et à 6h (figure 2.7). Le RMS et le Skewness affichent une tendance parabolique (diminuent puis augmentent), alors que le FC et le Kurtosis affichent une tendance haussière avec l'augmentation de la taille du défaut.






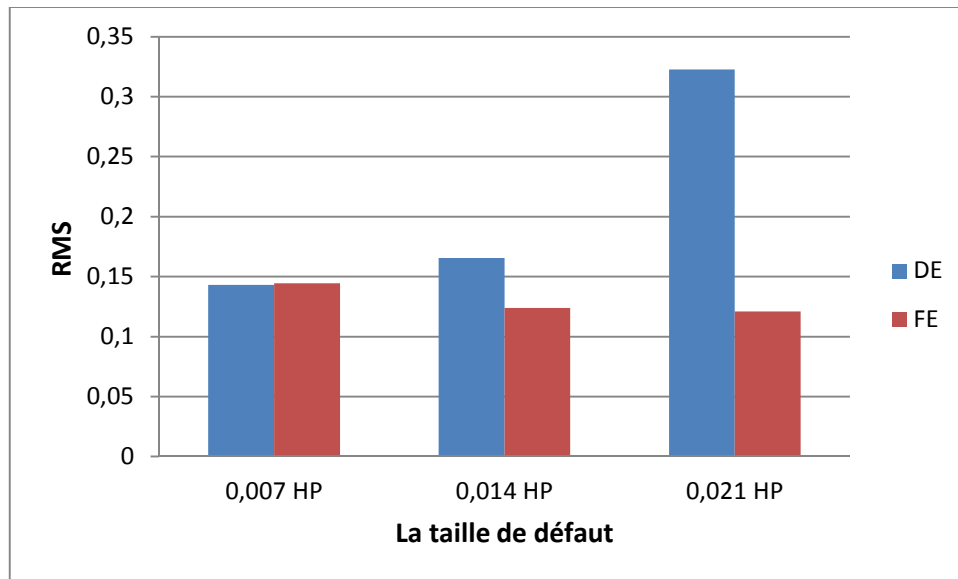
### 2.7. Indicateurs scalaires en fonction de la gravité du défaut dans le cas d'un défaut sur la bague extérieure



#### 3.2.3. Défaut sur la bille 3 HP

Dans ce cas le RMS et le Kurtosis ont la même tendance, ils augmentent avec l'augmentation de la taille du défaut notamment par le Kurtosis.

Le facteur de crête et le Skewness augmentent puis diminuent pour la plus grande taille du défaut (0.021 inch).

## Chapitre 2 : Détection des défauts de roulements par analyse statistique


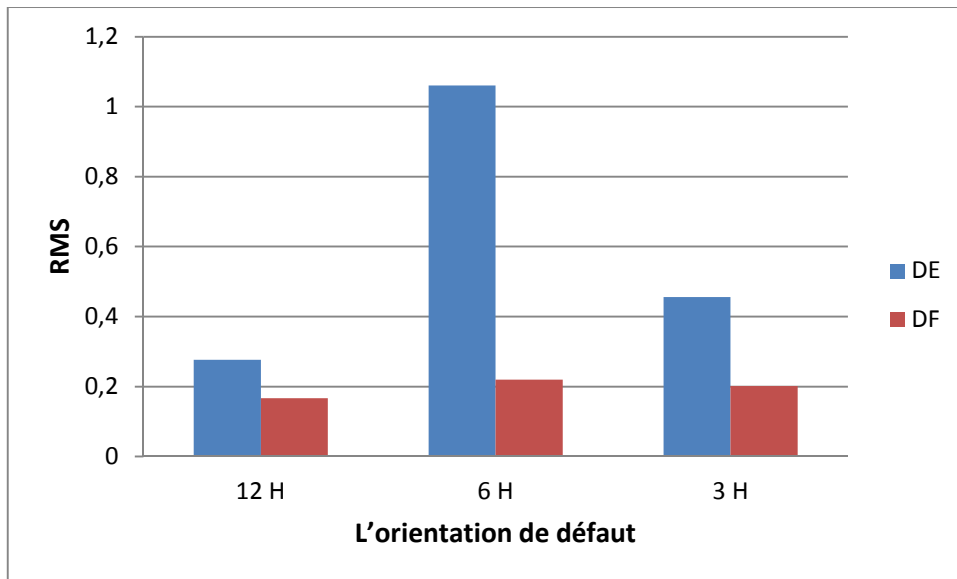




## 2.8. Indicateurs scalaires en fonction de la gravité du défaut dans le cas d'un défaut sur la bille

### 3.3. Influence de l'orientation du défaut

Dans ce cas on s'intéresse à vérifier si l'orientation du défaut sur la bague extérieure a une influence sur les indicateurs scalaires. Pour le RMS et le Skewness, les valeurs maximales sont enregistrées dans le cas où le défaut est orienté à 6h. Pour le Kurtosis et le FC elles sont enregistrées à 12 h, c'est-à-dire dans le cas où le capteur est fixé directement sur le défaut. En effet dans ce cas toute l'énergie vibratoire est mesurée par le capteur, ce qui explique les valeurs importantes.








Figure 2.9. Influence de l'orientation de défaut

#### 4. Conclusion du chapitre

Le travail entamé dans ce chapitre est une étude paramétrique portant sur l'utilisation de quatre indicateurs scalaires, le RMS, le facteur de crête, le kurtosis et le skewness. Plusieurs paramètres ont été pris en considération pour vérifier la sensibilité de ces quatre indicateurs pour la détection des défauts de roulements.

Le travail a été réalisé sur des signaux expérimentaux de la base de données Américaine « Bearing Data Center » qui permet un large choix des paramètres étudiés (charge, type du défaut, taille du défaut, orientation, ...etc.).

Les résultats montrent de tendances parfois très distinctes des indicateurs scalaires. Le RMS est sensible à l'énergie du signal et affiche donc des tendances contradictoire avec le kurtosis et le facteur de crête qui sont sensibles à la forme du signal. Le skewness, quant à lui, se montre plutôt proche du RMS que des deux autres indicateurs.

En conclusion, cette étude ne fait que confirmer la grande supériorité du kurtosis en tant qu'indicateur scalaire de première intention à appliquer pour la surveillance et la détection des défauts de roulement.

## Chapitre 3

# Détection des défauts de roulements par application de la méthode d'enveloppe

### 1. Introduction

Dans ce chapitre nous allons utiliser la méthode d'enveloppe pour la détection des différents défauts de roulements que nous avons déjà discutés au chapitre 2. La méthode d'enveloppe est une approche bien connue dans le domaine de la détection des défauts. Elle est principalement basée sur un filtrage bande et la transformée de Hilbert. La particularité de notre travail est le fait que le filtrage que nous avons utilisé est basé sur la transformée en ondelettes.

### 2. Principe de la méthode d'enveloppe

La figure (3.1) montre les principales étapes utilisées pour appliquer la méthode d'enveloppe. La première étape est un filtrage passe bande pour cerner la fréquence propre du roulement. Ensuite la transformée de Hilbert est appliquée sur le signal filtré et une enveloppe est calculée. Enfin un spectre d'enveloppe est calculé pour mettre en évidence la fréquence du défaut et ses harmoniques.

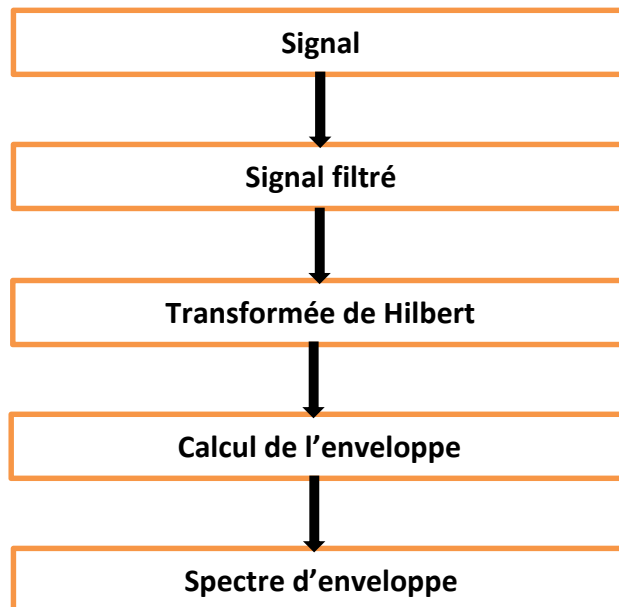


Figure 3.1. Etapes de la méthode d'enveloppe

### 3. Résultats obtenus

#### 3.1. Cas d'un défaut sur la bague extérieure

Dans ce cas on considère un défaut sur la bague extérieure orienté à 12 H. la figure (3-2) montre le résultat obtenu dans le cas d'un défaut d'une gravité de 0.007 inch et une charge de 0 HP. Dans ce cas le spectre ne donne aucune information sur le défaut. Le spectre d'enveloppe montre un pic correspondant à (107.8 HZ) ce qui correspond parfaitement à la fréquence caractéristique d'un défaut sur la bague extérieure pour une charge 0HP. Plusieurs harmoniques de la fréquence du défaut sont visibles.

Le même résultat est obtenu pour le cas où le roulement est chargé (1HP, 2HP, 3HP). Dans ce cas à cause de la charge, la vitesse de roulement diminue et la fréquence du défaut diminue aussi. Les spectres d'enveloppe montrent des fréquences caractéristiques de (106,2 HZ) pour le cas 1HP (figure 3.3), 104,9HZ pour le cas 2HP (figure 3.4) et enfin 103,3HZ pour le cas 3HP (figure 3.5). Notons également que les amplitudes du spectre d'enveloppe sont beaucoup plus importantes dans le cas où le roulement est chargé, donc la détection est meilleure dans ce cas.

Pour le cas où la gravité du défaut est beaucoup plus importante (0.014 inch), les spectres d'enveloppes montrent à chaque fois la fréquence caractéristique d'un défaut sur la bague extérieure, avec un petit décalage dans certains cas. Le plus important c'est que ces spectres d'enveloppe sont très riches des composantes correspondant à la fréquence de rotation et ses harmoniques et ses sous-harmoniques (figures 3-6 jusqu'à 3-9).

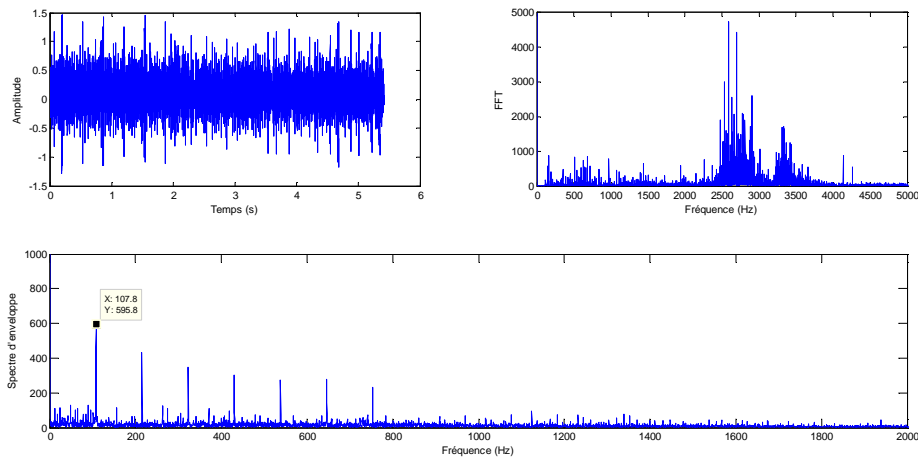


Figure 3.2. Cas d'un défaut sur la bague extérieure : 0HP, 0.007 inch

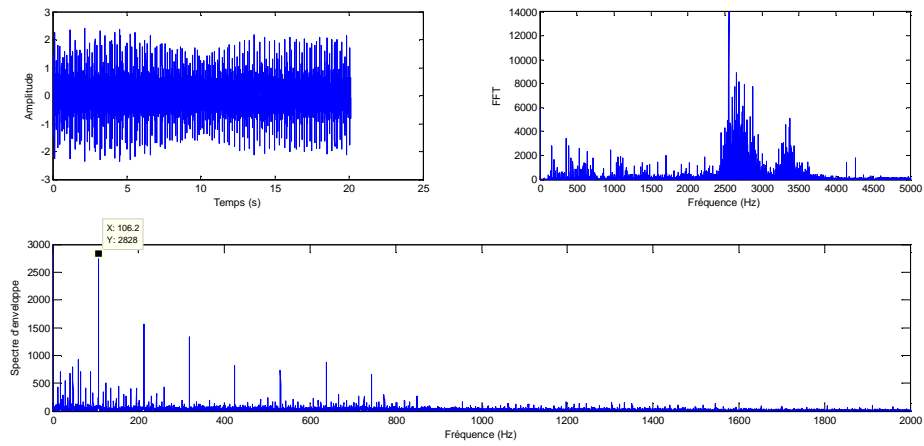


Figure 3.3. Cas d'un défaut sur la bague extérieure : 1HP, 0.007 inch

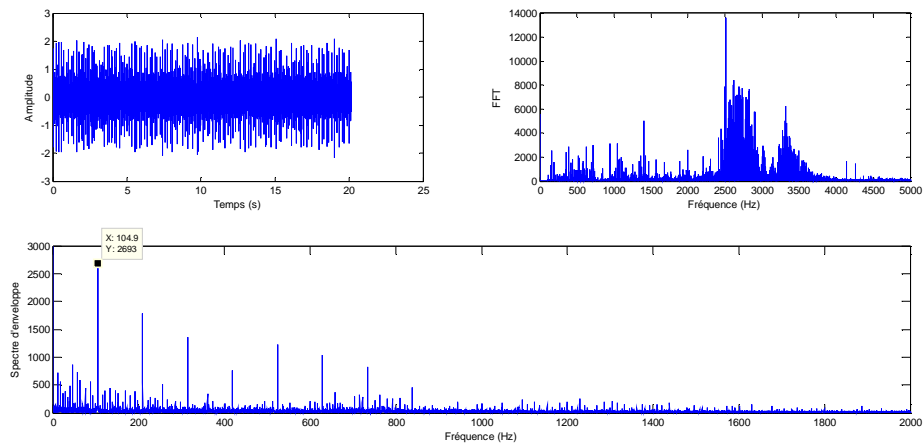


Figure 3.4. Cas d'un défaut sur la bague extérieure : 2HP, 0.007 inch




Figure 3.5. Cas d'un défaut sur la bague extérieure : 3HP, 0.007 inch




Figure 3.6. Cas d'un défaut sur la bague extérieure : 0HP, 0.014 inch




Figure 3.7. Cas d'un défaut sur la bague extérieure : 1HP, 0.014 inch

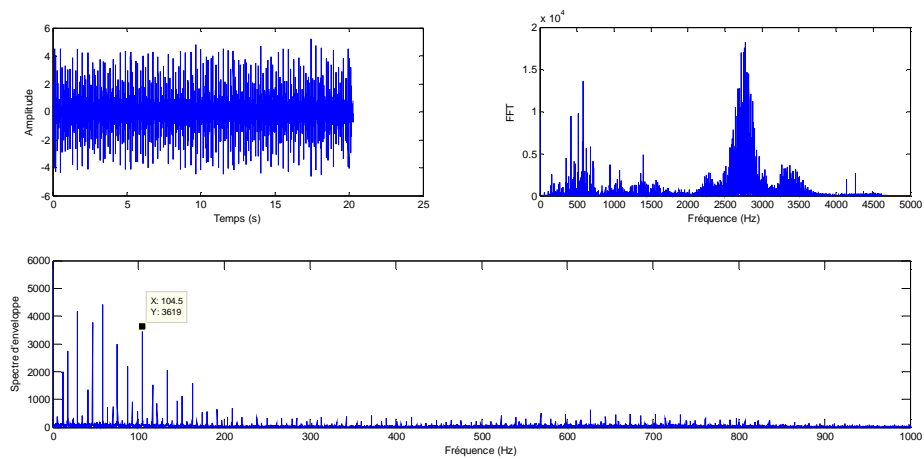


Figure 3.8. Cas d'un défaut sur la bague extérieure : 2HP, 0.014 inch

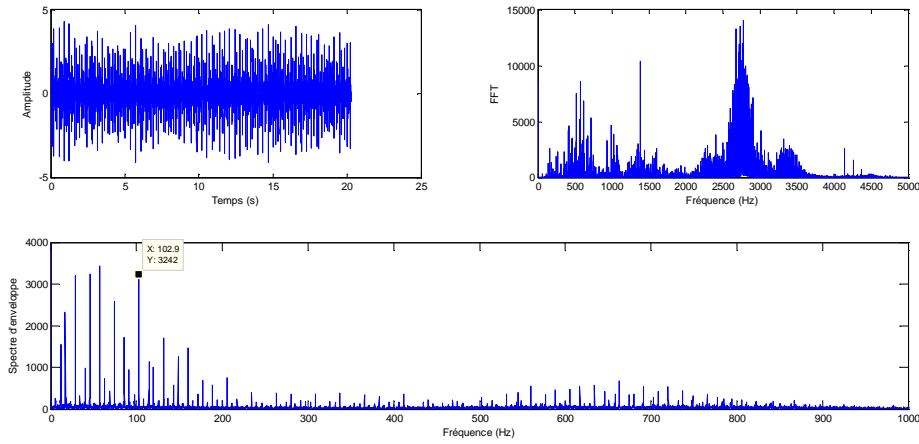


Figure 3.9. Cas d'un défaut sur la bague extérieure : 3HP, 0.014 inch

### 3.2. Cas d'un défaut sur la bague intérieure

Dans ce cas on considère un défaut sur la bague intérieure. La figure (3.10) montre le résultat obtenu pour une gravité de 0.007 inch et une charge de 0 HP. Le spectre d'enveloppe montre une composante principale et plusieurs de ses harmoniques. Cette composante est égale 0 (161.7 HZ) ce qui correspond parfaitement à la fréquence d'un défaut sur la bague intérieure.

Le même résultat est obtenu pour les trois autres charges (1HP, 2HP, 3HP) avec un décalage dû à la diminution de la fréquence de rotation (figures 3.11 jusqu'à 3.13).

Les mêmes constatations sont valables dans le cas où le gravité du défaut est égale à 0.021 inch avec la présence de plusieurs composantes correspondant à la fréquence de rotation et ses harmoniques et sous-harmoniques figures (3.14 jusqu'à 3.17).

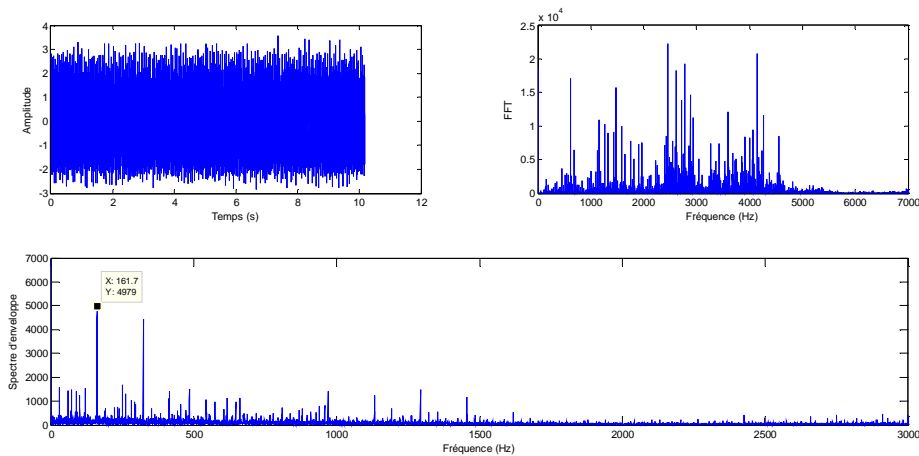


Figure 3.10. Cas d'un défaut sur la bague intérieure : 0HP, 0.007 inch

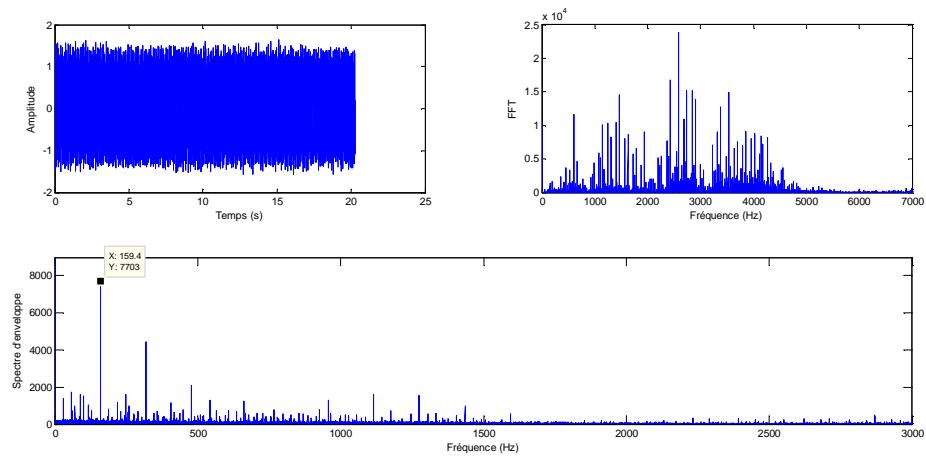


Figure 3.11. Cas d'un défaut sur la bague intérieure : 1HP, 0.007 inch

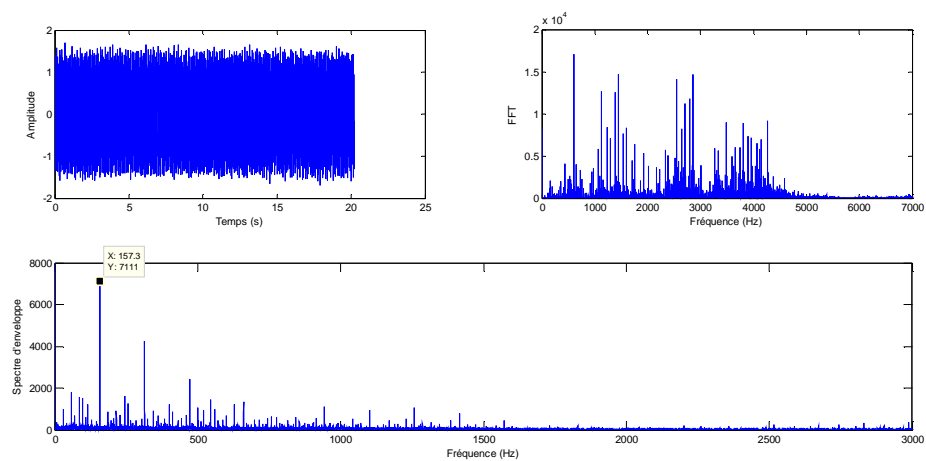


Figure 3.12. Cas d'un défaut sur la bague intérieure : 2HP, 0.007 inch

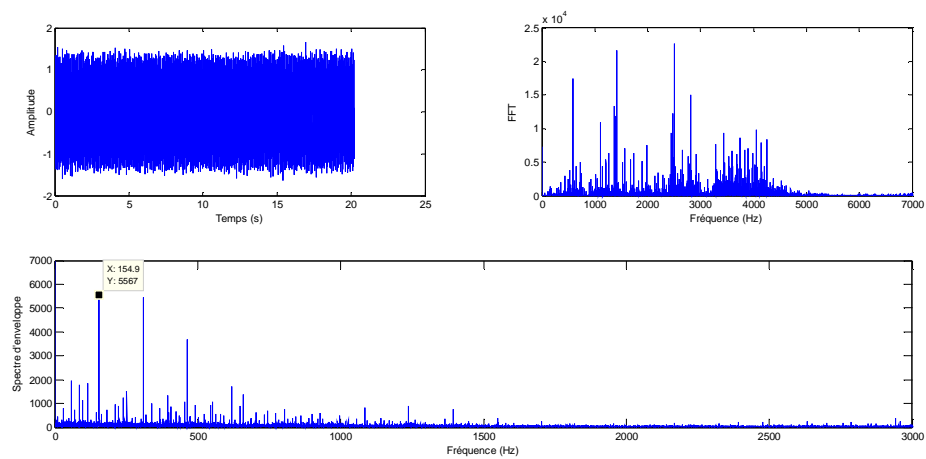


Figure 3.13. Cas d'un défaut sur la bague intérieure : 3HP, 0.007 inch



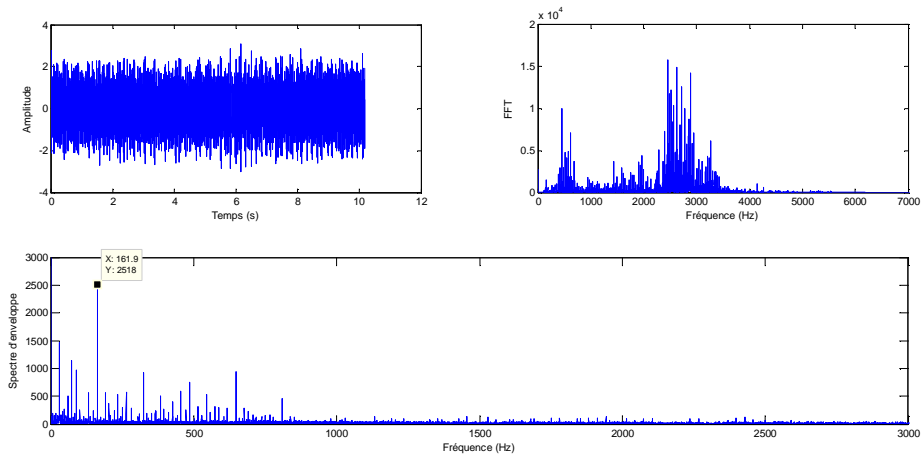


Figure 3.14. Cas d'un défaut sur la bague intérieure : 0HP, 0.021 inch

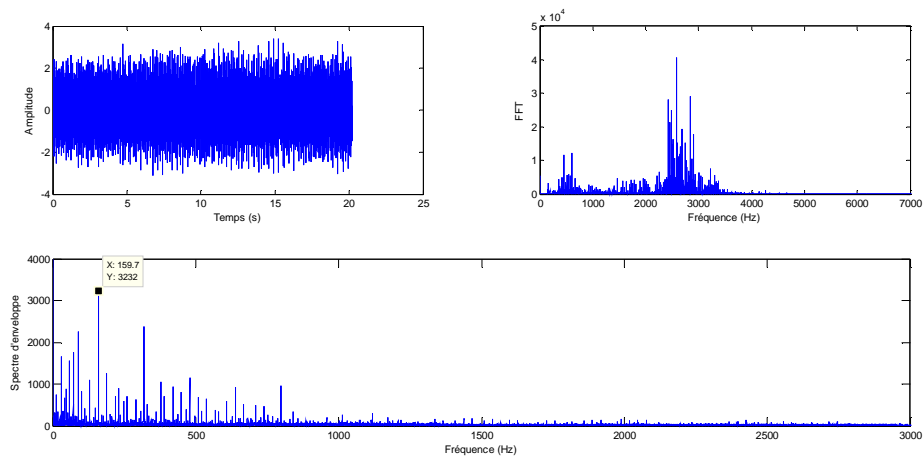


Figure 3.15. Cas d'un défaut sur la bague intérieure : 1HP, 0.021 inch

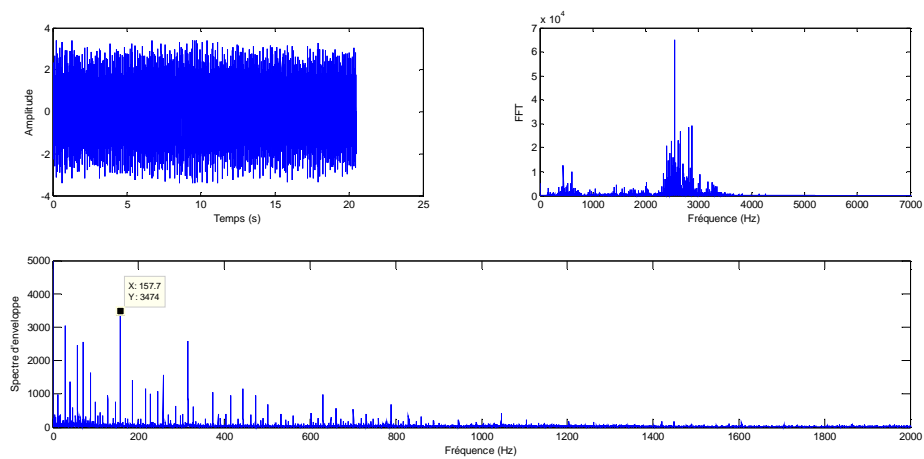


Figure 3.16. Cas d'un défaut sur la bague intérieure : 2HP, 0.021 inch

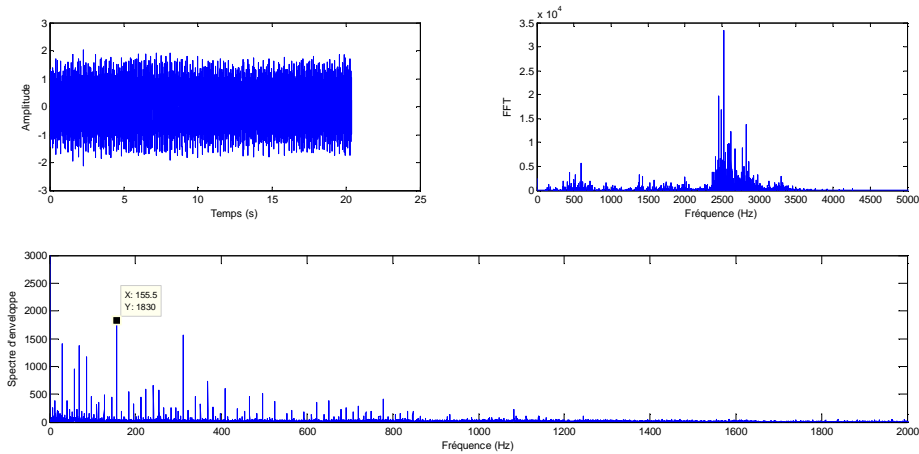


Figure 3.17. Cas d'un défaut sur la bague intérieure : 3HP, 0.021 inch

### 3.3. Cas d'un défaut sur la bille

Dans ce cas on considère un défaut sur la bille avec une gravité de 0.007 inch et une charge de 0 HP figure (3.18). Dans ce cas il est pratiquement impossible de détecter la fréquence caractéristique d'un défaut sur la bille (140 Hz). La même remarque est valable pour les autres charges (figure 3.19 jusqu'à 3.21).

Dans le cas où la gravité du défaut est égale à (0.021 inch), les spectres d'enveloppe montrent difficilement la fréquence d'un défaut sur la bille avec un décalage de quelques Hertz (figures 3.22 à 3.25).

Cette composante reste difficile à détecter sur le spectre d'enveloppe malgré que les signaux correspondant mettent en évidence des impacts périodiques très clairs ce qui implique qu'il est très difficile de détecter un défaut sur la bille.




Figure 3.18. Cas d'un défaut sur la bille : 0HP, 0.007 inch

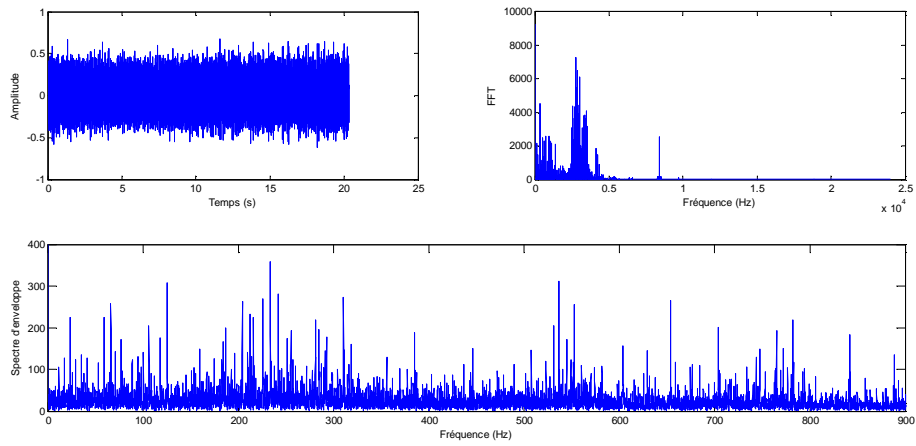


Figure 3.19. Cas d'un défaut sur la bille : 1HP, 0.007 inch




Figure 3.20. Cas d'un défaut sur la bille : 2HP, 0.007 inch

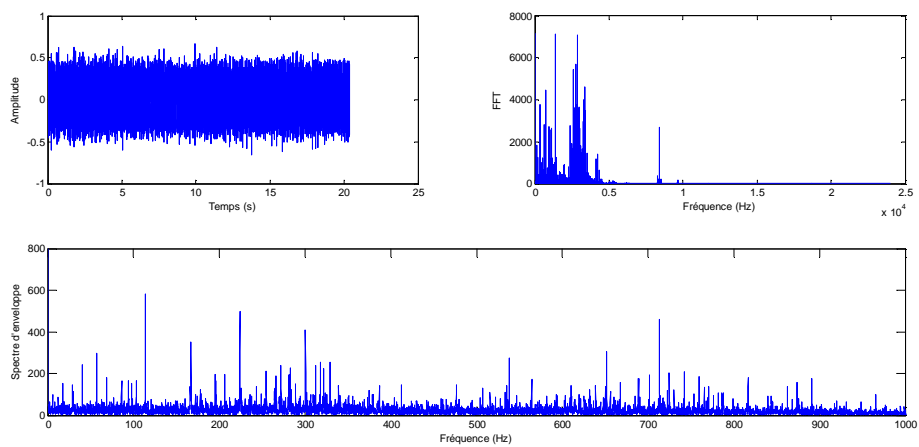


Figure 3.21. Cas d'un défaut sur la bille : 3HP, 0.007 inch

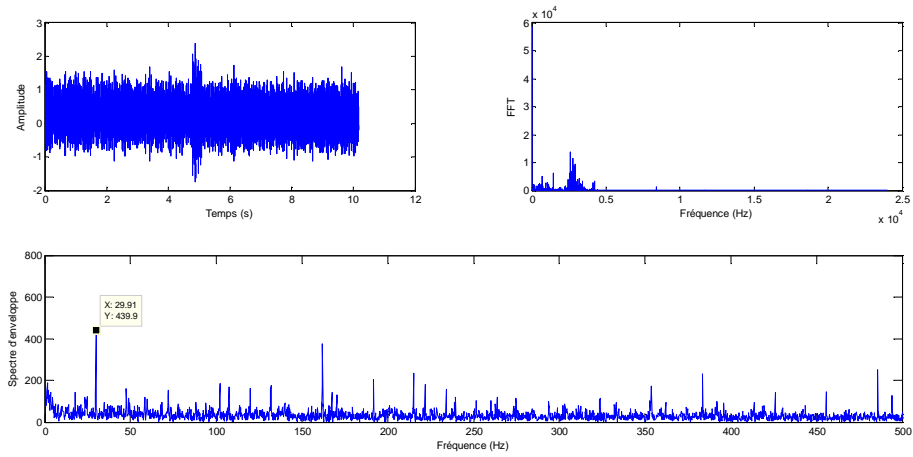


Figure 3.22. Cas d'un défaut sur la bille : 0HP, 0.021 inch

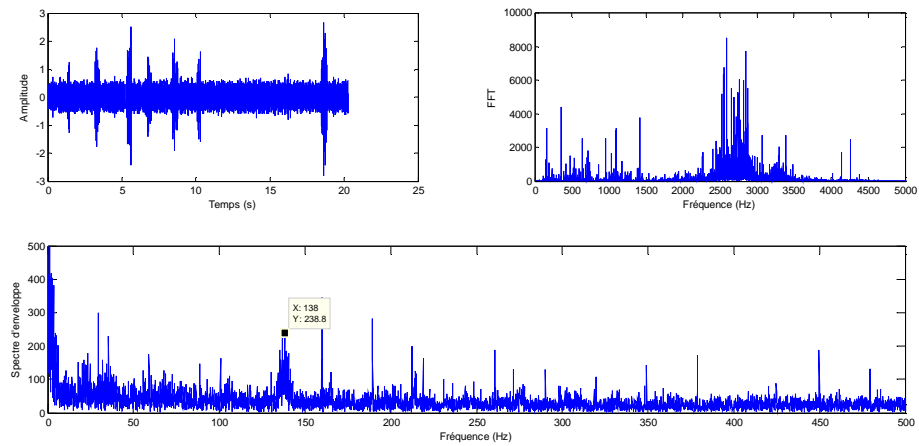


Figure 3.23. Cas d'un défaut sur la bille : 1HP, 0.021 inch





Figure 3.24. Cas d'un défaut sur la bille : 2HP, 0.021 inch



**Figure 3.25. Cas d'un défaut sur la bille : 3HP, 0.021 inch**

## 4. Conclusion du chapitre

Ce chapitre concerne l'application de la méthode d'enveloppe pour la détection des défauts de roulements. Trois types de défauts sont considérés dans différentes configurations : charge et gravité du défaut.

La particularité de notre travail est l'application du filtrage par ondelette comme première étape de la méthode d'enveloppe à la place d'un simple filtrage passe bande conventionnel.

Les résultats montrent la robustesse de cette méthode dans la détection du défaut dans différentes configurations. La fréquence caractéristique du défaut est à chaque fois mise en évidence sur le spectre d'enveloppe ainsi que ses harmoniques.

Notons qu'il était très difficile de détecter le défaut sur la bille sauf dans certains cas rares où la gravité est importante. Ceci concorde avec la littérature où plusieurs auteurs évoquent la difficulté de détecter un défaut de bille à cause du roulement chaotique de la bille. En effet dans ce cas la période de répétition des chocs n'est pas toujours maintenue et donc la fréquence correspondante n'est pas facilement identifiable.

## Chapitre 4

# Automatisation de la détection des défauts de roulements par utilisation de l'algorithme SOM (Self Organizing Maps)

### 1. Introduction

Ce chapitre a pour objectif de concevoir un système automatique pour la détection des défauts de roulements. Ce système est basé sur la méthode (SOM) qui est une méthode non supervisée. A cause de la difficulté rencontrée au chapitre 3 pour la détection du défaut de bille, celui-ci n'est pas pris en considération dans ce chapitre. Trois cas sont considérés : sans défaut, défaut sur la bague extérieure et défaut sur la bague intérieure.

### 2. Apprentissage supervisé ou non supervisé ?

L'apprentissage est une technique, parmi d'autres, de l'intelligence artificielle utilisée essentiellement dans la classification et la régression. Cette approche s'est répandue ayant pour objectif la conception de systèmes intelligents permettant l'étude d'un comportement dans un environnement complexe et/ou changeant. Deux grandes classes d'apprentissage existent, à savoir l'apprentissage supervisé et l'apprentissage non-supervisé.

#### 2.1. Apprentissage supervisé


Dans l'apprentissage supervisé, le réseau est guidé par l'utilisateur durant la phase d'entraînement. Les classes ou les résultats obtenus sont connus d'avance, le rôle de l'utilisateur consiste alors à « enseigner » au réseau les réponses correctes correspondant aux données. La phase d'entraînement se termine si l'algorithme atteint un niveau de performance acceptable. En d'autre terme, en apprentissage supervisé nous avons une connaissance préalable de ce que devraient être les valeurs de sortie.

Dans le domaine de la détection des défauts dans les machines tournantes ce type d'apprentissage a été largement utilisé dans l'automatisation de la fonction diagnostic. A partir d'un certain nombre de données (entrées) pertinentes (le plus souvent des indicateurs scalaires), l'utilisateur fixe d'avance les classes dans lesquelles seront insérer les entrées. Après la phase d'entraînement, l'algorithme exécutera cette tâche en faisant correspondre à chaque classe de sortie ses vecteurs correspondants. Ceci permettra de distinguer, parmi plusieurs signaux mesurés, ceux correspondant par exemple à un défaut sur la bague extérieure d'un roulement, sur la bague intérieure, défaut d'engrenage ou tout simplement le cas sans défaut [4].

Le problème de ce type d'apprentissage c'est qu'il nécessite un grand nombre de données durant la phase d'entraînement. En plus, dans le domaine de la détection des défauts en milieu industriel, il est très difficile, voire impossible, de familiariser tout système intelligent avec tous les types de défauts. Il en résulte que si le système rencontre une entrée qui ne correspond à aucune sortie prédéfinie, il donnera automatiquement un faux diagnostic. Parmi les algorithmes les plus réponsus dans l'apprentissage supervisé nous pouvons citer la classification par les réseaux de neurones (ANN pour Artificial Neural Network) et le SVM (Support Vector Machine) [4-5].

## 2.2. Apprentissage non-supervisé

Contrairement à l'apprentissage supervisé, celui non-supervisé n'a pas de résultats étiquetés. Son objectif est de déduire la structure naturelle présente dans un ensemble de points de données. Donc dans ce type d'apprentissage, le résultat ou le nombre de classes n'est pas connu à priori ce qui rend la tâche plus difficile. L'approche consiste alors à rechercher d'éventuelles similitudes entre les données et de les grouper dans des classes en se basant sur leurs propriétés statistiques, cette méthode s'appelle le groupement ou le clustering en Anglais. La méthode la plus utilisée dans le groupement des données est sans doute la carte auto-adaptative, auto-organisatrice ou topologique, bien que nous préférons la nomenclature de référence en Anglais SOM pour Self Organizing Maps. La figure (4.1) montre la différence entre le groupement (clustering) et la classification [4-5].



**Figure 4.1. Différence entre clustering (apprentissage non-supervisé) et la classification (apprentissage supervisé, le SVM par exemple)**

## 3. L'algorithme SOM : Self Organizing Maps

L'algorithme SOM (Self Organizing Map) est une classe de réseaux de neurones artificiels fondée sur des méthodes d'apprentissage non-supervisées. Cet algorithme est également nommé cartes auto-adaptative en Français ou cartes de Kohonen du nom du statisticien Finlandais ayant développé cette approche en 1982. La méthode est utilisée notamment pour le groupement, la visualisation, et l'exploration dans l'analyse des données. Elle peut servir d'un moyen efficace pour étudier la répartition d'un ensemble de données dans un espace à grande dimension.

Contrairement aux méthodes supervisées, la SOM est une méthode non-supervisée, c'est-à-dire qu'il n'y a pas un objectif prédéfini à l'avance qui peut guider le processus de groupement. A cet effet, la SOM utilise un apprentissage par



compétition où les nœuds de sortie coordonnent entre eux pour permettre l'opportunité d'une distinction claire entre les données [4].

### 3.1. Architecture d'un SOM

Contrairement aux réseaux de neurones conventionnels, l'architecture du SOM ne contient pas une couche intermédiaire ou cachée, la couche d'entrée est directement connectée à celle de sortie. La couche d'entrée contient les attributs (features), en d'autre terme les données ou les variables d'entrée. La couche de sortie contient quant à elle les groupes sous forme de nœuds.

Les données sont sous forme d'un vecteur à  $m$  dimension  $x = (x_1, x_2, x_3, \dots, x_m)^T$ , la couche de sortie permet une visualisation des données en une dimension moindre que celle de la couche d'entrées. Généralement une présentation en deux dimensions est la plus utilisée. Les nœuds de sortie peuvent avoir plusieurs formes typologiques, les plus utilisées d'entre elles sont la forme rectangulaire et la forme hexagonale (Fig. 4.2). Donc en d'autre terme, le nombre de nœuds de sortie correspond au nombre de groupes donnés par l'algorithme de SOM [4].




Figure 4.2. Typologies des nœuds de l'algorithme de SOM : à gauche forme rectangulaire, à droite forme hexagonale

### 3.2. Etapes de l'algorithme SOM

#### 3.2.1. Etape 1 : Choisir la typologie du SOM et initialiser les poids

Dans cette étape l'utilisateur choisi la forme des nœuds et la dimension de l'espace de sortie. On définit également un vecteur poids  $w_i(t) = (w_{i1}, w_{i2}, w_{i3}, \dots, w_{im})^T$  choisi d'une manière arbitraire au début et qui serait mis à jour progressivement au fur et à mesure du processus de l'algorithme. Le vecteur poids reflète en réalité la connexion entre les nœuds d'entrée et de sortie. Les paramètres d'apprentissage seront également choisis dans cette phase à savoir la fonction de voisinage  $h_0$ , le taux d'apprentissage  $\alpha_0$  et le nombre maximal d'itérations  $T$ .

#### 3.2.2. Etape 2 : Phase d'assignement

Dans cette étape, un vecteur d'entrée  $x(t)$  est sélectionné arbitrairement (l'index  $t$  est égal à 1 dans la phase initiale). Définir ensuite la similarité en calculant

la distance Euclidienne entre le vecteur sélectionné et tous les poids assignés à cette étape par la formule (4.1) :

$$d_i(t) = \|x(t) - w_i(t)\| = \sqrt{\sum_{j=1}^m (x(t)_j - w(t)_{ij})^2} \quad (4.1)$$

A la fin du processus de calcul, le nœud ayant la distance Euclidienne la plus minimale dans l'itération  $t$  est déclaré nœud gagnant et sera noté  $c(t)$ . C'est le nœud qui se rapproche le plus du vecteur  $x(t)$  [4-5].

$$c(t) = \operatorname{argmin}\{\|x(t) - w_i(t)\|\} \quad (4.2)$$

### **3.2.3. Etape 3 : Mise à jour du vecteur poids**

Comme nous l'avons souligné au début, le vecteur poids est sélectionné d'une manière arbitraire, après la désignation du nœud gagnant une mise à jour du vecteur poids  $w_i(t)$  du nœud gagnant et de ses voisins à l'itération  $t$  est ainsi faite pour être mieux représentatifs des attributs d'entrée. En utilisant la formule (4.3) le nouveau vecteur poids  $w_i(t+1)$  correspondant à l'itération  $(t+1)$  est calculé par :

$$w_i(t+1) = w_i(t) + \alpha(t)h_{ci}(t)\|x(t) - w_i(t)\| \quad (4.3)$$

### **3.2.4. Etape 4 : Continuation**

Mettre  $t=t+1$ , ajuster les paramètres de voisinage et d'apprentissage et retourner à l'étape 2 et continuer les calculs jusqu'à ce que le nombre maximal d'itération  $T$  soit atteint.

## **4. Application de l'approche SOM pour automatiser la détection des défauts de roulements**

L'objectif de cette partie est d'utiliser l'algorithme SOM pour l'automatisation de la détection des défauts de roulements. Trois cas ont été pris en considération : cas d'un défaut sur la bague extérieure, cas d'un défaut sur la bague intérieure et le cas sans défaut. Quatre signaux ont été pris pour chacun des cas, ce qui donne un ensemble de douze (12) signaux. Donc l'objectif est de concevoir un système automatique capable non seulement de détecter la présence d'un défaut de roulement, mais de différencier son type. Comme nous avons à grouper trois classes, le nombre de neurones de sortie est pris égal à 4 (2x2).

### **4.1. Désignation des indicateurs retenus comme attributs pour l'algorithme SOM**

Les indicateurs retenus comme attributs pour le groupement sont répartis en trois types, ceci pour bien étudier l'aptitude de l'approche SOM à différencier entre les types de défauts :

1. Indicateurs de forme : Kurtosis, facteur de crête et skewness ;
2. Indicateur sensible à l'énergie : RMS ;

3. Nouveau indicateur proposé.

**4.1.1. Indicateurs classiques**

Le tableau (4.1) résume tous les résultats du calcul des quatre indicateurs (kurtosis, facteur de crête, RMS et facteur de crête) pour les signaux considérés. Nous laisserons la présentation et la discussion du nouvel indicateur proposé pour la section qui suit dans ce chapitre.

		RMS	Facteur de crête	Kurtosis	Skewness
Sans Défaut	S1	0,0738	4.2196	2.7642	-0.0354
	S2	0,0664	5.2129	2.9306	-0.173
	S3	0,0643	5.5847	2.9251	-0.1671
	S4	0,0659	4.6515	2.9572	-0.1275
Défaut bague extérieure	S5	0,2762	8.6838	12.3941	0.0357
	S6	0,5509	9.6344	22.9189	0.1535
	S7	0,475	10.9498	22.5694	0.1690
	S8	0,4067	10.5497	21.0958	0.1528
Défaut bague intérieure	S9	0,2787	5.9263	7.3687	-0.091
	S10	0,2807	6.044	7.5105	-0.0924
	S11	0,2378	11.2226	20.1512	0.1253
	S12	0,2685	9.9203	14.9401	0.2246

**Tableau 4.1. Valeurs des indicateurs scalaires classiques retenus comme attributs pour les douze signaux considérés**

**4.1.2. Indicateur proposé**

En parallèle avec les quatre indicateurs classiques mentionnés auparavant nous proposons un nouvel indicateur calculé à partir du spectre d'enveloppe. Le principe de calcul de cet indicateur est le suivant :

1. On calcule un spectre d'enveloppe conformément à la méthodologie décrite au chapitre 3 ;
2. On calcule l'amplitude vibratoire correspondant à la composante fréquentielle du défaut sur la bague extérieure et sur la bague intérieure, que nous allons noter respectivement  $A_{OBPFO}$  et  $A_{OBPFI}$  ;
3. On calcule le rapport  $\frac{A_{OBPFO}}{A_{OBPFI}}$  ;
4. On calcule enfin le nouvel indicateur égal au logarithme du rapport précédent soit :  $\log\left(\frac{A_{OBPFO}}{A_{OBPFI}}\right)$

La figure (4.3) explique le principe de calcul du nouvel indicateur sur un spectre d'enveloppe. Pour le cas d'un défaut sur la bague extérieure, l'amplitude vibratoire du défaut sur la bague extérieure sera plus importante, donc le rapport  $\frac{A_{OBPFO}}{A_{OBPFI}}$  sera supérieur à un et donc le nouvel indicateur  $\log\left(\frac{A_{OBPFO}}{A_{OBPFI}}\right)$  sera largement positif. En

**CHAPITRE 4 : Automatisation de la détection des défauts de roulements par utilisation de l'algorithme SOM (Self Organizing Maps)**

revanche pour le cas d'un défaut sur la bague intérieure le rapport  $\frac{A_{OBPF0}}{A_{OBPFI}}$  sera inférieur à un et donc le nouvel indicateur  $\log\left(\frac{A_{OBPF0}}{A_{OBPFI}}\right)$  sera largement négatif. Enfin pour le cas sans défaut, ce rapport sera presque égal à un et par suite le nouvel indicateur  $\log\left(\frac{A_{OBPF0}}{A_{OBPFI}}\right)$  aura une valeur proche du zéro.

Le tableau (4.2) montre les valeurs de ce nouvel indicateur pour les douze signaux.

		$\log\left(\frac{A_{BPFO}}{A_{BPFI}}\right)$
<b>Sans Défaut</b>	S1	0.22
	S2	0.13
	S3	0.12
	S4	0.17
<b>Défaut bague extérieur</b>	S5	5.3402
	S6	4.5433
	S7	4.6498
	S8	4.6426
<b>Défaut bague intérieur</b>	S9	-4.6207
	S10	-3.9421
	S11	-2.5328
	S12	-3.5015

**Tableau 4.2. Valeurs du nouvel indicateur pour les douze signaux**

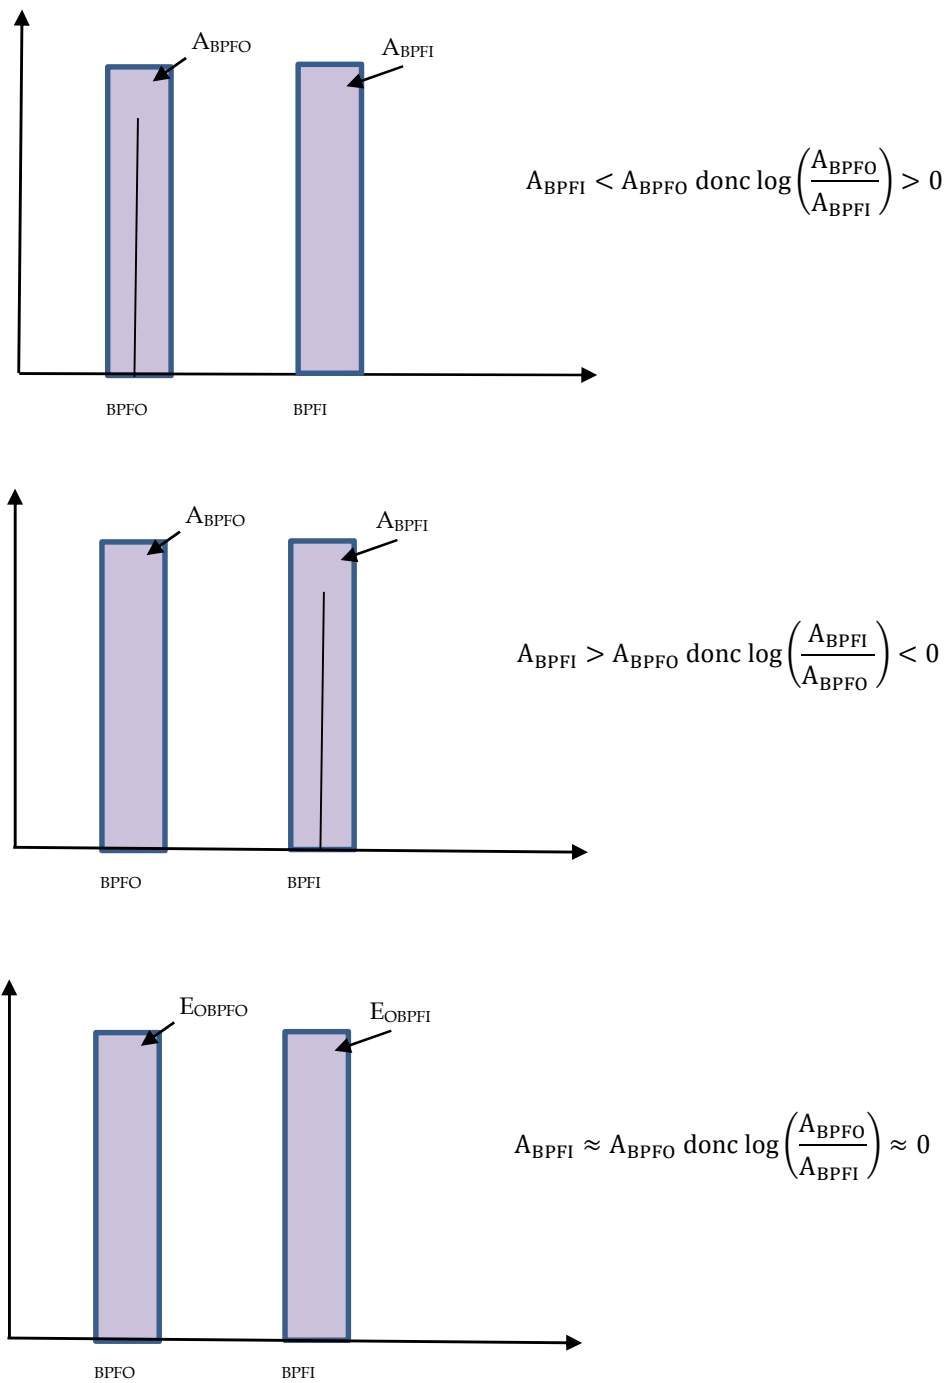


Figure 4.3. Variation du nouvel indicateur proposé en fonction du type du défaut, de haut en bas : défaut sur la bague extérieure, défaut sur la bague intérieure, sans défaut

## 5. Application sur les douze signaux

### 5.1. Groupement sur la base du RMS

Dans ce cas on utilise les valeurs du RMS des douze signaux pour alimenter le système. La figure (4.4) montre les résultats obtenus, on constate que dans ce cas le système n'a pu grouper que les quatre signaux correspondant au cas sans défaut. Les huit autres signaux (4 du défaut sur la bague extérieure et 4 du défaut sur la bague intérieure) ont été éparpillés donc une confusion dans la distinction entre ces deux types de défauts.




Figure 4.4. Groupement sur la base du RMS

### 5.2. Groupement sur la base du facteur de crête

Dans ce cas on utilise le facteur de crête comme attribut. Notons que le facteur de crête est un bon indicateur de la présence d'un défaut de roulement. Malheureusement la figure (4.5) montre que le système n'a pu regrouper que les signaux correspond au cas sans défaut, les autre signaux sont confondus. En effet en se basant sur le facteur de crête le système a pu grouper les signaux dont la valeur est inférieure à 6. Les autres signaux correspondent aux défauts avec un  $fc > 6$  et donc le système les a complètement éparpillé et n'a pu distinguer entre défaut sur la bague extérieure et la bague intérieure.




Figure 4.5. Groupement sur la base du FC

### 5.3. Groupement sur la base du kurtosis

Le même résultat d'auparavant est obtenu en se basant sur le kurtosis considéré comme l'indicateur le plus sensible aux chocs. La figure (4.6) montre que le système n'a pu regrouper que les signaux correspondant au cas sans défaut, les autres signaux des défauts ( $k > 3$ ) sont confondus.




Figure 4.6. Groupement sur la base du Kurtosis

### 5.4. Groupement sur la base du Skewness

Le skewness est un indicateur relativement récent. Malgré cela il n'a pas pu grouper les douze signaux.




Figure 4.7. Groupement sur la base du Skewness

### 5.5. Groupement sur la base du RMS+ kurtosis

Dans ce cas on combine deux indicateurs comme attributs ; le RMS et le Kurtosis, le résultat n'est encore pas satisfaisant du fait que mis à part les quatre signaux du cas sans défaut, les autres sont complètement confondus.




Figure 4.8. Groupement sur la base du RMS+kurtosis

### 5.6. Groupement sur la base du Kurtosis + Facteur de crête

Dans ce cas nous avons voulu tester les deux indicateurs les plus sensibles au choc (kurtosis + facteur de crête), malgré cela le système n'a encore une fois pas pu permettre un groupement efficace.






Figure 4.9. Groupement sur la base du Kurtosis + fc

### 5.7. Groupement sur la base du RMS+Kurtosis + Facteur de crête+ Skewness

Le résultat n'est pas meilleur en considérant les quatre attributs classiques (RMS+ Kurtosis + Skewness +facteur de crête). La figure (4.10) montre que seules les quatre signaux du cas sans défaut sont correctement groupés.




Figure 4.10. Groupement sur la base du RMS+ Kurtosis + Skewness +fc

### 5.8. Groupement sur la base de l'indicateur proposé

Dans ce cas on utilise les douze valeurs de l'indicateur proposé  $\log\left(\frac{A_{BPFO}}{A_{BPFI}}\right)$  comme attributs. Dans ce cas le système a pu distinguer efficacement les trois groupes considérés. Du fait que les valeurs de cet indicateur sont très différentes entre les trois cas (sans défaut, défaut sur la bague extérieure, défaut sur la bague intérieure), le système a facilement pu grouper les douze signaux (Fig. 4.11).




Figure 4.11. Groupement sur la base de l'Indicateur proposé

### 5.9. Groupement sur la base des 5 indicateurs

On ajoutant les quatre autres indicateurs (RMS+ Kurtosis + Skewness +facteur de crête) à l'indicateur proposé, le résultat n'est plus satisfaisant comme dans les cas précédent. Dans ce qui suit nous allons donc chercher quels indicateurs marchent bien avec l'indicateur proposé et quels sont ceux qui rendent le résultat médiocre.




Figure 4.12. Groupement sur la base des 5 indicateurs

### 5.10. Groupement sur la base de l'Indicateur + Kurtosis + facteur de crête

En combinant l'indicateur proposé au kurtosis et au facteur de crête le résultat n'est encore pas satisfaisant comme le montre la figure (4.13).




Fig. 4.13. Groupement sur la base de l'indicateur Kurtosis +fc

### 5.11. Groupement sur la base de l'Indicateur + RMS

En combinant l'indicateur proposé avec le RMS le système a efficacement groupé les douze signaux en 3 groupes.




Figure 4.14. Groupement sur la base de l'indicateur + RMS


### 5.12. Groupement sur la base de l'Indicateur + RMS+Skewness

En combinant l'indicateur proposé au RMS et au skewness, le résultat est très satisfaisant. Le système a efficacement groupé les douze signaux aux trois groupes correspondant aux trois types de défauts considérés.

En effet, notre analyse la suivante : comme les indicateurs de forme (kurtosis et facteur de crête) permettent de détecter la présence du défaut mais pas son type, ils classent tous les signaux des défauts ensemble ou les éparpillent selon leurs valeurs. Leur association avec l'indicateur proposé ne permet pas un groupement efficace. Alors que l'association du RMS et du skewness est très efficace.

## CHAPITRE 4 : Automatisation de la détection des défauts de roulements par utilisation de l'algorithme SOM (Self Organizing Maps)

---



**Figure 4.15. Groupement sur la base de l'indicateur + RMS+ Skewness**

## **6. Conclusion du chapitre**

Ce chapitre avait pour objectif la conception d'un système pour l'automatisation de la détection des défauts de roulements. Nous avons choisi une méthode basée sur l'apprentissage non-supervisé, la SOM (Self Organizing Maps).

Trois cas sont considérés : sans défaut, défaut sur la bague extérieure, défaut sur la bague intérieure. Douze signaux ont été pris pour tester l'efficacité du système conçu (quatre signaux pour chaque cas). L'objectif principal est que ce système puisse grouper ces signaux en trois groupes, chaque quatre signaux du même cas ensemble.

Le problème était de choisir les attributs pertinents pour l'alimentation de ce système. Pour ce faire quatre indicateurs connus dans la littérature ont été pris (RMS, kurtosis, facteur de crête, skewness). Un indicateur basé sur le rapport des amplitudes de la fréquence d'un défaut sur la bague extérieure et intérieure a été proposé.

Les résultats montrent que l'utilisation des indicateurs classiques seuls ou combinés ne permet pas un groupement efficace des douze signaux. Alors que l'utilisation seule de l'indicateur proposé est très efficace. Comme il est déconseillé d'utiliser un seul attribut pour le groupement nous avons combiné cet indicateur avec les quatre autres.

Les résultats montrent que l'association de cet indicateur avec les indicateurs de forme qui ont un seuil de détection (kurtosis et facteur de crête) ne permet pas un groupement efficace, alors que son association avec le RMS et le skewness a été très satisfaisante.

## Conclusion générale

La conception d'un système expert basé sur l'approche SOM (Self-Organizing Maps) pour l'automatisation du diagnostic vibratoire des défauts de roulements présente plusieurs avantages significatifs. Ce mémoire a exploré en détail l'application de l'approche SOM pour résoudre le problème complexe du diagnostic des défauts de roulements.

Premièrement, l'approche SOM offre une méthode efficace pour la classification et la reconnaissance de motifs dans les données vibratoires. Elle permet de représenter de manière organisée et structurée les caractéristiques des vibrations des roulements, facilitant ainsi l'identification des défauts et la prise de décision.

Deuxièmement, le système expert basé sur l'approche SOM présente une capacité d'apprentissage autonome et une adaptabilité aux nouvelles données. Il est capable d'auto-organiser et de s'ajuster en fonction des différents types de défauts de roulements, ce qui améliore considérablement la précision et la fiabilité du diagnostic.

Troisièmement, l'automatisation du processus de diagnostic vibratoire grâce à un système expert basé sur l'approche SOM permet de réduire les coûts de maintenance et d'augmenter la disponibilité des machines. En détectant précocement les défauts de roulements, il est possible de planifier les opérations de maintenance de manière proactive, évitant ainsi les arrêts imprévus et les dommages plus importants aux équipements.

Cependant, il convient également de noter que la conception et la mise en œuvre d'un tel système expert exigent une connaissance approfondie des techniques de traitement des signaux vibratoires, ainsi qu'une expertise dans la manipulation des réseaux de neurones et des algorithmes d'apprentissage automatique. Des efforts supplémentaires doivent également être consacrés à la collecte de données vibratoires représentatives et à la construction d'une base de connaissances solide pour alimenter le système expert.

Enfin, l'approche SOM offre une approche prometteuse pour l'automatisation du diagnostic vibratoire des défauts de roulements. Son utilisation dans un système expert permet d'améliorer la précision et l'efficacité du diagnostic, ce qui se traduit par une meilleure maintenance prédictive et une réduction des coûts opérationnels. Le développement continu de cette approche, combiné à d'autres techniques avancées, ouvre de nouvelles perspectives pour l'industrie en matière de maintenance préventive et d'optimisation des performances des machines.

## Résumé

Le présent mémoire porte sur la conception d'un système expert basé sur l'approche SOM (Self-Organizing Maps) pour l'automatisation du diagnostic vibratoire des défauts de roulements. Les roulements défectueux peuvent entraîner des problèmes majeurs dans les machines industrielles, ce qui nécessite une détection précoce et une maintenance proactive. L'approche SOM est une technique d'apprentissage non supervisé qui permet la classification et la reconnaissance de motifs dans les données vibratoires.

Le mémoire commence par une revue de la littérature sur les défauts de roulements, les techniques de diagnostic vibratoire existantes et les applications de l'approche SOM dans le domaine. Ensuite une étude paramétrique portant sur la détection des défauts de roulements par l'approche statistique a été entamée. Une approche fréquentielle basée sur la méthode d'enveloppe a ensuite été appliquée. Enfin, une méthodologie détaillée est présentée, comprenant la collecte de données vibratoires, l'étude des attributs, le prétraitement des signaux, la création d'une base de données et la formation du réseau SOM.

Une évaluation approfondie du système expert est réalisée en utilisant des données réelles provenant d'une base de données de renommée internationale. Les résultats obtenus sont comparés à ceux des méthodes traditionnelles de diagnostic vibratoire, démontrant ainsi l'efficacité et la précision du système proposé.

**Mots-clés :** Analyse vibratoire, détection des défauts de roulements, analyse statistique, méthode d'enveloppe, automatisation, apprentissage supervisé et non-supervisé, approche SOM

## Abstract

This thesis deals with the design of an expert system based on the SOM (Self-Organizing Maps) approach for the automation of the vibration diagnosis of bearing defects. Defective bearings can lead to major problems in industrial machinery, which requires early detection and proactive maintenance. The SOM approach is an unsupervised learning technique that enables the classification and recognition of patterns in vibrational data.

The thesis begins with a review of the literature on bearing faults, existing vibration diagnostic techniques and applications of the SOM approach in the field. Then a parametric study on the detection of bearing defects by the statistical approach was started. A frequency approach based on the envelope method was then applied. Finally, a detailed methodology is presented, including vibration data collection, attribute study, signal preprocessing, database creation and SOM network training.

An in-depth evaluation of the expert system is carried out using real data from an internationally renowned database. The results obtained are compared with those of traditional methods of vibration diagnosis, thus demonstrating the efficiency and accuracy of the proposed system.

**Keywords:** Vibration analysis, bearing fault detection, statistical analysis, envelope method, automation, supervised and unsupervised learning, SOM approach



## ملخص

تتناول هذه الرسالة تصميم نظام خبير يعتمد على نهج SOM (خرائط التنظيم الذاتي) لأتمتة تشخيص اهتزاز عيوب المحامل. يمكن أن تؤدي المحامل المعيبة إلى مشاكل كبيرة في الآلات الصناعية ، والتي تتطلب الكشف المبكر والصيانة الاستباقية. نهج SOM هو أسلوب تعليمي غير خاضع للإشراف يمكن من تصنيف الأنماط في البيانات الاهتزازية والتعرف عليها.

تبدأ الأطروحة بمراجعة الأدبيات المتعلقة بأعطال المحامل، وتقنيات تشخيص الاهتزاز الحالية وتطبيقات نهج SOM في هذا المجال. ثم بدأت الدراسة البارامترية للكشف عن عيوب الحمل بالمنهج الإحصائي. ثم تم تطبيق نهج التردد على أساس طريقة الغلاف. أخيرًا ، يتم تقديم منهجية مفصلة ، بما في ذلك جمع بيانات الاهتزاز ، ودراسة السمات ، والمعالجة المسبقة للإشارة ، وإنشاء قاعدة بيانات ، وتدريب شبكة SOM. يتم إجراء تقييم متعمق لنظام الخبراء باستخدام بيانات حقيقية من قاعدة بيانات مشهورة عالميًا. تمت مقارنة النتائج التي تم الحصول عليها مع تلك الخاصة بالطرق التقليدية لتشخيص الاهتزاز ، مما يدل على كفاءة ودقة النظام المقترح.

**الكلمات الرئيسية:** تحليل الاهتزاز ، كشف خطأ المحمل ، التحليل الإحصائي ، طريقة الغلاف ، الأتمتة ، التعلم الخاضع للإشراف وغير الخاضع للإشراف ، نهج SOM

## Références bibliographiques

- [1] Site internet <http://openai.com/blog/chatgpt>
- [2] T. BAALI, Application de L'ensemble de décomposition en mode empirique (EEMD) pour la détection des défauts de roulements en régime variable. Mémoire de Master, Université de Guelma 2017.
- [3] Y. DEBBAH, Cours de mécanique de vibration, Université des Frères Mentouri Constantine.
- [4] L. CHAABI, Conception d'un système expert pour le diagnostic des roulements dans les machines tournantes fonctionnant en régime variable. Thèse de Doctorat, Université de Guelma 2021.
- [5] U. Asan and C. Ecran, An introduction to self-organizing maps. Computational Intelligence Systems in Industrial Engineering, Atlantic Press Book, July 19, 2012.
- [6] M.L. Fadda and A. Moussaoui, Hybrid SOM-PCA method for modeling bearing faults detection and diagnosis. Journal of the Brazilian Society of Mechanical Sciences and Engineering (2018) 40:268.
- [7] S. Allia, R. Nasri, I. Meddour and R. Younes, Comparison between sound perception and self-organizing maps in the monitoring of the bearing degradation. International Journal of Advanced Manufacturing Technology (2020) 110(7/8):1-11.
- [8] V. Vakharia, V.K. Gupta and P.K. Kandar, Ball bearing fault diagnosis using supervised and unsupervised machine learning methods. International journal of acoustics and vibration (2015) 20(4):244-250.