

الجمهورية الجزائرية الديمقراطية الشعبية  
وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR- ANNABA UNIVERSITY  
UNIVERSITE BADJI MOKHTAR - ANNABA



جامعة باجي مختار- عنابة

Année: 2020/ 2021

Faculté: Sciences de l'ingéniorat  
Département: Electronique

## THÈSE

Présentée en vue de l'obtention du diplôme de Doctorat en science

### Intitulée

**Surveillance de l'état de fonctionnement du groupe  
turbogénérateur d'une centrale électrique**

Option : Electronique

Par : KHELLIL Jalel

Soutenue le : 14 Juillet 2021

Devant le jury

<b>PRESIDENT :</b>	<b>GUERCI Nouredine</b>	<b>Pr. U. ANNABA</b>
<b>RAPPORTEUR :</b>	<b>RAMDANI Messaoud</b>	<b>Pr. U. ANNABA</b>
<b>EXAMINATEURS :</b>	<b>CHENIKHER Salah</b>	<b>Pr. U. TEBESSA</b>
	<b>MEHENNAOUI Lamine</b>	<b>MCA U. SKIKDA</b>

**Résumé** Le secteur énergétique joue un rôle stratégique dans le développement des pays et le confort des populations à travers le monde entier. Parmi les axes principaux de ce secteur, l'électricité a investi de nombreux domaines comme l'industrie, les transports, l'éclairage domestique et public, etc. L'expansion rapide de ce secteur dans un monde concurrentiel, requiert de plus en plus une stratégie de maintenance fiable et efficace des machines électriques tournantes permettant d'augmenter la disponibilité des machines, de réduire le coût de production, diminuer le temps de réparation et éviter les grands endommagements. La surveillance et le diagnostic des défauts pouvant altérer le bon fonctionnement de ces machines, s'appuie essentiellement sur la surveillance de symptômes liés à différentes conditions de dégradation. Ces symptômes peuvent être tirés et extraits de diverses sources d'information, parmi lesquelles, l'analyse vibratoire occupe une place prépondérante. Cette thèse a pour objectif de combiner l'analyse vibratoire avec la méthode de reconnaissance des formes afin d'améliorer la détection précoce des différents défauts des machines tournantes d'une centrale électrique, d'une part, et de prévenir au mieux la dégradation du système surveillé d'autre part. Pour cela nous avons développé un système de diagnostic basé sur la reconnaissance des formes, et où l'analyse des signaux vibratoires est effectuée à travers une transformation d'ondelette discrète optimisée. Basé sur la représentation polyphase du banc des filtres d'ondelettes. Cette méthode permet de générer les coefficients des filtres à travers des paramètres angulaires. Enfin, l'algorithme d'optimisation par essaim particulaires (Partical Swarm Optimisation : PSO), a été utilisé pour la recherche des paramètres angulaires optimaux à un problème spécifique.

**Mots-clés :** Machines tournantes, diagnostic, intelligence artificielle, vibration, représentation polyphase, optimisation.

**Abstract** The energy sector plays a strategic role in the development of countries and the comfort of populations throughout the world. Amongst the main axes of this sector, electricity has invested in many areas such as industry, transport, domestic and public lighting, etc. The rapid expansion of this sector in a competitive world increasingly requires a reliable and efficient maintenance strategy for rotating electrical machines to increase machine availability, reduce production cost, decrease repair time and avoid great damage. The monitoring and diagnosis of faults that may affect the proper functioning of these machines is based primarily on monitoring symptoms related to various degradation conditions. These symptoms can be drawn and extracted from various sources of information, among which, vibration analysis occupies a prominent place. This thesis aims to combine vibration analysis with the pattern recognition method in order to improve the early detection of the various faults of the rotating machines of a power plant, on the one hand, and to prevent the degradation of the monitored system on the other hand. For this we have developed a diagnostic system based on pattern recognition, where the analysis of vibrational signals is performed through an optimized discrete wavelet transformation. Based on the polyphase representation of the wavelet filter bank, this method allows generating the coefficients of the filters through angular parameters. Finally, the Partical Swarm Optimization (PSO) algorithm was used to find the optimum angular parameters for a specific problem.

**Keywords:** Rotating machines, diagnostics, Artificial intelligence, vibration, polyphase representation, Optimization

**ملخص** يلعب قطاع الطاقة دورًا استراتيجيًا في تنمية البلدان وراحة السكان في جميع أنحاء العالم. ومن بين المحاور الرئيسية لهذا القطاع ، استثمرت الكهرباء في العديد من المجالات مثل الصناعة والنقل والإضاءة المنزلية والعامة ، إلخ. يتطلب التوسع السريع لهذا القطاع في عالم تنافسي بشكل متزايد استراتيجية صيانة موثوقة وفعالة للألات الكهربائية الدوارة لزيادة توافر الماكينة وتقليل تكلفة الإنتاج وتقليل وقت الإصلاح وتجنب حدوث أضرار كبيرة تعتمد مراقبة وتشخيص الأخطاء التي قد تؤثر على الأداء السليم لهذه الآلات في المقام الأول على مراقبة الأعراض المتعلقة بظروف التدهور المختلفة. يمكن استخلاص هذه الأعراض واستخراجها من مصادر مختلفة للمعلومات، من بينها تحليل الاهتزاز الذي يحتل مكانة بارزة. تهدف هذه الرسالة إلى الجمع بين تحليل الاهتزاز وطريقة التعرف على الأنماط من أجل تحسين الكشف المبكر عن الأعطال المختلفة للألات الدوارة لمحطة توليد الكهرباء من جهة ومنع تدهور النظام المرصود من جهة أخرى. لهذا قمنا بتطوير نظام تشخيص يعتمد على التعرف على الأنماط ، وحيث يتم إجراء تحليل الإشارات الاهتزازية من خلال تحويل موجي منفصل محسن. بناءً على التمثيل متعدد الأطوار لبنك مرشح الموجات. تتيح هذه الطريقة إمكانية إنشاء معاملات المرشحات من خلال المعلمات الزاوية. أخيرًا تم استخدام خوارزمية تحسين حشد الجسيمات (PSO) للعثور على المعلمات الزاوية المثلى لمشكلة معينة.

**الكلمات المفتاحية:** الآلات الدوارة ، التشخيص ، الذكاء الاصطناعي ، الاهتزاز ، التمثيل متعدد الأطوار ، التحسين.

# Dédicaces

*Je dédie ce travail :*

- + A la mémoire de mon très cher père, qu'Allah le tout puissant l'accepte dans son vaste paradis,*
- + A ma très chère mère qui n'a pas cessé de m'encourager et de prier pour moi.*
- + A ma très chère femme pour son dévouement inconditionnel,*
- + A mes chers enfants Ibrahim, Hadjer, et Nour el Imene,*
- + A mes frères et sœurs,*
- + A toute ma famille,*

*A tous ceux que j'aime.*

# Remerciements

Je remercie tout d'abord le Bon Dieu pour m'avoir donné la volonté et le courage pour accomplir ce travail.

Je tiens à exprimer mes sincères remerciements et ma profonde reconnaissance à mon Directeur de thèse Monsieur Messaoud Ramdani, Professeur à l'université Badji Mokhtar Annaba, pour la confiance dont il m'a gratifiée, de m'avoir encadré et soutenu tout au long des années de travail, ainsi que pour ses valeureux conseils et orientations. Il a été patient, compréhensif envers tous les obstacles et difficultés rencontrés durant tout ce parcours de mon doctorat.

Je tiens également à remercier chaleureusement mon frère, Monsieur Khaled Khelil Professeur à l'université Cherif Messaadia de Souk Ahras pour le temps et la confiance qu'il m'a accordés au long de ces années et d'avoir cru en mes capacités. Je veux vivement le remercier de m'avoir apporté tout son soutien, son expérience et ses compétences sans lesquelles ce travail n'aurait pas pu aboutir.

Je voudrais adresser mes sincères remerciements à Monsieur Noureddine Guerci, Professeur à l'université Badji Mokhtar Annaba, pour l'intérêt qu'il a accordé à mon travail en acceptant de présider l'honorable jury de cette thèse.

Je tiens à remercier vivement Monsieur Salah Chenikher, Professeur à l'Université Larbi Tebessi de Tébessa, et Monsieur Lamine Mehennaoui Maître de conférences (A) à l'Université 20 Aout 1955 de Skikda, de m'avoir fait l'honneur d'accepter d'être les Examineurs de cette thèse.

Je suis profondément reconnaissant à tous mes collègues, membres du Centre des Recherches et des Technologies Industrielles d'Annaba (CRTI), et plus particulièrement Mr Nadir Boutasseta, et Mr Brahim Oudjani pour leur soutien, leur aide, et leurs encouragements.

Mes sincères remerciements s'adressent à tout l'encadrement du Département d'Electronique de l'université d'Annaba de m'avoir accepté parmi eux, et pour l'aide que chacun d'eux a pu m'apporter.

Aussi, je tiens à exprimer mes vifs remerciements à mes collègues de travail au sein de la Société Algérienne de Production d'Electricité (SPE : Filiale Sonelgaz) qui m'ont aidé de manière directe ou indirecte à l'aboutissement de cette thèse.

Ma profonde gratitude et mes sincères remerciements s'adressent finalement à toute ma famille pour sa patience et son encouragement infaillible durant toutes les années de mes études.

# Table des Matières

Résumé.....	I
Abstract.....	I
ملخص.....	I
Dédicaces.....	II
Remerciements.....	III
Table des Matières.....	IV
Liste des Figures.....	VII
Liste des Tableaux.....	IX
Notations & Abréviations.....	X
Introduction Générale .....	01
Chapitre I : MAINTENANCE DES MACHINES TOURNANTES ET DES STRUCTURES	
<b>1.1 Introduction.....</b>	<b>05</b>
<b>1.2 Description d'une centrale de production d'électricité.....</b>	<b>05</b>
1.2.1 Historique .....	05
1.2.2 Fonctionnement général d'une centrale électrique.....	05
1.2.3 Turbine à gaz.....	06
1.2.4 Domaines d'applications.....	06
1.2.5 Principe de fonctionnement d'une turbine à gaz .....	07
1.2.6 Equipements auxiliaires d'une turbine à gaz.....	08
<b>1.3 Types de maintenance .....</b>	<b>09</b>
1.3.1 La maintenance curative.....	10
1.3.2 La maintenance préventive systématique .....	10
1.3.3 La maintenance préventive conditionnelle.....	10
<b>1.4 Objectifs visés par la maintenance préventive conditionnelle .....</b>	<b>11</b>
<b>1.5 Principaux défauts des machines tournantes.....</b>	<b>11</b>
1.5.1 Défaut de balourd.....	11
1.5.2 Défaut d'alignement .....	11
1.5.3 Défaut de roulement .....	12
<b>1.6 Conclusion.....</b>	<b>15</b>
Chapitre II : SYSTEMES DE DIAGNOSTIC DES MACHINES	
<b>2.1 Introduction.....</b>	<b>16</b>
<b>2.2 Méthodes de diagnostic à base de modèle analytique (Méthodes internes) .....</b>	<b>16</b>
<b>2.3 Méthodes de diagnostic sans modèle (Méthodes externes).....</b>	<b>17</b>
2.3.1 L'analyse vibratoire.....	18

<b>2.4</b>	<b>La surveillance par analyse vibratoire</b>	18
2.4.1	Nature d'une vibration	18
2.4.2	Différents niveaux d'analyse vibratoire	19
2.4.3	Systèmes de mesure des signaux vibratoires	19
<b>2.5</b>	<b>Techniques de traitement de signal appliquées à l'analyse vibratoire</b>	20
2.5.1	Analyse temporelle	21
2.5.2	Analyse spectrale	23
2.5.3	Analyse temps-fréquence	25
2.5.4	Analyse temps-échelle	25
<b>2.6</b>	<b>Banc de filtres d'ondelette et représentation polyphase</b>	32
2.6.1	Notation polyphase	32
<b>2.7</b>	<b>Conclusion</b>	34

### Chapitre III : METHODES DE RECONNAISSANCE DE FORMES DANS LE CADRE DE DIAGNOSTIC DES MACHINES TOURNANTES

<b>3.1</b>	<b>Introduction</b>	36
<b>3.2</b>	<b>Présentation générale</b>	36
<b>3.3</b>	<b>Principales étapes d'un système de reconnaissance des formes</b>	37
3.3.1	Acquisition des données	37
3.3.2	Prétraitement	37
3.3.3	Extraction des caractéristiques	38
3.3.4	Réduction de l'espace de représentation	38
3.3.5	Règles de décision	39
<b>3.4</b>	<b>Différents types de classifieurs</b>	39
3.4.1	Les Réseaux de Neurones Artificiels (Artificial Neural Network: ANN)	39
3.4.2	Machine à vecteurs de support (SVM)	43
3.4.3	Les K plus proches voisins (K Nearest Neighbors : KNN)	50
3.4.4	Méthode des K plus proches voisins Floue (Fuzzy KNN : F-KNN)	54
<b>3.5</b>	<b>Conclusion</b>	57

### Chapitre IV : ALGORITHMES D'OPTIMISATION

<b>4.1</b>	<b>Introduction</b>	58
<b>4.2</b>	<b>Problème d'optimisation</b>	58
<b>4.3</b>	<b>Algorithmes d'optimisation approchée</b>	59
4.3.1	Heuristiques	59
4.3.2	Métaheuristiques	59
<b>4.4</b>	<b>L'algorithme de colonie de fourmis</b>	61
<b>4.5</b>	<b>Les algorithmes évolutionnaires</b>	61
4.5.1	Les algorithmes génétiques	62
<b>4.6</b>	<b>Optimisation par Essais Particulaires</b>	64
4.6.1	Introduction	64
4.6.2	Algorithme PSO	65
4.6.3	Formalisation	66
4.6.4	Topologie de voisinage	68
4.6.5	Le critère d'arrêt	69
<b>4.7</b>	<b>Conclusion</b>	69

## CHAPITRE V : SIMULATIONS ET RESULTATS

<b>5.1</b>	<b>Introduction</b> .....	71
<b>5.2</b>	<b>Première partie expérimentale</b> .....	71
5.2.1	Description succincte de la centrale électrique F'kirina .....	71
5.2.2	Phase d'acquisition des signaux vibratoires .....	72
5.2.3	Phase de traitement et analyse des signaux vibratoires.....	72
5.2.4	Phase d'extraction des caractéristiques .....	75
5.2.5	Phase de classification .....	76
5.2.6	Résultats expérimentaux et commentaires .....	76
5.2.7	Conclusion.....	80
<b>5.3</b>	<b>Deuxième partie expérimentale</b> .....	81
5.3.1	Banc d'essais .....	81
5.3.2	Constitution du banc d'essais .....	81
5.3.3	Constitution de la base de données.....	82
5.3.4	Résultats expérimentaux obtenus et discussions .....	84
5.3.5	Conclusion.....	90
<b>5.4</b>	<b>Troisième partie expérimentale</b> .....	91
5.4.1	Procédure d'optimisation des filtres d'ondelette .....	92
5.4.2	Résultats expérimentaux et discussions .....	94
5.4.3	Conclusion.....	97
	Conclusion Générale .....	98
	Bibliographie .....	102
	Annexe .....	115

# Liste des Figures

## Chapitre I

1.1	Centrale de production d'électricité	06
1.2	Principe de fonctionnement d'une turbine à gaz	07
1.3	Roulements à billes et à rouleaux	12
1.4	Géométrie d'un roulement	14

## Chapitre II

2.1	Principe du diagnostic par modèle	17
2.2	Chaîne de mesure vibratoire	20
2.3	Obtention d'un spectre à partir du signal temporel	24
2.4	Exemples d'ondelettes mères	26
2.5	Décomposition en ondelettes dyadiques	29
2.6	Arbre de décomposition en ondelettes dyadiques au niveau $j = 3$	29
2.7	Découpage en sous bandes fréquentielles d'un signal par la transformée en ondelettes dyadiques au niveau $j = 3$	29
2.8	Arbre de décomposition en paquets d'ondelettes à trois niveaux	31
2.9	Schéma direct et schéma polyphase d'un banc de filtres d'analyse	32

## Chapitre III

3.1	Modèle d'un neurone artificiel	40
3.2	Principe de fonctionnement de la méthode SVM	43
3.3	Différentes frontières possibles d'un SVM	44
3.4	Illustrations de cas linéairement séparable et non-linéairement séparable	44
3.5	Illustration de l'affectation par la règle des KNN	51

## Chapitre IV

4.1	Chemin de fourmis	61
4.2	Étapes d'un Algorithme Génétique simple	64
4.3	Exemples de déplacement en groupe	65
4.4	Stratégie de déplacement d'une particule	66
4.5	Voisinage Anneau	68
4.6	Voisinage rayon	68
4.7	Voisinage étoile	69



## Chapitre V

5.1	Schéma synoptique d'un groupe TG centrale F'kirina	72
5.2	Défaut de balourd	73
5.3	Défaut d'alignement	74
5.4	Défaut de roulement	74
5.5	Taux de classification de l'ondelette Daubechies	77
5.6	Taux de classification de l'ondelette Symlet	78
5.7	Taux de classification de l'ondelette Coiflet	78
5.8	Taux Max de classification	79
5.9	Taux de classification de l'ondelette Daubechies en fonction du niveau de décomposition	80
5.10	Banc d'essais	81
5.11	Différents défauts de roulements	82
5.12	Représentation temporelle des signaux vibratoires des différents états de roulement issus du banc d'essais	83
5.13	Taux Maximum de classification	89
5.14	Taux Moyen de classification	90
5.15	Organigramme d'optimisation des filtres d'ondelette basée sur l'algorithme PSO	93
5.16	Taux de classification en utilisant l'ondelette Daubechies en fonction des niveaux de décomposition pour les quatre classificateurs	95
5.17	Taux de classification de l'ondelette optimisée PSO-DWT en fonction de l'ordre des filtres pour les quatre classificateurs	96
5.18	Etude comparative des taux de classification des défauts de roulement	97

# Liste des Tableaux

## Chapitre I

1.1	Différents types de maintenance	11
-----	---------------------------------	----

## Chapitre V

5.1	Caractéristiques techniques de la centrale turbine à gaz de F'kirina	72
5.2	Total des signaux par classe de défaut	73
5.3	Taux de classification de l'ondelette Daubechies	79
5.4	Taux de classification de l'ondelette Symlet	80
5.5	Taux de classification de l'ondelette Coiflet	80
5.6	Taux Max de classification	81
5.7	Taux de classification de l'ondelette Daubechies en fonction du niveau de décomposition	81
5.8	Caractéristiques techniques des roulements	84
5.9	Différents défauts de roulements	85
5.10	Taux de classification des défauts de roulements avec l'ondelette Daubechies	88
5.11	Taux de classification des défauts de roulements avec l'ondelette Symlet	89
5.12	Taux de classification des défauts de roulements avec l'ondelette Coiflet	91
5.13	Taux Maximum de classification	91
5.14	Taux Moyen de classification	92
5.15	Taux de classification en utilisant l'ondelette Daubechies en fonction des niveaux de décomposition pour les quatre classificateurs	96
5.16	Taux de classification de l'ondelette optimisée PSO-DWT en fonction de l'ordre des filtres pour les quatre classificateurs	97
5.17	Coefficients des filtres d'ondelettes conçues d'ordre 6	98
5.18	Etude comparative des taux de classification des défauts de roulement	99

# Notations & Abréviations

<i>Notation</i>	<i>Abréviation</i>
Ac	Amplitude maximale ou valeur crête
Acc	Amplitude crête à crête
ACO	Optimisation par Colonie de Fourmis (Ant Colony Optimization)
AEs	Algorithmes Evolutionnaires
AFNOR	Association Française de Normalisation
AI	Intelligence Artificielle (Artificial Intelligence)
ANN	Réseaux de Neurones Artificiels (Artificial Neural Network)
Arg.	Argument
CWT	Transformée en ondelettes continue (Continuous Wavelet Transform)
DFT	Transformée de Fourier Discrète (Discret Fourier Transform)
DWT	Transformée en Ondelettes Discrète (Discret Wavelet Transform)
ECG	Electrocardiogramme
EMD	Décomposition en Modes Empiriques (Empirical Mode Decomposition)
EP	Programmation évolutionnaire (Evolutionary Programming)
FC	Facteur de crête
$F_c$	Fréquence centrale
FFT	Transformée de Fourier Rapide (Fast Fourier Transform)
F-KNN	K- Plus Proches Voisins Floue (Fuzzy-K Nearest Neighbors)
FIR	Réponse impulsionnelle finie (Finite Impulse Response)
GA	Algorithme Génétique (Genetic Algorithm)
GP	Programmation Génétique (Genetic Programming)
$H(z)$	Fonction de transfert dans le domaine Z
$H_{poly}(z)$	Matrice polyphase du filtre $h$
IIR	Réponse impulsionnelle infinie (Infinite Impulse Response)
IR	Défaut de bague intérieure du roulement (Inner Race)
KNN	K-Plus Proches Voisins (K Nearest Neighbors)
Ku	Kurtosis
MLP	Perceptron Multi couches (Multi Layer Perceptron)
MSE	Erreur Quadratique Moyenne (Mean Square Error)

NF	Norme Française
OR	Défaut de bague extérieur du roulement (Outer Race)
PDR	Pièces De Rechange
PSO	Optimisation par Essaim Particulaires (Partical Swarm Optimisation)
QMF	Filtres à miroirs quadratiques (Quadrature Mirror Filters)
QP	Programmation quadratique (Quadratic Programming)
RBF	Fonction à base radiale (Radial Basis Function)
RdF	Reconnaissance des Formes
RMS	Amplitude efficace (Root Mean Square)
RUL	Durée de vie résiduelle (Remaining Useful Life)
SK	Skewness : Coefficient de dissymétrie (ou moment statistique d'ordre 3)
STFT	Transformée de Fourier à court terme (Short-Time Fourier Transform)
SVM	Machines à Vecteurs de Support (Support Vector Machines)
W-KNN	K Plus Proches Voisins Pondéré (Weighted-KNN)
WPT	Transformée en paquets d'ondelette (Wavelet Paquet Transform)
WVT	Transformée de Wigner-Ville
$\bar{x}$	Moyenne empirique
$X(f)$	Transformée de Fourier
$\psi(t)$	Ondelette Mère
$\phi(t)$	Fonction échelle
$\sigma$	Variance
*	Conjugué complexe
$\theta_i$	Paramètres angulaires
Sgn	Fonction Signe
$\alpha_i$	Multiplicateurs de Lagrange
$\beta_i$	Multiplicateurs de Lagrange
$\Omega_c$	Classe de rang c (c =1,..., M)
$\mu_{ij}$	Degré d'appartenance de l'observation $x_j$ par rapport à la classe $C_i$

# Introduction Générale

Historiquement, la production industrielle d'électricité date depuis la fin du XIXe siècle, où les premières applications techniques voient le jour : l'éclairage électrique, le télégraphe, le téléphone, ..., etc. Aujourd'hui, l'énergie électrique est devenue un secteur stratégique dans le développement des pays et le confort des populations à travers le monde entier. Ainsi, selon la source d'énergie primaire utilisée : énergies fossiles (fioul, gaz, charbon), ou énergies nucléaires, on peut distinguer deux types de centrales de production d'électricité : Les centrales thermiques (turbines à vapeur, turbines à gaz, ou turbine à cycle combiné gaz/vapeur), et les centrales nucléaires. Cependant, l'électricité peut également être issue non pas d'une énergie mécanique, mais d'une énergie dite renouvelable telle que : l'énergie hydraulique (utilisant les eaux des barrages), l'énergie éolienne, l'énergie solaire, ..., etc.

Une centrale turbine à gaz, est généralement constituée d'un ou plusieurs groupes turbogénérateurs. Chaque groupe turbogénérateur est à son tour, composé d'équipements principaux tels que turbine, compresseur d'air, chambre de combustion, alternateur, et d'autres équipements dits auxiliaires tels que moteur de lancement, réducteur de vitesses, vireur, pompes, centrifugeuses, ventilateurs, ...etc. Tous ces équipements, sont souvent de nature machine tournante.

Selon des études statistiques du parc de production du groupe Sonelgaz, environ 40% des indisponibilités des centrales électriques sont dues à des défaillances, voire des incidents au niveau des équipements auxiliaires. C'est pour cette raison que toute entreprise de production d'électricité s'est trouvée dans l'obligation d'instaurer une stratégie de maintenance fiable, permettant de surveiller et d'entretenir en permanence, non seulement les équipements principaux, mais également les équipements auxiliaires afin de les rentabiliser d'une part, et d'éviter des arrêts de production imprévus, des indisponibilités fortuites et des pertes économiques qui en découlent, d'autre part. Pour cela, il s'avère d'une importance capitale de développer des outils de surveillance et de diagnostic pour détecter de manière précoce toute défaillance pouvant altérer au bon fonctionnement de ces diverses machines tournantes.

Généralement, ces machines tournantes sont constituées d'un ensemble de mécanismes et d'organes mécaniques, hydrauliques ou électriques combinés, destinés à accomplir une tâche précise : transformer une énergie, transmettre un mouvement...etc. Ces mécanismes, mobiles entre eux, ne peuvent fonctionner sans jeux, contraintes mécaniques importantes, efforts dynamiques et chocs dont les effets se manifestent principalement par une émission vers l'extérieur de nombreux signaux qui sont symptomatiques de leurs états de fonctionnement, tels que la chaleur dégagée, la puissance absorbée, le bruit, les vibrations, ... etc.

Parmi ces signaux, les vibrations présentent des avantages en raison de la richesse des informations qu'elles véhiculent, de leur transmission quasi-instantanée et de leur rapport direct avec les mouvements de la machine. Il faut dire qu'elles permettent à elles seules de détecter pratiquement tous les défauts susceptibles d'apparaître dans les machines tournantes. Un déséquilibre massique des rotors (balourd), un mauvais graissage, un défaut d'alignement entre deux rotors, usure de roulement, d'engrenages, ou même des courroies ..., se traduisent par une variation des efforts internes que subit la machine, et par conséquent à une modification de son comportement vibratoire. C'est pourquoi, afin de garantir une exploitation sans perturbations, empêcher les arrêts machines non planifiés, et garantir la sécurité des biens et des personnes, la plupart des méthodes modernes de

maintenance des machines font appel à l'analyse du comportement vibratoire [1]. En outre, dans le monde industriel d'aujourd'hui, les roulements de par leurs fonctions essentielles, sont devenus des composants incontournables au sein des machines tournantes, [2]. Néanmoins, ces composants peuvent être facilement endommagés. Les statistiques montrent qu'environ 30% des pannes des machines tournantes sont causées par des roulements [3]. Pour ces raisons parmi tant d'autres, que nous avons réservé une partie de notre travail de thèse à l'analyse des signaux vibratoires à des fins de surveillance et de diagnostic des différents défauts susceptibles d'apparaître principalement dans les roulements des machines tournantes.

L'analyse vibratoire repose sur le suivi d'indicateurs de défauts extraits des signaux vibratoires. Ces indicateurs peuvent être temporels (valeur d'amplitude maximale, valeur efficace, facteur crête, Kurtosis, Skewness, etc.) ou fréquentiels (amplitude des fréquences caractéristiques de défaut, Kurtosis fréquentiel, centre de fréquence, etc.). L'évolution brusque ou graduelle de ces indicateurs révèle la présence d'un défaut sur un ou plusieurs organes de la machine. L'extraction de ces indicateurs est basée sur des techniques de traitement du signal. Parmi ces techniques, on peut trouver l'analyse temporelle, l'analyse spectrale, l'analyse d'enveloppe, l'analyse cepstrale, etc. Cependant cette évolution peut être due à des facteurs autres que la présence de défauts comme les facteurs non linéaires qui peuvent affecter la machine tournante et s'ajouter à la complexité du système, par exemple le changement de la vitesse de rotation, les variations des charges ou la friction pour ne citer que les cas les plus fréquents [4].

Face à ces contraintes de fonctionnement, et l'intégration de ces machines dans des systèmes industriels de plus en plus complexes rendant le diagnostic plus difficile, de nouvelles techniques de traitement du signal ont été développées, permettant de mieux diagnostiquer les machines tournantes. Parmi ces techniques, on peut citer l'analyse temps-fréquence, l'analyse temps-échelle (Transformation en ondelettes). etc.

Ces dernières années, la transformée en ondelettes a été largement employée par les chercheurs dans divers domaines [5] [6]. C'est la technique la plus appropriée en termes de localisation temps-fréquence surtout pour analyser les signaux vibratoires à évolution à grande échelle. Aussi, il s'avère que la transformée en ondelette dans sa version discrète (transformée en ondelettes discrète : DWT) peut être implémentée au moyen d'un banc de filtres d'ondelette composé d'un filtre passe-bas et d'un filtre passe-haut à réponses impulsionnelles finies. Pour ces raisons, que cette technique d'analyse a été adoptée dans notre travail de thèse.

Cependant, et vu que les progrès des sciences ne cessent d'entraîner des évolutions considérables dans divers secteurs économiques, les industriels modernes s'équipent de plus en plus avec des systèmes automatiques complexes, afin d'améliorer la productivité, et la qualité de leurs produits tout en réduisant leur coût de traitement. La technicité de supervision de ces systèmes doit alors suivre leurs évolutions. La doter d'un outil de diagnostic adapté, à la fois rapide et robuste, peut permettre d'éviter les conséquences catastrophiques sur le plan économique, humain et environnemental. De ce fait, il est primordial d'aller vers des nouvelles techniques efficaces de supervision, qui permettent d'établir des diagnostics fiables quand c'est difficile autrement, et sans l'intervention d'un expert.

Les méthodes de reconnaissance de formes (RdF) qui sont des techniques issues de l'intelligence artificielle (AI), furent des solutions acclamées dans la littérature de diagnostic de par leur autonomie, leur fiabilité, leur facilité d'interprétation, ...etc. A cet effet, notre travail de recherche a pour objectif principal d'élaborer un système automatique de reconnaissance des formes

basé sur l'analyse des signaux vibratoires issus des différentes machines tournantes, et ce à des fins de diagnostic des différents défauts pouvant altérer le bon fonctionnement de ces machines.

Afin d'atteindre cet objectif, notre thèse a été organisée en cinq chapitres :

Le premier chapitre est scindé en deux parties principales. Dans la première partie nous avons présenté une description générale d'une centrale de production d'électricité. Ensuite, nous avons présenté le principe de fonctionnement d'une turbine à gaz, ainsi que les divers domaines d'utilisation. Les différents équipements principaux et auxiliaires constitutifs d'un groupe turbogénérateur à gaz, ont été également détaillés. Quant à la deuxième partie de ce chapitre, elle a été réservée à une étude bibliographique des différentes stratégies de maintenance appliquées au sein des entreprises industrielles.

Le deuxième chapitre a été consacré à développer les différentes méthodes permettant de réaliser une démarche de diagnostic des machines tournantes, et de prévenir au mieux la dégradation de leurs états de fonctionnement. Ces méthodes ont été classées en deux grandes familles : celles qui utilisent un modèle mathématique du système à surveiller, appelées aussi les « méthodes internes », et celles qui consistent à analyser les signaux mesurés, appelées aussi les « méthodes externes ».

Parmi les différentes méthodes de diagnostic utilisant des modèles analytiques, nous trouverons principalement l'espace de parité, les méthodes à base d'observateurs et les modèles d'estimation paramétrique. Néanmoins, et vu que parfois l'élaboration de modèles mathématiques s'avère très laborieuse, voire impossible, vu la complexité des systèmes à surveiller et du nombre important des variables les composant, les chercheurs ont été contraints à développer d'autres méthodes dites externes qui s'appliquent dans les situations où la modélisation des mécanismes reliant les causes de défaillances et des dégradations n'est pas techniquement modélisable ou ne présente pas d'intérêts économiques compte tenu des enjeux recherchés. En pratique, on trouve une grande variété de techniques issues des méthodes externes, telles que l'analyse des lubrifiants, la surveillance de la température (thermographie), l'analyse des émissions acoustiques, l'analyse des vibrations, l'analyse du bruit, l'analyse de la signature du courant moteur et les tests non destructifs. Une description détaillée a été consacrée à l'analyse vibratoire. Ensuite, un état de l'art des différentes techniques classiques et récentes de traitement de signal appliquées à l'analyse vibratoire et au diagnostic des machines a été présenté. Une attention particulière a été dédiée à la technique de transformation en ondelettes à travers ses trois catégories principales : Transformée en Ondelettes Continue (CWT), Transformée en Ondelettes Discrète (DWT), et enfin la Transformée en Paquets d'Ondelette (WPT). Enfin, nous avons présenté la notion de banc de filtres d'ondelette, ainsi que sa représentation polyphase. La factorisation de la matrice polyphase initiée par Vaidyanathan, ainsi que la méthode récursive proposée par Sherlock et Monro [7], pour générer les différents coefficients des filtres d'ondelette, ont été également développées.

Afin de pallier aux limitations des différentes techniques de diagnostic présentées au chapitre précédent, le troisième chapitre a été consacré à développer des nouvelles techniques issues de l'intelligence artificielle (AI). Parmi ces techniques, on trouve les méthodes de reconnaissance des formes (RdF). A cet effet, et après une introduction succincte sur les méthodes de reconnaissance des formes, nous avons détaillé les principales étapes nécessaires pour l'élaboration d'un système de reconnaissance des formes. Pour finir, nous avons décrit en détails, les principes de fonctionnement, les avantages et inconvénients, ainsi que les différentes applications dans le domaine du diagnostic

des machines industrielles, de quelques règles de décision (classifieurs) les plus utilisées dans les techniques de reconnaissance des formes.

Le chapitre 4 a été consacré à présenter une variété de techniques les plus utilisées pour résoudre des problèmes d'optimisation. Ces techniques peuvent être classifiées en deux grandes familles : déterministes et stochastiques. Ce chapitre est scindé en trois parties. La première partie a été réservée à exposer brièvement les techniques déterministes, ainsi que leurs conditions de mise en œuvre. Dans la deuxième partie, nous avons présenté en détails les méthodes stochastiques, appelées aussi « méthodes approchées » ou méthodes heuristiques. Quant à la dernière partie, elle a été consacrée à la présentation des techniques métaheuristiques. Cette famille d'algorithmes d'optimisation n'est en fait qu'une extension des méthodes heuristiques pouvant être adaptables à un grand nombre de problèmes différents sans changements majeurs dans l'algorithme. Le chapitre se termine par un état de l'art présentant quelques algorithmes métaheuristiques les plus étudiés et les plus utilisés dans la littérature, parmi lesquels se trouve l'approche adoptée dans notre travail de thèse.

Le chapitre 5 a été dédié à la validation expérimentale du système de diagnostic proposé. Pour cela, ce chapitre a été subdivisé en trois parties expérimentales essentielles. La première partie expérimentale a été consacrée à établir un système d'analyse et de diagnostic de certains défauts, les plus répandus (défaut de balourd, désalignement, et défaut de roulements) dans un groupe turbogénérateur. Pour cela, les différents travaux et traitements ont été effectués sur une base de données temporelles de signaux vibratoires collectés d'une centrale électrique (centrale de F'kirina située à la wilaya d'Oum el Bouaghi-Algérie).

Etant donné que les roulements sont devenus des composants indispensables dans la majorité des machines tournantes existantes au niveau des centrales électriques. La deuxième partie expérimentale, a été réservée pour la détection et le diagnostic des différents défauts susceptibles d'apparaître principalement dans les roulements. Pour cela, des signaux vibratoires ont été prélevés des roulements sous différents états de fonctionnement (Sain, et avec défauts). Ces signaux vibratoires sont collectés d'un banc d'essais expérimental du Centre de Recherche en Technologie Industrielle (CRTI) de l'université d'Annaba.

Dans la troisième partie expérimentale, et au lieu d'utiliser des ondelettes standards, notre contribution a été conçue à mettre en œuvre une démarche complète pour la conception d'une ondelette discrète PSO-DWT la mieux adaptée à l'analyse et au diagnostic des signaux vibratoires issus des roulements. Basé sur la représentation polyphase des bancs de filtres d'ondelette, et en s'inspirant de la factorisation initiée par Vaidyanathan, ainsi que la méthode récursive proposée par Sherlock et Monro, cette méthode va nous permettre de générer les coefficients d'un filtre passe bas  $\{h_0, h_1, \dots, h_{2N-1}\}$  de longueur  $2N$ , ainsi que ceux du filtre passe haut correspondant à travers seulement  $N$  paramètres angulaires  $\{\theta_0, \theta_1, \dots, \theta_{N-1}\}$  prenant des valeurs appartenant à l'intervalle  $[0, 2\pi[$ .

Afin de procéder à la recherche des paramètres angulaires optimaux, conduisant aux coefficients des filtres passe bas et passe haut les plus adéquats en terme de performance de classification, l'algorithme d'optimisation par essaim de particules (Partial Swarm Optimisation : PSO), a été employé.

Enfin, cette thèse s'achève par une conclusion générale qui synthétise l'ensemble de nos contributions et nos suggestions de quelques perspectives destinées à la poursuite de ce travail de recherche.



CHAPITRE I

MAINTENANCE DES MACHINES  
TOURNANTES ET DES STRUCTURES

N'acceptez jamais la défaite, vous êtes peut-être à un pas de la réussite.

**Jack Addington.**

## **Chapitre I : MAINTENANCE DES MACHINES TOURNANTES ET DES STRUCTURES**

### **1.1 Introduction**

Historiquement, la notion d'entretien d'un matériel date de l'apparition des premiers outils et des premières machines. Cependant, il faut attendre la première moitié du XXe siècle, après le développement de l'industrialisation, pour voir se structurer les méthodes d'intervention. C'est à la suite de la seconde guerre mondiale que de nouveaux besoins apparaissent, traduisant la nécessité d'une approche économique, et non plus seulement technique, de l'entretien des machines. Des notions nouvelles sont alors mises en forme pour servir d'outils efficaces permettant une gestion globale du fonctionnement des machines, notamment lorsque ces dernières sont regroupées en chaînes et ensembles complexes interagissant entre eux [8].

Notre étude doctorale va se focaliser sur le secteur énergétique, et principalement sur les centrales de production de l'énergie électrique qui jouent un rôle stratégique dans le développement des pays et le confort des populations à travers le monde entier.

Ce premier chapitre sera scindé en deux parties principales : la première partie sera consacrée à présenter un état de l'art sur les centrales de production d'électricité. Quant à la deuxième partie, elle sera réservée à une présentation détaillée des différentes stratégies de maintenance appliquées au sein des entreprises industrielles.

### **1.2 Description d'une centrale de production d'électricité**

#### **1.2.1 Historique**

A partir du XVIIe siècle les propriétés de l'électricité sont découvertes. Ainsi en 1799, Alessandro Volta crée la pile électrique. Il donnera son nom à l'unité de mesure de la force électromotrice et de différence de potentiel, le Volt (symbole : V). Le XIXe siècle voit la recherche s'accélérer. En 1831, Michael Faraday découvre que si un courant électrique peut produire un champ magnétique, l'inverse est possible : ainsi en mettant en mouvement un champ magnétique, on peut créer un courant électrique. Suivant ces découvertes, la dynamo est inventée par le belge Zénobe Gramme en 1868. Onze ans plus tard, Thomas Edison apporte avec l'ampoule électrique à incandescence une autre façon de faire de la lumière. La même année, en Suisse, la première centrale hydroélectrique voit le jour.

A la fin du XIXe siècle, la production industrielle d'électricité devient possible et les premières applications techniques voient le jour : l'éclairage électrique, le télégraphe, le téléphone, ..., etc. La deuxième révolution industrielle commence ! L'électricité investit de nombreux domaines comme l'industrie, les transports, l'éclairage public, ...etc.

#### **1.2.2 Fonctionnement général d'une centrale électrique**

Pour fonctionner, une centrale électrique (figure 1.1), doit produire une certaine énergie mécanique pour faire bouger les électrons à l'intérieur d'un alternateur. Ce sont ces électrons en mouvement qui se muent en électricité. Les énergies choisies pour cette mutation sont dites primaires. Selon la source d'énergie primaire utilisée : énergies fossiles (fioul, gaz, charbon), ou énergies nucléaires, on peut distinguer deux types de centrales de production d'électricité : Les centrales thermiques (turbines à vapeur, turbines à gaz, ou cycle combiné gaz/vapeur), et les

centrales nucléaires. Cependant, l'électricité peut également être issue non pas d'une énergie mécanique, mais d'une énergie dite renouvelable telle que : l'énergie hydraulique, l'énergie éolienne, l'énergie solaires, ..., etc.

En conséquence, le fonctionnement des centrales électriques est finalement toujours à peu près identique. La centrale n'a d'autre but que d'actionner une turbine qui fait tourner un alternateur. Celui-ci produit du courant qui, avant d'être transporté dans les lignes à haute ou très haute tension, doit voir sa tension transformée à travers un transformateur électrique.

Ce n'est que la façon dont est produite l'énergie primaire produisant l'énergie nécessaire pour actionner la turbine qui distingue réellement les centrales. Dans la section qui suit, une présentation détaillée sera consacrée à la turbine à gaz.



Figure 1.1 Centrale de production d'électricité

### 1.2.3 Turbine à gaz

Une Turbine à Gaz, appelée aussi turbine à combustion, est une machine tournante thermodynamique appartenant à la famille des moteurs à combustion interne dont le rôle est de produire de l'énergie mécanique (rotation d'un arbre) à partir de l'énergie contenue dans un hydrocarbure (fioul, gaz...).

### 1.2.4 Domaines d'applications

Les applications des turbines à gaz découlent directement de leurs avantages spécifiques. Ainsi, les turbines à gaz sont bien utilisées dans le domaine de la motorisation des avions. La propulsion navale fait également de plus en plus appel aux turbines à gaz notamment pour les navires à grande vitesse. En outre, les turbines à gaz sont employées pour l'entraînement de compresseurs et de pompes, dans le cadre de l'exploitation de pétrole et de gaz naturel. Le principal domaine d'emploi des turbines à gaz est la production d'électricité. En effet, il s'agit d'applications à régime constant et à charge relativement constante pour lesquelles le rendement de ces machines est le meilleur. La puissance varie de quelques centaines de kilowatt (KW) à près de 400 Mégawatt (MW). Les machines les plus puissantes sont en général associées à des turbines à vapeur dans des cycles combinés dont le rendement global tend actuellement vers 60%. En cycle simple, le rendement est de

l'ordre de 30 à 35% voire plus pour les grosses machines. L'avantage principal de l'utilisation des turbines à gaz consiste en un état de service très rapide. Des turbines à gaz sont opérationnelles à pleine charge dans un délai très court (Environ 10 mn), et c'est la raison pour laquelle elles sont souvent utilisées comme entraînements de réserve et en cas d'activité de pointe. L'inconvénient réside dans une consommation supérieure de carburant, comparée à celle d'un moteur diesel.

Enfin, des efforts importants ont été entrepris par les constructeurs pour la préservation de l'environnement, et limiter la pollution de l'air par les turbines à gaz, en particulier en réduisant les rejets d'oxyde d'azote (NOx). L'utilisation de gaz naturel permet une émission faible de dioxydes de soufre (SO<sub>2</sub>) et de monoxyde de carbone (CO).

### 1.2.5 Principe de fonctionnement d'une turbine à gaz

Dans sa forme la plus simple et la plus répandue, une turbine à gaz est composée de trois éléments essentiels (figure 1.2) :

- Un compresseur d'air, centrifuge ou plus généralement axial, qui a pour rôle de comprimer de l'air ambiant à une pression comprise aujourd'hui entre 10 et 30 bars environ ;
- Une chambre de combustion, dans laquelle un combustible gazeux ou liquide est injecté sous pression, puis brûlé avec l'air comprimé ;
- Une turbine, généralement axiale, dans laquelle sont détendus les gaz brûlés qui sortent de la chambre de combustion.

Sous cette forme, la turbine à gaz constitue un moteur à combustion interne à flux continu. On notera que le terme de turbine à gaz provient de l'état du fluide de travail, qui reste toujours gazeux, et non du combustible utilisé, qui peut être aussi bien gazeux que liquide (les turbines à gaz utilisent généralement du gaz naturel ou des distillats légers).




Figure 1.2 Principe de fonctionnement d'une turbine à gaz

Pour atteindre des taux de compression de 20 ou 30 bars, le compresseur est multi-étagé (composé de plusieurs étages), avec parfois une réfrigération intermédiaire destinée à réduire le

travail consommé. Les rotors axiaux sont constitués d'un empilage de disques, soit montés sur un moyeu central, soit assemblés en tambour sur leur périphérie. Les matériaux utilisés vont des alliages d'aluminium ou de titane pour les premiers étages aux alliages d'acier et aux alliages réfractaires pour les derniers étages, qui peuvent supporter des températures atteignant 500 °C.

La chambre de combustion est destinée à chauffer l'air provenant du compresseur afin de lui apporter l'énergie nécessaire à faire mouvoir la turbine et à donner suffisamment de poussée à la tuyère. Cet apport de chaleur se fait par la combustion du dioxygène de l'air avec du carburant (gaz naturel ou fioul) injecté par une pompe, et enflammé par une bougie d'allumage (allumeur). Après avoir atteint son régime d'autonomie, l'allumage de la bougie est coupé (bougie d'allumage rétractable) et la flamme s'auto-entretient. Les gaz de combustion atteignent des températures supérieures à +1000 °C. En raison de l'apport d'énergie dans la chambre de combustion, la vitesse des gaz brûlés augmente. Le flux des gaz brûlés à haute température et haute pression, va s'acheminer vers les différents étages turbine pour se détendre, en faisant tourner la turbine à des vitesses élevées atteignant les 3000 tr/mn.

La turbine généralement de type axial comprend un ou plusieurs étages de détente. Contrairement aux turbines à vapeur, il s'agit toujours de turbines à réaction. Deux grands types de turbines à gaz sont à distinguer :

- Simple arbre : le compresseur et l'ensemble des étages de détente sont regroupés sur le même arbre entraînant également l'organe récepteur qui est l'alternateur.
- Double arbres : le compresseur est sur le même arbre que les étages de turbine strictement nécessaires à son entraînement, les autres étages de turbine étant groupés sur un second arbre solidaire de la machine entraînée.

Le mouvement de rotation de la turbine est communiqué à l'arbre qui actionne d'une part le compresseur, d'autre part une charge qui n'est autre qu'un appareil récepteur (alternateur, pompe...) accouplé à son extrémité droite. Pour la mise en route, on utilise un moteur de lancement accouplé au compresseur qui joue le rôle de démarreur. Le réglage de la puissance et de la vitesse de rotation est possible en agissant sur le débit de l'air en entrée et sur l'injection du carburant.

Enfin, les gaz utilisés pour entraîner la turbine sont réacheminés pour être soit rejetés à l'atmosphère, soit dirigés vers une chaudière de récupération (dans le cas d'une turbine à cycle combiné).

### **1.2.6 Equipements auxiliaires d'une turbine à gaz**

En plus des équipements principaux constituant une turbine à gaz (détaillés précédemment), on trouve d'autres équipements vitaux, dits équipements auxiliaires. Ces équipements indispensables, contribuent directement au fonctionnement des groupes turbogénérateurs, et présentent un impact très étroit sur leur disponibilité, ainsi que sur leurs performances.

Parmi ces équipements auxiliaires, on peut citer :

- Moteur de lancement servant à lancer la turbine lors de son démarrage jusqu'à atteindre sa vitesse d'auto-sustentation.
- Réducteur de vitesse.

- Pompe à huile auxiliaire de lubrification turbine.
- Motopompe de soulèvement.
- Motopompe vireur.
- Compresseur gaz.
- Compresseur à air.
- Etc.

Ces dernières décennies, les groupes turbogénérateurs à gaz sont dotés de systèmes contrôle/commande On-line très sophistiqués, destinés d'une part, pour la mise en service et arrêt de ces groupes, et d'autre part pour la surveillance et le réglage de tous les paramètres d'exploitation (Température, pression, vibrations, dilatations, ...etc.) selon des normes établies par les constructeurs, et ce pour une meilleure performance des groupes, et leur protection contre tout dysfonctionnement ou incident. En outre, des opérations d'entretiens programmées sont généralement établies par les constructeurs selon des échanciers bien respectés en fonction du nombre d'heures de marches ou bien du nombre de démarrages des groupes.

Néanmoins, et malgré ces politiques de maintenance fiables, des études statistiques ont montré qu'environ 30% des indisponibilités des groupes turbogénérateurs sont dues à des défaillances, voire des incidents au niveau des équipements auxiliaires. C'est pour cette raison que tous ces équipements auxiliaires qui sont généralement de type machines tournantes doivent en permanence être contrôlées et entretenues afin de les rentabiliser, d'éviter des arrêts de production imprévus, des indisponibilités fortuites et des pertes économiques qui en découlent. C'est dans cet esprit que la maintenance est devenue une des principales priorités au sein des entreprises industrielles modernes. Cette nouvelle politique de maintenance a la lourde tâche non seulement d'augmenter la disponibilité des équipements mais également de garantir la sécurité des biens et des personnes. Il est donc important de développer des outils de diagnostic pour détecter de manière précoce les défauts pouvant apparaître sur ces différentes machines tournantes.

### 1.3 Types de maintenance

Selon la norme européenne NF EN 13306 [9], la maintenance est définie comme étant : « l'ensemble de toutes les actions techniques, administratives et de gestion, durant le cycle de vie d'un bien, destinées à le maintenir ou le rétablir dans un état dans lequel il peut accomplir une fonction requise » [10]. Les installations industrielles de nos jours sont généralement constituées d'un nombre important de machines tournantes telles que turbines, compresseurs, pompes, ventilateurs, moteurs, etc. L'augmentation de la productivité et la maîtrise des coûts dans un contexte de compétitivité économique nationale ou mondiale exigent que ces machines tournantes doivent être surveillées en permanence et entretenues afin d'accroître leur disponibilité, optimiser leur performance, réduire les incidents, et empêcher les arrêts machines non planifiés. Pour cela, il existe plusieurs façons d'organiser les actions de maintenance afin d'obtenir une disponibilité maximum au moindre coût [11]. Il en ressort les types de maintenance suivants :

- Maintenance curative.
- Maintenance préventive systématique.
- Maintenance préventive conditionnelle.

### 1.3.1 La maintenance curative

Elle correspond à une action de maintenance effectuée après une défaillance mécanique. Son utilisation est réservée aux équipements qui ne présentent pas un intérêt majeur dans le système de production et aucun risque pour le personnel en termes de sécurité [12].

### 1.3.2 La maintenance préventive systématique

Elle consiste à établir un échancier, basé sur le temps de bon fonctionnement [13].

### 1.3.3 La maintenance préventive conditionnelle

Elle fait appel à des indicateurs de performance pour prendre ou non des mesures correctives. Ces indicateurs peuvent être de différentes natures telles que l'analyse vibratoire, l'émission acoustique, l'analyse du bruit, la thermographie infrarouge, l'analyse des lubrifiants, ...etc. Ce type de maintenance est coûteux à mettre en place car il nécessite l'intégration d'instruments de mesures sur le système étudié et fait appel à des compétences de plus en plus pointues. Cependant, elle reflète le mieux l'état de fonctionnement de l'équipement concerné. Ces mesures sont ensuite extrapolées pour en déduire la durée de vie résiduelle avant une panne [14]. Le choix entre ces différents types de maintenance dépend des politiques menées sur chaque équipement. Le coût d'une panne et la sécurité du personnel sont deux paramètres primordiaux quant au choix du type de maintenance. Une bonne politique de maintenance correspond à un bon dosage entre ces trois méthodes. Elle est basée essentiellement sur leur complémentarité.

Le tableau ci-dessous récapitule les différents types de maintenance selon la norme NF EN 13306.

Situation selon NF EN 13306	Type de maintenance
Maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise.	Maintenance curative
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.	Maintenance systématique
Maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent.	Maintenance conditionnelle

Tableau 1.1 Différents types de maintenance

## 1.4 Objectifs visés par la maintenance préventive conditionnelle

- ✚ Améliorer la fiabilité du matériel [15].
- ✚ Garantir la qualité des produits.
- ✚ Améliorer l'ordonnancement des travaux.
- ✚ Assurer la sécurité humaine.
- ✚ Améliorer la gestion de la pièce de rechange (PDR) en stock.
- ✚ Améliorer le climat de relation humaine.

## 1.5 Principaux défauts des machines tournantes

Une machine tournante est généralement constituée d'un assemblage de pièces mécaniques, hydrauliques ou électriques combinées entre elles dans le but d'effectuer une tâche précise, transformer une énergie, transmettre un mouvement . . . etc. C'est pourquoi, afin d'établir un bon diagnostic des principaux défauts pouvant se manifester sur la machine, ainsi que leur gravité, la première démarche consiste à comprendre d'abord la nature de cette machine, de connaître la cinématique de l'installation à surveiller et d'analyser les origines de changements vibratoires de la machine.

L'expérience acquise sur les problèmes des machines tournantes a conduit à une panoplie de défauts dont on peut citer : défaut de fixation, défaut d'accouplement, le déséquilibre massique des rotors, désalignement entre deux rotors, usure de roulement, d'engrenages, ou des courroies, défaut de graissage, desserrage, jeu, fissures, ...etc. [15]. Cette liste de défaillances précitées est loin d'être exhaustive. Il serait illusoire de vouloir s'étendre sur toutes les innombrables défaillances éventuelles.

Dans ce qui suit, nous allons nous limiter à quelques défauts jugés les plus importants et les plus répandus dans les machines tournantes.

### 1.5.1 Défaut de balourd

Le déséquilibre massique (Balourd) est le générateur de vibrations le plus commun dans une machine tournante et il est dû à la distribution non symétrique de la masse autour de l'axe de rotation [16]. Un rotor est bien équilibré si son centre de masse appartient à l'axe de rotation et si cet axe est l'axe principal d'inertie. Le déséquilibre massique provient généralement du défaut d'usinage, d'assemblage, et de l'échauffement dissymétrique du rotor lors du fonctionnement [17].

### 1.5.2 Défaut d'alignement

Dans les machines tournantes, le défaut d'alignement de l'arbre (désalignement), est une situation dans laquelle l'arbre de la machine motrice et celui de la machine entraînée ne se trouvent pas sur la même ligne médiane, et que leurs axes de rotation ne sont pas concentriques [18]. En général, il existe trois types de désalignement d'arbre [19]

- Désalignement angulaire.
- Désalignement parallèle.
- Désalignement combiné (angulaire et parallèle).



### 1.5.3 Défaut de roulement

Le roulement est un élément mécanique qui s'interpose entre deux parties d'une machine électrique dont l'une est tournante et l'autre est fixe. Sa fonction principale est de permettre la rotation relative de ces éléments avec précision et avec un frottement minimal tout en supportant des charges radiales ou axiales plus au moins importantes [20]. Son couple de démarrage et ses pertes de frottement opérationnel sont généralement beaucoup plus faibles que pour les paliers lisses. Le roulement peut être aussi utilisé pour assurer un positionnement précis de l'arbre, et corriger des défauts d'alignement. C'est pourquoi, dans le monde industriel d'aujourd'hui, le roulement est devenu un composant incontournable au sein des machines tournantes.

De manière générale, les roulements sont constitués de quatre composants essentiels :

- Deux bagues concentriques en acier, appelés bague intérieure et bague extérieure, comportant des chemins de roulement (surfaces sur lesquelles "roulent" les corps roulants).
- Des corps roulants : billes, rouleaux ou aiguilles généralement en acier, permettant le mouvement des deux bagues avec un frottement minimal.
- Une cage séparant et guidant les corps roulants (en polyamide, tôle acier, laiton ou résine).

En pratique, pour chaque opération mécanique existe un roulement approprié ayant des caractéristiques spécifiques en termes de charges radiales et axiales supportées, de vitesse limite de rotation ou encore de défaut d'alignement admissible.

La figure 1.3 montre le schéma type de roulements à billes et à rouleaux.



Figure 1.3 Roulements à billes et à rouleaux

#### 1.5.3.1 Causes de dégradation des roulements

Le roulement est parmi les composants les plus utilisés dans les machines tournantes modernes, mais c'est aussi l'un des composants qui sont facilement endommagés. Des études statistiques montrent que 30 % des pannes de machines tournantes sont causées par des roulements. La dégradation du roulement peut se produire suite à une fatigue des matériaux sous des conditions normales de fonctionnement, ou bien lors d'une mauvaise utilisation ou d'un mauvais montage du roulement [21].

Parmi les causes probables de dégradation des roulements [22], on peut citer :

- L'usure due au vieillissement.
- Température de fonctionnement élevée.
- Perte de lubrification.
- Huile de lubrification contaminée (par des paillettes métalliques issues de la dégradation des billes ou de la bande de roulement).
- Défaut de montage.
- Les courants d'arbres.

Au début de la dégradation du roulement, et selon l'endroit où le défaut se produit, des fissures vont apparaître soit sur les pistes de la bague interne, sur les pistes de la bague externe, ou bien sur les éléments roulants. Au fil du temps, des écaillages et des arrachements de matière peuvent accélérer rapidement l'usure du roulement. Ces phénomènes seront accompagnés par l'évolution des niveaux de bruit et de vibrations [23].

### 1.5.3.2 Principaux défauts des roulements

Les principaux défauts qu'on peut rencontrer dans les roulements sont les suivants [21] :

- Écaillage : Se caractérise par des traces de fissuration et d'arrachement de fragments de matière.
- Grippage : dû à l'absence de lubrification, à une vitesse excessive ou un mauvais choix du type de roulement. Ceci se manifeste par un transfert de matière arrachée sur les surfaces et redéposée par microsoudure.
- L'incrustation de particules étrangères, due à un manque de propreté au montage ou de l'entrée accidentelle d'impuretés.
- La corrosion, due à un mauvais choix du lubrifiant.
- Les criques, fissures étroites ou autres amorces de cassures dues aux contraintes exagérées au montage ou au démontage.
- L'usure par abrasion, due à une mauvaise lubrification.

En effet, et selon l'emplacement géométrique du défaut dans le roulement, nous pouvons distinguer les types de défauts suivants :

1. Défaut de bague externe.
2. Défaut de bague interne.
3. Défaut de billes.
4. Défaut de cage

### 1.5.3.3 Fréquences caractéristiques des défauts de roulements

Chaque type de ces défauts est caractérisé par une fréquence de manifestation dite fréquence caractéristique. Ces fréquences caractéristiques sont déterminées à partir des côtes internes du

roulement, ainsi que de la cinématique de la machine étudiée (figure 1.4). Elles sont données par les équations suivantes [23] :

Défaut de bague externe :

$$f_{ex} = \frac{N_b}{2} f_r \left( 1 - \frac{D_b}{D_c} \cos \beta_c \right) \quad (1.1)$$

Défaut de bague interne :

$$f_{in} = \frac{N_b}{2} f_r \left( 1 + \frac{D_b}{D_c} \cos \beta_c \right) \quad (1.2)$$

Défaut de billes :

$$f_{bi} = \frac{D_c}{2D_b} f_r \left( 1 - \frac{D_b^2}{D_c^2} \cos^2 \beta_c \right) \quad (1.3)$$

Défaut de cage :

$$f_{ca} = \frac{1}{2} f_r \left( 1 - \frac{D_b}{D_c} \cos \beta_c \right) \quad (1.4)$$

Dans le cas où la bague externe est fixe, la fréquence caractéristique du défaut de billes (1.3) s'écrit sous la forme :

$$f_{bi} = \frac{D_c}{D_b} f_r \left( 1 - \frac{D_b^2}{D_c^2} \cos^2 \beta_c \right) \quad (1.5)$$

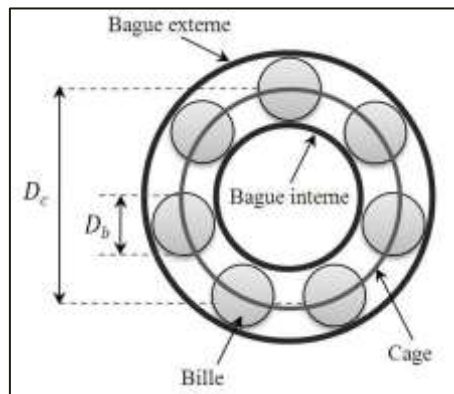


Figure 1.4 Géométrie d'un roulement

Avec  $f_r$  la fréquence de rotation du rotor,  $N_b$  le nombre d'éléments roulants,  $\beta_c$  est l'angle de contact de la bille avec les bagues,  $D_b$  et  $D_c$  sont respectivement le diamètre de l'élément roulant et le diamètre primitif.

## 1.6 Conclusion

Dans la première partie de ce chapitre, nous avons tout d'abord présenté un bref historique sur les premières découvertes de l'énergie électrique. Ensuite, nous avons décrit le principe de fonctionnement d'une centrale de production de l'électricité. Les équipements principaux d'un groupe turbogénérateur, ainsi que les équipements auxiliaires qui lui sont rattachés, ont été également présentés. Quant à la deuxième partie de ce chapitre, nous l'avons réservé à une présentation détaillée des différentes stratégies de maintenance appliquées au sein des entreprises industrielles. Une description détaillée a été consacrée à la stratégie de maintenance préventive conditionnelle. Enfin, les principaux défauts pouvant apparaître dans les machines tournantes ont été présentés.

# CHAPITRE II

## SYSTEMES DE DIAGNOSTIC DES MACHINES

Les défis sont ce qui rend la vie intéressante les surmonter est ce qui lui donne du sens.

**Joshua Marine.**

---

## Chapitre II : SYSTEMES DE DIAGNOSTIC DES MACHINES

### 2.1 Introduction

Etant donné la diversité des défauts pouvant intervenir dans les machines tournantes et la complexité des relations de cause à effet, de nombreuses méthodes permettant de réaliser une démarche de diagnostic et de prévenir au mieux la dégradation du système surveillé, ont été développées. Ces méthodes peuvent être regroupées en deux grandes familles : celles qui utilisent un modèle mathématique du système (méthodes internes), et celles qui consistent à analyser les signaux mesurés (méthodes externes). En effet, la sélection de la méthode de diagnostic la plus appropriée à un système industriel donné (c'est-à-dire la plus efficace sur le plan technique et économique) doit passer par l'inventaire des éléments indispensables suivants :

1. Nature des causes de défaillance à localiser.
2. Connaissance des symptômes associés aux défaillances induites par les causes.
3. Maîtrise des moyens de mesure des symptômes.
4. Maîtrise des moyens de traitement des symptômes.
5. Connaissance des mécanismes physiques entre les causes et les effets.
6. Définition du niveau de confiance dans le diagnostic.
7. Identification des utilisateurs finaux du diagnostic.

Dans ce chapitre, nous allons développer quelques-unes de ces méthodes ainsi que leurs applications dans le domaine du diagnostic des machines tournantes.

### 2.2 Méthodes de diagnostic à base de modèle analytique (Méthodes internes)

Ces méthodes requièrent une connaissance approfondie du système étudié afin de le représenter analytiquement (mathématiquement) sous forme d'un modèle quantitatif et/ou qualitatif [24]. Mathématiquement, on peut avoir plusieurs modèles du même système étudié. Ces modèles peuvent être à temps continu ou à temps discret, descriptibles au moyen d'équations différentielles ou d'équations aux différences, symboliques ou non, etc.

Le principal avantage de ces méthodes réside dans l'intégration d'une connaissance a priori du système et donc un filtrage de l'information. Ces méthodes reposent sur la comparaison des mesures réelles sur le système à surveiller et des informations que fournit le modèle (figure 2.1). Les écarts obtenus, aussi appelés résidus reflètent les défauts potentiels du système. Chaque résidu représente une signature unique d'un défaut et donc les éléments défectueux peuvent être facilement identifiés.

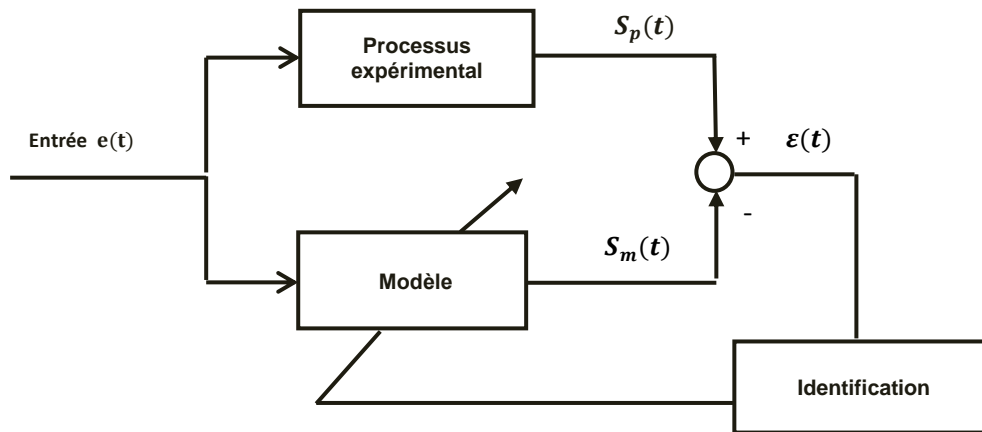


Figure 2.1 Principe du diagnostic par modèle.

Parmi les différentes méthodes de diagnostic utilisant des modèles analytiques, nous trouverons principalement l'espace de parité, les observateurs et l'estimation paramétrique.

### 2.3 Méthodes de diagnostic sans modèle (Méthodes externes)

Nous avons vu que la première catégorie de méthodes de diagnostic à base de modèles mathématiques (méthodes internes), nécessite la connaissance approfondie du comportement dynamique du système à surveiller. Toutefois, il est à signaler que les modèles ne permettent pas d'étudier tous les défauts qui peuvent surgir dans une machine industrielle (défaut de roulements par exemple). En outre, parfois l'élaboration de modèles mathématiques s'avère très difficile voire impossible vu la complexité des systèmes à surveiller et du nombre important des variables les composant. Toutes ces contraintes parmi tant d'autres ont poussé les chercheurs à développer d'autres méthodes (dites méthodes externes), qui ne reposent pas sur des modèles analytiques. Ainsi, les méthodes de diagnostic externes ont été développées pour pouvoir s'appliquer dans les situations où la modélisation des mécanismes reliant les causes de défaillances et des dégradations n'est pas techniquement modélisable ou ne présente pas d'intérêts économiques compte tenu des enjeux recherchés. De ce fait, le système à diagnostiquer est considéré comme étant une boîte noire où seules les signaux d'entrées et de sorties observables peuvent être mesurés.

En pratique, on trouve une grande variété de techniques issues des méthodes externes, telles que l'analyse des lubrifiants (huile ou graisse) [25-26], la surveillance de la température, appelée aussi la thermographie [27], l'analyse des émissions acoustiques [28], l'analyse des vibrations, l'analyse du bruit, l'analyse de la signature du courant moteur et les tests non destructifs [29].

Contrairement aux méthodes internes, ces techniques ont l'avantage de l'indépendance de l'analyse par rapport aux fluctuations internes du système. D'autre part, l'information contenue dans les signaux, n'étant pas filtrée par la modélisation, elle reste intacte. Une description détaillée sera donnée à l'analyse vibratoire, objet de notre étude.

### 2.3.1 L'analyse vibratoire

L'utilisation de l'analyse des signaux vibratoires comme méthode de diagnostic des défauts remonte aux années 1960. Depuis, on y fait largement appel dans la plupart des installations industrielles, particulièrement dans la prévention des pannes mécaniques [30]. Il faut dire qu'elle permet à elle seule de détecter pratiquement tous les défauts susceptibles d'apparaître dans les machines tournantes. Un déséquilibre massique (balourd), un mauvais graissage, un défaut d'alignement, un roulement usé ou endommagé... se traduisent par une variation des efforts internes que subit la machine, et par conséquent à une modification de son comportement vibratoire. Ce changement de comportement vibratoire constitue souvent la première manifestation physique d'une anomalie, cause potentielle de dégradations, voire de pannes [27], [31].

Dans notre étude et dans la suite de cette thèse, nous nous intéressons plus particulièrement à cette technique d'analyse vibratoire pour la détection et l'identification des différents défauts susceptibles d'apparaître au niveau des équipements principaux et auxiliaires des groupes turbogénérateurs des centrales électriques.

## 2.4 La surveillance par analyse vibratoire

Un système mécanique est dit en vibration lorsqu'il est animé d'un mouvement de va et vient autour d'une position moyenne dite d'équilibre. Selon la norme AFNOR E90.350 [32], une vibration peut être définie par la « variation avec le temps de la valeur d'une grandeur caractéristique du mouvement ou de la position d'un système mécanique, lorsque la grandeur est alternativement plus grande ou plus petite qu'une certaine valeur moyenne ou de référence »

### 2.4.1 Nature d'une vibration

Les vibrations issues d'une machine tournante en fonctionnement peuvent être classées de la façon suivante :

- Vibrations périodiques de type sinusoïdales simples ou sinusoïdales complexes représentatives du fonctionnement normal ou anormal d'un certain nombre d'organes mécaniques (rotation de lignes d'arbres, engrènements...) ou d'un certain nombre d'anomalies (déséquilibre, désalignement, déformations, instabilité des films d'huile de graissage, défaut de roulements, ...).
- Vibrations périodiques de type impulsionnel : sont appelées ainsi par référence aux forces qui les génèrent et à leur caractère brutal, et périodique, à l'exemple de chocs dus à un défaut d'engrenage, d'écaillage de roulement ou de jeux excessifs.
- Vibrations aléatoires de type impulsionnel.



### 2.4.2 Différents niveaux d'analyse vibratoire

On note trois niveaux d'analyse vibratoire :

- **Surveillance vibratoire :** Elle consiste à surveiller l'état général de la machine dans des conditions d'exploitation identiques. Cette surveillance vibratoire est réalisée à travers des indicateurs globaux. Ces indicateurs sont mesurés à l'aide de capteurs à intervalles de temps réguliers puis comparés à des normes ou aux valeurs précédentes. Si un ou plusieurs indicateurs dépassent le seuil admissible, cela permet de mettre en évidence l'existence d'une anomalie à un stade précoce et de faire une première idée des types de défauts qui affectent la machine. Ces contrôles peuvent donner suite à des interventions correctives simples de maintenance ne nécessitant pas de réalisation d'un diagnostic de panne et de démontage. Ils peuvent aussi déclencher, notamment sur des anomalies constatées, des opérations de maintenance de niveaux supérieurs afin d'identifier et d'estimer le problème ; il s'agit du diagnostic.
- **Diagnostic :** Le diagnostic consiste à mettre en évidence la défaillance des composants et d'identifier la source de cette défaillance par des outils de traitement du signal tels que l'analyse de Fourier, le cepstre, l'analyse d'enveloppe, etc. Ces outils permettent d'identifier sur le spectre un certain nombre de fréquences caractéristiques, qui révèlent la présence et l'origine des défauts. Cependant, et afin d'établir un bon diagnostic vibratoire, il est indispensable de connaître non seulement la cinématique de la machine, mais également les caractéristiques de ses composants ainsi que leurs différents modes de dégradation. Ces outils mathématiques fournissent aussi des informations significatives de l'état de dégradation des composants [33], qui seront utilisées pour le suivi dans le temps de l'évolution de la sévérité de la défaillance ; il s'agit de la troisième étape qui est le suivi et pronostic.
- **Suivi et pronostic :** L'étape de suivi et de pronostic constitue le niveau le plus élevé dans l'analyse vibratoire. Dans ce niveau on s'intéresse soit à l'estimation de la probabilité qu'une défaillance survienne à un instant donné, soit à la prédiction du temps résiduel avant défaillance communément appelé RUL (Remaining Useful Life) [34]. Cela permet de planifier un arrêt programmé de la machine pour le remplacement du (ou des) composant(s) défectueux.

### 2.4.3 Systèmes de mesure des signaux vibratoires

En analyse vibratoire, le choix de la chaîne de mesure est une étape cruciale pour l'acquisition des signaux vibratoires à étudier. Pour cela, le matériel de mesure sélectionné doit être performant, et en adéquation avec les caractéristiques vibratoires fournies par les machines tournantes [35]. Une chaîne de mesure (figure 2.2), est généralement composée des éléments constitutifs suivants [36] :

- Capteurs de vibration : qui convertissent les vibrations mécaniques en signaux électriques sous forme d'une tension électrique (1- 5 volts) ou charge électrique (4-20 mA).
- Préamplificateur : ayant pour rôle d'amplifier le signal de sortie du capteur pour le rendre exploitable et transportable.
- Intégrateur : permettant des intégrations simples et double pour ainsi obtenir en sortie des signaux de vitesse ou de déplacement.
- Filtres passe haut ou passe bas : Pour limiter les plages de fréquences du signal à traiter et ainsi améliorer la qualité du signal avant enregistrement et/ou analyse.
- Amplificateur : permet d'amplifier de nouveau le signal obtenu pour le transmettre de nouveau à l'appareil de visualisation et ainsi pouvoir analyser.

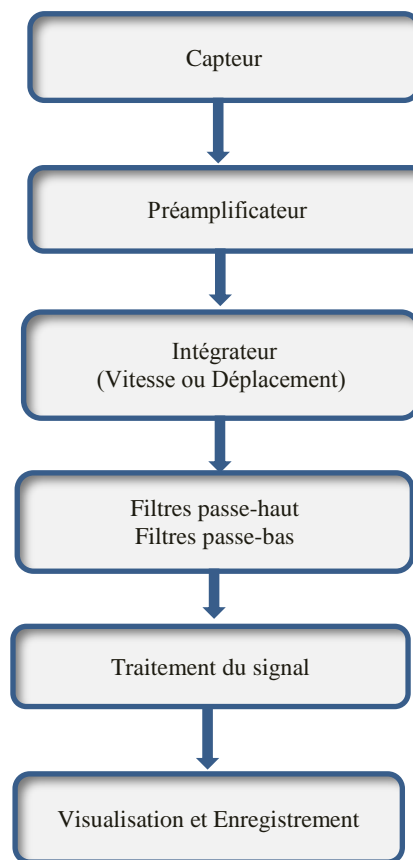


Figure 2.2 Chaîne de mesure vibratoire

## 2.5 Techniques de traitement de signal appliquées à l'analyse vibratoire

En pratique, un signal vibratoire n'est jamais pur, mais il est souvent superposé à une composante parasite appelée « Bruit », gênant sa perception ou son interprétation. C'est pour cette raison, que parmi les principaux objectifs des techniques de traitement de signal est de séparer le signal utile recherché du bruit qui lui est associé. Cette définition suppose que l'on sache ce qu'est le signal recherché, ou ce qu'est le bruit à éliminer. Sans cela, sans une connaissance fine de la problématique des études entreprises, les techniques de traitement du signal les plus sophistiquées du monde risquent de tourner à vide [37].

En littérature, il existe une panoplie de techniques de traitements de signal qui peuvent être appliquées dans le domaine de la surveillance et du diagnostic des défauts des machines tournantes. Ces techniques peuvent être divisées en sept groupes différents : l'analyse temporelle, l'analyse spectrale, l'analyse d'enveloppe, l'analyse cepstrale, l'analyse de la cyclostationnarité, l'analyse temps-fréquence, et enfin l'analyse temps-échelle.

Dans ce chapitre, on va se limiter à la présentation de quelques techniques qui sont employées dans notre travail de thèse.

### 2.5.1 Analyse temporelle

Les méthodes temporelles sont basées sur l'analyse statistique des signaux recueillis des capteurs de vibration et filtrés sur certaines plages fréquentielles. Ces méthodes considérées historiquement les plus anciennes, permettent d'extraire des indicateurs statistiques temporels résumant l'information contenue dans les signaux vibratoires, et permettant de suivre son évolution dans le temps. Les avantages des indicateurs statistiques temporels sont leur simplicité, leur facilité d'interprétation et la possibilité de les agrémenter de seuils dont le dépassement déclenche une alarme en situation anormale. Ils sont donc particulièrement bien adaptés pour la surveillance et le contrôle en ligne, voire en temps réel [38].

De nombreux indicateurs temporels performants et adéquats existent dans la littérature [39]. Dans ce qui suit, nous allons présenter quelques indicateurs les plus utilisés.

#### 2.5.1.1 Amplitude

On appelle amplitude d'un signal vibratoire la valeur de ses écarts par rapport au point d'équilibre et on peut définir :

**a. Amplitude maximale, ou valeur crête ( $A_c$ ):**

L'amplitude maximale par rapport au point d'équilibre, appelée amplitude crête ( $A_c$ ) ou niveau crête. La valeur de crête donne l'amplitude maximale et s'avère utile dans les mesures concernant les phénomènes de courte durée ; les chocs en sont un exemple. Cependant, elle ne tient pas compte de l'évolution de la vibration dans le temps.

**b. Amplitude crête à crête ( $A_{cc}$ ):**

L'amplitude double, aussi appelée l'amplitude crête à crête ( $A_{cc}$ ) (peak to peak, en anglais) ou niveau crête-crête. Cet indicateur indique la différence entre les amplitudes maximale et minimale du mouvement. C'est une quantité utile pour déterminer le déplacement d'un composant, déplacement qui peut être critique pour des considérations de contrainte maximale ou de jeu mécanique.

**c. Amplitude efficace ou valeur RMS ( $A_{eff}$ ):**

L'indicateur scalaire le plus couramment utilisé en traitement de signal, est la valeur efficace ou moyenne quadratique du signal temporel (RMS : Root Mean Square). En plus de tenir compte de

l'évolution du signal dans le temps, ce descripteur représente une caractéristique importante du signal, puisqu'il permet de mesurer son énergie moyenne, et de détecter des dissipations d'énergies anormalement élevées accompagnant la naissance d'un défaut. En outre, il est généralement utilisé pour des signaux de type accélération ( $A_{eff}$ ) et sur une bande de fréquences entre 0 et 20 KHz [40].

Considérons un signal vibratoire temporel discrétisé  $x(n)$  de longueur  $N$  et de moyenne empirique  $\bar{x}$ , la valeur efficace RMS est donnée par l'expression suivante :

$$A_{eff} = RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n))^2} \quad (2.1)$$

Néanmoins, l'un des inconvénients majeurs de l'utilisation du RMS, c'est qu'il donne généralement une alarme assez tardive, notamment pour le cas des défauts de roulements, où la variation du signal due à l'apparition d'un défaut est masquée par d'autres composantes d'amplitudes plus élevées [41].

### 2.5.1.2 Le facteur de crête (FC)

Le facteur de crête est un indicateur dérivé de la valeur efficace utilisé, pour la détection spécifique d'impulsions ou de choc présents dans le signal vibratoire [42]. Il est défini comme étant le rapport entre la valeur crête du module du signal et sa valeur efficace :

$$FC = \frac{A_{crête}}{A_{eff}} \quad (2.2)$$

Contrairement à la valeur efficace, le facteur de crête a l'avantage de détecter le défaut dès son apparition et donne une information très précoce de la prédiction. Ceci provient du fait que par exemple, pour un roulement sans défaut, le rapport reste sensiblement constant et augmente lorsqu'un début d'écaillage apparaît. Ceci est dû à la présence des chocs dans le signal vibratoire [41].

L'inconvénient majeur de cet indicateur est qu'il présente environ les mêmes valeurs dans les deux cas extrêmes (état neuf et fin de vie du roulement), seule son évolution est donc significative.

### 2.5.1.3 Le Kurtosis (Ku)

Le Kurtosis (ou moment statistique d'ordre 4), est un indicateur statistique permettant d'analyser la répartition des amplitudes vibratoires contenues dans un signal temporel.

Mathématiquement, il est défini par l'expression suivante :

$$Kurtosis (Ku) = \frac{\frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^4}{\left[ \frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^2 \right]^2} \quad (2.3)$$

Les vibrations de type sinusoïdal ou impulsionnel génèrent des allures de courbe de densité différente. Pour quantifier cette différence, le Kurtosis est le plus représentatif. Ce paramètre détecte la présence d'impulsions ou de choc dans le signal.

En temps normal, la distribution statistique de ce paramètre obéit à une loi gaussienne. Les valeurs mesurées se répartissent en forme de cloche autour d'une valeur moyenne, et le Kurtosis vaut mathématiquement 3. Mais lorsqu'un défaut apparaît, la valeur du Kurtosis augmente, et l'allure de la courbe deviendra plus étroite [43].

Le Kurtosis permet alors d'en caractériser « l'aplatissement ». Cet indicateur ne manque pas d'avantages. Comme il est calculé sur plusieurs bandes de fréquences à partir d'à peine quelques hertz et que les premiers défauts se manifestent par des chocs à basse fréquence, le Kurtosis permet de détecter la dégradation des roulements à un stade précoce.

Aussi, cet indicateur présente l'avantage d'être indépendant des variations des vitesses de rotation et des charges de la machine [44].

Son inconvénient, c'est que tout comme le facteur de crête, le Kurtosis décroît lorsque les défauts se développent. A un stade avancé de la détérioration du roulement, il reprend une valeur proche de 3, c'est-à-dire celle de l'état initial sans défaut.

#### 2.5.1.4 Skewness (SK)

Le coefficient de dissymétrie (ou moment statistique d'ordre 3) appelé Skewness, représente le taux de dissymétrie de la distribution d'amplitude du signal par rapport à un maximum (dont l'abscisse correspond à la moyenne dans le cas d'une gaussienne). La mesure de cette dissymétrie est donnée par :

$$SK = \frac{\sum_{n=1}^N [x(n) - \bar{x}]^3}{(N - 1)\sigma^3} \quad (2.4)$$

C'est une quantité sans dimension. SK sera positif ou négatif selon l'étalement de la courbe à droite ou à gauche, respectivement, de la valeur moyenne. L'ensemble de ces indicateurs temporels est très facile à mettre en œuvre. Le plus souvent, ces différents indicateurs sont traités simultanément pour profiter des avantages de chacun et confirmer les résultats. Ces indicateurs indiquent une modification du comportement vibratoire de l'ensemble de la structure mais ne permettent pas la localisation de l'élément qui modifie ce comportement.

Un deuxième niveau est alors nécessaire pour définir la cause de cette variation du niveau de vibration : c'est le diagnostic.

### 2.5.2 Analyse spectrale

Tout défaut affectant une machine tournante se traduit par des vibrations dont les fréquences correspondent aux fréquences d'apparition des forces les induisant et de leurs harmoniques [35].

L'analyse des signaux vibratoires dans le domaine fréquentiel est devenue un outil incontournable pour la surveillance et le diagnostic des machines tournantes [45]. Elle est considérée comme étant la contrepartie indispensable de l'analyse dans le domaine temporel du signal ; il n'est en effet pas rare que des phénomènes difficilement discernables dans l'un des domaines apparaissent clairement dans l'autre. L'analyse fréquentielle consiste à décomposer l'énergie du signal analysé par bandes de fréquence, et par conséquent, de discerner dans le domaine fréquentiel des phénomènes indépendants caractérisés par des épanouissements fréquentiels différents (figure 2.3).




Figure 2.3 Obtention d'un spectre à partir du signal temporel

L'analyse fréquentielle du signal vibratoire  $x(t)$  s'appuie sur la transformée de Fourier, représentée par l'équation (2.5) :

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \tag{2.5}$$

Où  $X(f)$  est la transformée de Fourier,  $t$  est la variable temps,  $f$  est la variable fréquence.

Cette représentation permet de connaître le contenu fréquentiel du signal vibratoire, et de localiser les fréquences caractéristiques de défauts sous forme d'un **spectre** « Amplitudes-fréquences » [46]. C'est en 1965 que Cooley et Tukey ont décrit un algorithme très pertinent pour implémenter la transformée de Fourier discrète (DFT) [47]. Cet algorithme désormais appelé la transformée de Fourier rapide (Fast Fourier Transform : FFT).

En pratique, on utilise la transformée de Fourier rapide (FFT) (équation 2.6) sur des signaux numérisés [35] :

$$X(k\Delta f) = \frac{1}{N} \sum_{n=0}^{N-1} x(nt_e)e^{-j2\pi k \frac{n}{N}} \tag{2.6}$$

Où  $X(k \Delta f)$  est la transformée de Fourier discrète rapide,  $t_e$  est la période d'échantillonnage du signal temporel,  $n$  est le numéro de l'échantillon,  $k$  est le numéro de la ligne fréquentielle,  $\Delta f$  est l'intervalle entre deux raies fréquentielles,  $N$  est le nombre d'échantillons prélevés.

Cependant, l'interprétation d'un spectre sera d'autant plus précise et pertinente que les conditions de fonctionnement et la cinématique de la machine sont connues, notamment :

- Le type de moteur, le nombre de barres et d'encoches, le nombre de pales du ventilateur de refroidissement,
- Le type de roulements,

- Le type d'accouplement et le nombre de dents ou de doigts,
- Le nombre de poulies, la longueur et le nombre de courroies,
- Le nombre de dents des engrenages,
- Le nombre d'aubes de pompes ou d'augets de Turbine
- ...etc.

L'inconvénient majeur de l'analyse spectrale classique est son caractère global. L'aspect temporel du signal disparaît. En effet, la transformée de Fourier suppose que les signaux sont stationnaires, elle ne fournit donc pas d'informations sur l'évolution du spectre du signal en fonction du temps [48]. Néanmoins, les signaux vibratoires issus des machines tournantes sont généralement non-stationnaires.

### 2.5.3 Analyse temps-fréquence

En maintenance préventive, les techniques de diagnostic des défauts des machines tournantes, ont largement évolué, en allant des descripteurs temporels, analyse spectrale, à l'analyse cepstrale en passant par la démodulation d'amplitude (analyse d'enveloppe).

Néanmoins, ces techniques s'avèrent parfaitement adaptées seulement au diagnostic des signaux à caractère stationnaire. Cependant, les signaux de vibration des composants défectueux dans les machines tournantes sont souvent intermittents. Ces signaux sont sous une forme non-stationnaire et ont des caractéristiques fréquentielles variables au cours du temps. La propriété non-stationnaire du signal rend la transformée de Fourier comme un outil de traitement du signal inapproprié car elle ne fournit pas d'informations sur le temps. En conséquence, il devient nécessaire d'introduire de nouveaux outils visant à se pencher à la fois sur la variation dans le temps et sur les fréquences du signal. D'où le développement des techniques d'analyse temps-fréquence [49]. L'analyse temps-fréquence a pour but de combler les lacunes de la transformée de Fourier pour l'analyse des signaux non-stationnaires. Ces méthodes permettent :

1. De fournir une représentation du signal en trois dimensions (amplitude-temps-fréquence).
2. De détecter et de suivre le développement des défauts qui génèrent une faible puissance vibratoire.
3. De superviser des machines dans lesquelles le processus de fonctionnement normal produit une amplitude élevée des chocs périodiques.

Parmi les techniques d'analyse temps-fréquence les plus utilisées, on peut citer : la transformée de Fourier à court terme (Short Time Fourier Transform : STFT) [50], et la transformée de Wigner-Ville (WVT) [51].

### 2.5.4 Analyse temps-échelle

Comme il a été décrit dans les sections précédentes, que l'analyse spectrale basée sur la transformée de Fourier est une transformation globale. En effet, la transformée de Fourier suppose que les signaux sont stationnaires, elle ne fournit donc pas d'informations sur l'évolution du spectre

du signal en fonction du temps. Aussi, on a vu que les transformations temps-fréquence (STFT et WVT) sont à caractère local, et présentent des résolutions temporelles fixes. En conséquence, ces transformations sont recommandées surtout pour l'analyse des signaux quasi-stationnaires, par contre, il s'avère qu'elles ne sont pas appropriées pour analyser les évolutions à grande échelle.

Face à ces limites, de nouveaux outils de traitement de signal, viennent d'être développés, permettant de pallier à ces inconvénients. Ces techniques appelées transformations **temps-échelle**, ou **transformations en ondelettes**, consistent d'une certaine manière, à faire varier la taille de la fenêtre en fonction de la fréquence.

En effet, elles sont conçues de telle manière à effectuer des analyses localisées sur une partie du signal. Des aspects particuliers caractérisant les phénomènes non stationnaires, tels que discontinuités ou petites singularités dues généralement à des fluctuations d'alimentation, peuvent être révélés par l'analyse par ondelettes.

Le principe de la transformée en ondelettes consiste à décomposer le signal à l'aide de fonctions analysantes particulières (Ondelettes) construites à partir d'une ondelette « mère » appelée  $\psi(t)$  dont les caractéristiques sont les suivantes : oscillante, rapidement amortie, et à moyenne nulle [52].

La figure (2.4) présente deux exemples d'ondelettes mères : Ondelette de Morlet et Ondelette de Daubechies.




Figure 2.4 Exemples d'ondelettes mères : (a) : Morlet. (b) : Daubechies d'ordre 2.

Ces ondelettes définies par  $\psi_{(a,b)}(t)$  centrées autour du paramètre  $b$  et à échelle variable indiquée par le paramètre  $a$  sont données par :

$$\psi_{(a,b)}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right), \quad \text{avec } (a,b) \in \mathbb{R} \quad (2.7)$$

Le paramètre «  $a$  » désignant l'échelle, est un coefficient de dilatation qui correspond à l'étirement ou à la contraction de l'ondelette. Ainsi, à chaque valeur d'échelle, l'ondelette possède sa propre fréquence centrale  $F_c$ . Un rapport de proportionnalité inverse existe entre l'échelle  $a$  et la fréquence associée.



- ❖ Une valeur élevée de « a » (grande échelle), correspond à une ondelette étirée ou étendue selon l'axe du temps, par contre, elle est concentrée selon l'axe des fréquences. Ceci conduit à une ondelette qui convient à analyser le signal aux basses fréquences (Vue globale), autrement dit bonne résolution temporelle pour les basses fréquences.
- ❖ Une faible valeur de « a » signifie une ondelette contractée temporellement (petite échelle), soit une ondelette permettant de se concentrer sur les hautes fréquences (Vue détaillée), correspondant généralement aux composantes transitoires du signal à analyser, autrement dit, bonne résolution fréquentielle pour les hautes fréquences.

Le paramètre « b » correspond au décalage temporel de la fonction analysante, en le faisant varier, on déplace la fonction analysante le long de l'axe des temps.

Les techniques de transformation en ondelettes peuvent être classifiées en trois catégories principales : Transformée en ondelettes continue (CWT), Transformée en ondelettes discrète (DWT), et enfin la Transformée en paquets d'ondelette (WPT).

#### 2.5.4.1 Transformation en ondelettes continue (CWT)

La transformée en ondelettes continue  $CWT_x(a, b)$  associée à un signal  $x(t)$  est donnée par :

$$CWT_x(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^* \left( \frac{t-b}{a} \right) dt \quad (2.8)$$

Où \* représente le complexe conjugué.

Le rapport  $\frac{1}{\sqrt{a}}$  normalise l'énergie des ondelettes à toutes les échelles.

La transformation inverse permet de reconstruire le signal original :

$$x(t) = k \cdot \frac{1}{\sqrt{a}} \iint_{-\infty}^{+\infty} \psi \left( \frac{t-b}{a} \right) WT_x(a, b) \cdot da db \quad (2.9)$$

Tout comme a été défini le spectrogramme pour la transformée de Fourier à court terme, on peut définir le « **scalogramme** » comme étant le module au carré de la transformée en ondelettes continue :  $|CWT_x(a, b)|^2$

Le scalogramme qui n'est rien d'autre que la corrélation locale entre la fonction analysante et le signal, est très utilisé dans le diagnostic des défauts.

Les applications de la CWT sont nombreuses et diversifiées. Ainsi, dans le domaine mécanique, elle a largement été employée pour le diagnostic des défauts de roulements [53]. Wang et al ont combiné les transformations de Fourier et en ondelettes pour caractériser des défauts naissants et bien localisés sur les paliers à roulement [54]. Rubini, a démontré l'efficacité des ondelettes par rapport à d'autres techniques, en étudiant des roulements comportant des défauts de piqûres sur les pistes et cela pour de faibles charges radiales. Une revue bibliographique sur l'application de la

transformation en ondelettes dans le domaine de diagnostic des machines tournantes a été réalisée par Peng et Chu en 2004 [55].

#### 2.5.4.2 Transformation en ondelettes discrète (DWT)

Parmi les inconvénients de la transformée en ondelettes continue (CWT), est qu'elle présente des pertes ou des redondances d'informations [56]. En outre, la transformation occasionne un volume important de calculs, vue la quantité des coefficients d'ondelettes à calculer, ce qui la rend applicable uniquement aux utilisations « Off-ligne ».

Afin de pallier à ces inconvénients, un processus de discrétisation est nécessaire surtout pour les applications nécessitant un traitement du signal en temps réel « On-line ».

Ainsi, la transformée en ondelettes discrète (DWT) est une implémentation utilisant un ensemble discret d'échelles et de translations d'ondelettes obéissant à certaines règles.

Grâce à la discrétisation de la CWT ( $a, b$ ), la transformée en ondelettes discrète DWT ( $j, k$ ) est définie comme suit :

$$DWT(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \psi \left( \frac{t - 2^j k}{2^j} \right) \quad (2.10)$$

Où  $a$  et  $b$  ont été remplacés respectivement par  $2^j$  et  $k2^j$

Où  $j$  représente le niveau de décomposition et  $k$  le facteur de translation ( $j, k \in \mathbb{Z}^2$ )

S. Mallat [57] montra que la transformée en ondelette discrète (DWT) peut être implémentée au moyen d'un banc de filtres d'ondelette comprenant un filtre passe-bas et un filtre passe-haut dont les réponses impulsionnelles sont respectivement  $h(n)$  et  $g(n) = (-1)^n h(1 - n)$ .

Appelés aussi filtres à miroirs quadratiques (Quadrature Mirror Filters : QMF), ces deux filtres d'ondelette sont déterminés à partir de l'ondelette mère  $\psi(t)$  ainsi que de sa fonction échelle correspondante  $\phi(t)$  [58, 59].

$$\begin{cases} \phi(t) &= \sqrt{2} \sum_n h(n) \phi(2t - n) \\ \psi(t) &= \sqrt{2} \sum_n g(n) \phi(2t - n) \end{cases} \quad (2.11)$$

En pratique, la transformée en ondelettes discrète (DWT), connue aussi sous le nom de décomposition en ondelettes dyadiques, consiste à faire passer le signal  $x(t)$  à travers le banc de filtres passe bas  $h(n)$  et passe haut  $g(n)$ . Le résultat ainsi obtenu réside en un signal d'approximation  $A_1$  et d'un signal de détail  $D_1$ . Ensuite, chaque décomposition subit une décimation d'un facteur 2 conduisant aux coefficients d'approximation  $CA_1$  et de détail  $CD_1$ . Les basses fréquences seront contenues dans le signal d'approximation  $CA_1$ , et les hautes fréquences dans le signal de détail  $CD_1$  (Voir figure 2.5).




Figure 2.5 Décomposition en ondelettes dyadiques

L'opération est répétée de manière itérative sur chaque signal d'approximation jusqu'au  $k^{ième}$  niveau de décomposition souhaité. En conséquence, le résultat final obtenu réside en un vecteur  $CA_k$  d'approximation et  $k$  vecteurs de détails  $CD_j$  ( $1 \leq j \leq k$ )

Un exemple de décomposition d'un signal  $x(t)$  en ondelettes dyadiques jusqu'au niveau  $j = 3$  est schématisé par la figure 2.6.




Figure 2.6 Arbre de décomposition en ondelettes dyadiques au niveau  $j = 3$

La fréquence d'échantillonnage étant  $f_{éch}$ , chaque niveau  $j$  contient deux intervalles :  $[0, \frac{f_{éch}}{2^{i+1}}]$  pour les approximations, et  $[\frac{f_{éch}}{2^{i+1}}, \frac{f_{éch}}{2^i}]$  pour les détails. Les sous bandes fréquentielles correspondantes sont schématisés dans la figure 2.7.




Figure 2.7 Découpage en sous bandes fréquentielles d'un signal par la transformée en ondelettes dyadiques au niveau  $j = 3$

Au fur et à mesure que le niveau de décomposition augmente, l'analyse du signal se focalise sur des bandes de fréquences de plus en plus basses, comme le montre la figure 2.7

Une fois le signal décomposé en sous-bandes représentatives de contenus fréquentiels différents, une transformée de Fourier est généralement appliquée pour analyser le contenu spectral des sous bandes [60].

$$\begin{aligned}
 s(t) &= CA_K(t) + \sum_{j=1}^K CD_j(t) \\
 &= \sum_n a_{K,n} \phi(t-n) + \sum_{j=1}^K \sum_n d_{j,n} \psi(2^j t - n)
 \end{aligned} \tag{2.12}$$

En utilisant les filtres d'ondelettes  $h(n)$  et  $g(n)$ , on peut montrer que le signal peut être décomposé de manière récursive en composants basses et hautes fréquences [59, 61] :

$$\begin{cases} a_{m,n} = \sum_k h[k-2n]a_{m-1,n} \\ d_{m,n} = \sum_k g[k-2n]a_{m-1,n} \end{cases} \tag{2.13}$$

Où  $a_{m,n}$  et  $d_{m,n}$  représentent respectivement les coefficients d'approximation et de détail de la décomposition multirésolution, obtenus par la convolution entre le coefficient d'approximation d'ordre précédent ( $a_{m-1,n}$ ) et les coefficients des filtres passe bas et passe haut respectivement.

Divers travaux ont eu recours aux transformées d'ondelettes discrètes. En effet, et en vue de suivre les défauts de moteur à combustion, Wu et al [62] ont établi une classification de ces défauts à base du spectre d'énergie issu des ondelettes discrètes et les réseaux de neurones. Par la suite, Wu [63] a identifié les défauts d'engrenage par combinaison des ondelettes et de la logique floue. Loparo et al. [64], ont utilisé l'écart type des coefficients de la transformée en ondelettes discrète comme vecteurs d'attributs avec un classificateur flou pour diagnostiquer les défauts dans les roulements. S. Prabhakar et al [65] ont montré l'efficacité de la technique DWT par rapport à la technique FFT dans le diagnostic de défaut unique et multiple des roulements. G. Vijay et al [66], ont mené une étude comparative entre la transformée de Fourier rapide (FFT) et la transformée en ondelettes discrète (DWT) pour le diagnostic des défauts de roulements. Ils ont conclu que les valeurs de l'énergie et Kurtosis des coefficients détaillés de la DWT peuvent être utilisés comme indicateurs efficaces pour le diagnostic des défauts de roulements. Par conséquent, la DWT peut être efficacement utilisée pour le diagnostic des défauts des machines tournantes par rapport à la FFT conventionnelle, sans soumettre le signal vibratoire à aucune sorte de prétraitement.

#### 2.5.4.3 Transformation en paquets d'ondelette (WPT)

L'un des principaux inconvénients de la transformée d'ondelettes discrète (DWT), est la perte d'informations importantes aux hautes fréquences, étant donné que les niveaux de détail ( $D_j$ ) ne sont pas décomposés en intervalles de fréquence plus courts. Pour surmonter cet obstacle, et améliorer l'analyse des hautes fréquences, une généralisation de la DWT a été développée, c'est la transformée

en paquets d'ondelette (Wavelet Paquet Transform : WPT), permettant de fournir une décomposition plus fine pour plusieurs bandes de fréquences, en particulier les signaux à haute fréquence, qui peuvent extraire les détails du signal non stationnaire d'origine.

En effet, comme pour la décomposition en ondelettes, il s'agit toujours de décomposer le signal d'origine au moyen d'un filtre passe-bas et d'un filtre passe-haut complémentaires. La différence réside dans le fait que les différents signaux de détails vont également faire l'objet à chaque itération d'une décomposition selon le même principe. L'opération de décomposition est réitérée jusqu'à ce que le niveau de décomposition souhaité soit atteint. Les coefficients d'approximation et de détail générés à chaque niveau sont appelés paquets, qui fournissent des signaux indépendants à une fréquence composée de  $N \cdot 2^{-j}$  coefficients. La figure 2.8 montre la méthode WPT pour la décomposition à 3 niveaux.




Figure 2.8 : Arbre de décomposition en paquets d'ondelettes à trois niveaux.

L'application efficace de la transformée en paquets d'ondelettes (WPT), nécessite l'optimisation de quatre aspects fondamentaux :

1. La sélection d'une ondelette mère appropriée pour un filtrage adéquat du signal.
2. La sélection des niveaux de décomposition qui fournissent les meilleurs paquets aboutissant à l'extraction des caractéristiques statistiques du signal à analyser.
3. La sélection de paramètres pour l'extraction des caractéristiques statistiques qui sont corrélés aux facteurs technologiques analysés.
4. Méthode optimale de sélection des paquets.


Plusieurs applications de la transformée en paquets d'ondelettes ont été déjà réalisées dans le cadre de la détection et du diagnostic de défauts des machines tournantes depuis plus d'une dizaine d'années. A titre d'exemples, Liu et al. [67] ont proposé une méthode basée sur des paquets d'ondelettes, pour le diagnostic des défaillances des roulements à billes. Les coefficients des paquets d'ondelettes ont été utilisés comme caractéristiques typiques, et les résultats montrent qu'ils possèdent une sensibilité élevée aux défaillances. S. Zhang et al [68] et N. G. Nikolaou et al [69] ont développé des techniques de classification des défauts basées sur la transformée en paquets d'ondelettes.

## 2.6 Banc de filtres d'ondelette et representation polyphase

### 2.6.1 Notation polyphase

La notation polyphase a été introduite au milieu des années 70 par M. Bellanger et al. [70] et permet de simplifier la construction et l'analyse des bancs de filtres. Quand un signal subit une décimation d'un facteur 2, cela revient à séparer les échantillons avec un indice pair de ceux avec un indice impair, ou encore, à séparer deux phases distinctes ayant des délais (aussi appelé écarts de phase) différents dans le vecteur.

En considérant le schéma du banc de deux filtres représenté dans la figure 2.9, on voit que le filtrage est classiquement appliqué avant la décimation. Cela signifie donc que le signal est filtré par les deux filtres et que l'on ne garde ensuite qu'une phase parmi les deux de chaque résultat de filtrage. Cette manière de faire la transformation n'est pas efficace car elle entraîne beaucoup de calculs qui ne seront pas exploités par la suite. La notion de représentation polyphase revient à inverser ce schéma en faisant en premier lieu l'opération de décimation (appelée aussi sous-échantillonnage), puis une opération de filtrage.



Figures 2.9 Schéma direct et schéma polyphase d'un banc de filtres d'analyse.

Ainsi, et étant donné qu'il a été montré que la transformée en ondelette discrète (DWT) peut être implémentée au moyen d'un banc de filtres d'ondelette comprenant un filtre passe-bas et un filtre passe-haut dont les réponses impulsionnelles sont respectivement  $h(n)$  et  $g(n)$ . Plusieurs types d'algorithmes ont été proposés pour générer les coefficients de ces filtres. Sherlock et Monro ont proposé une méthode récursive pour la détermination des coefficients des filtres.

Soit un filtre passe bas de réponse impulsionnelle  $h(t)$  finie ou infinie (FIR ou IIR).  $H_0(z)$  sa fonction de transfert dans le domaine  $\mathbb{Z}$  définie comme suit :

$$H_0(z) = \sum_{i=0}^{2N-1} h_i z^{-i} \tag{2.14}$$

Séparant les éléments pairs des éléments impairs, on aura :

$$\begin{aligned} H_0(z) &= \sum_{i=0}^{N-1} h_{2i} z^{-2i} + z^{-1} \sum_{i=0}^{N-1} h_{2i+1} z^{-2i} \\ &= H_{00}(z^2) + z^{-1} H_{01}(z^2) \end{aligned} \tag{2.15}$$

Où

$$H_{00}(z) = \sum_{i=0}^{N-1} h_{2i} z^{-i} \quad (2.16)$$

Et

$$H_{01}(z) = \sum_{i=0}^{N-1} h_{2i+1} z^{-i} \quad (2.17)$$

En remarquant que la transformée en  $z$  d'une convolution se réduit à une multiplication des transformées en  $z$ , la transformée en  $z$  du résultat du filtrage du vecteur  $X$  par le filtre  $h$  s'écrit alors:  $H_0(z) \cdot X(z)$  Si le filtrage est suivi d'une étape de décimation, on ne garde que les puissances paires de  $z$  donc :

$$H_0(z) \cdot X(z)_{pair} = H_{00}(z) \cdot X_0(z) + z^{-1} H_{01}(z) X_1(z) \quad (2.18)$$

La matrice polyphase de  $h$  est alors :

$$H_{poly}(z) = (H_{00}(z), H_{01}(z)) \quad (2.19)$$

En considérant maintenant un banc de deux filtres passe bas et passe haut, notés respectivement  $f$  et  $g$ , de matrices polyphase  $f_{poly}(z)$  et  $g_{poly}(z)$ , la matrice polyphase de ce banc de filtres est :

$$H_{poly}(z) = \begin{pmatrix} f_{poly}(z) \\ g_{poly}(z) \end{pmatrix} = \begin{pmatrix} f_{00}(z) & f_{01}(z) \\ g_{10}(z) & g_{11}(z) \end{pmatrix} \quad (2.20)$$

Où  $f_{00}(z)$  et  $f_{01}(z)$  représentent les composants polyphase du filtre passe bas  $f$ . De même,  $g_{10}(z)$  et  $g_{11}(z)$  représentent les composants polyphase du filtre passe haut  $g$ .

Vaidyanathan a proposé une factorisation de cette matrice polyphase [71] :

$$H_{poly}(z) = \begin{pmatrix} c_0 & s_0 \\ -s_0 & c_0 \end{pmatrix} \prod_{i=1}^{N-1} \begin{pmatrix} 1 & 0 \\ 0 & z^{-1} \end{pmatrix} \begin{pmatrix} c_i & s_i \\ -s_i & c_i \end{pmatrix} \quad (2.21)$$

Où,  $c_i = \cos(\theta_i)$  et  $s_i = \sin(\theta_i)$

Sherlock et al ont développé une nouvelle formulation en réécrivant la factorisation dans une forme récursive :

$$H_p^{(k+1)}(z) = H_p^{(k)}(z) \begin{pmatrix} 1 & 0 \\ 0 & z^{-1} \end{pmatrix} \begin{pmatrix} C_k & S_k \\ -S_k & C_k \end{pmatrix} \quad (2.22)$$

Avec  $k = 1, 2, \dots, N$

Et

$$H_p^{(1)} = \begin{pmatrix} C_0 & S_0 \\ -S_0 & C_0 \end{pmatrix}$$

Le paramètre  $k$  désigne un filtre de longueur  $2k$ . Cette forme conduit à une formulation récursive des coefficients pairs du filtre :

$$\begin{cases} h_0^{(k+1)} &= C_k h_0^{(k)} \\ h_{2i}^{(k+1)} &= C_k h_{2i}^{(k)} - S_k h_{2i-1}^{(k)} \quad i = 1, 2, \dots, k-1 \\ h_{2k}^{(k+1)} &= -S_k h_{2k-1}^{(k)} \end{cases} \quad (2.23)$$

Avec  $h_0^{(1)} = C_0$  et  $h_1^{(1)} = S_0$   $h_0^{(0)} = 1$

Cependant, les coefficients impairs  $\{h_{2i+1}\}$  du filtre passe bas sont définis comme suit :

$$\begin{cases} h_1^{(k+1)} &= S_k h_0^{(k)} \\ h_{2i+1}^{(k+1)} &= S_k h_{2i}^{(k)} + C_k h_{2i-1}^{(k)} \quad i = 1, 2, \dots, k-1 \\ h_{2k+1}^{(k+1)} &= C_k h_{2k-1}^{(k)} \end{cases} \quad (2.24)$$

En conclusion, grâce à cette formulation, on peut générer à travers  $N$  paramètres angulaires, les coefficients d'un filtre passe bas de longueur  $2N$ , ainsi que ceux du filtre passe haut correspondant. Les équations (2.23) et (2.24) déterminent les coefficients du filtre passe bas  $\{h_0, h_1, \dots, h_{2N-1}\}$  en fonction de  $N$  paramètres angulaires  $\{\theta_0, \theta_1, \dots, \theta_{N-1}\}$  prenant des valeurs appartenant à l'intervalle  $[0, 2\pi[$

En procédant à l'inversion et au changement de signes, on peut déterminer les coefficients du filtre passe haut de la façon suivante :

$$g_i = (-1)^{i+1} h_{2N-1-i} \quad (2.25)$$

Par conséquent, la conception d'une transformation d'ondelette discrète DWT, peut être considérée comme un problème d'optimisation dans l'espace  $\mathcal{R}^N$  des paramètres angulaires  $\theta_i$

## 2.7 Conclusion

Ce chapitre a été dédié à la présentation de l'état de l'art des différentes méthodes les plus largement utilisées dans le domaine de la surveillance et du diagnostic des défauts des machines tournantes.

Ces méthodes ont été scindées en deux grandes familles : celles qui utilisent un modèle mathématique du système à surveiller, appelées les méthodes internes, et celles qui consistent à analyser les signaux mesurés, issus de ces systèmes, appelées les méthodes externes. Après avoir rappelé les différentes techniques issues des méthodes internes et externes, nous avons présenté un état de l'art des différents outils de traitement de signal les plus fréquemment appliqués pour l'analyse vibratoire. Parmi ces outils, nous avons développé l'analyse temporelle, l'analyse spectrale, l'analyse temps-fréquence, et enfin, avec plus de détails l'analyse temps-échelle (transformation en ondelette).

Enfin, et vu que la transformée en ondelettes discrète (DWT) peut être implémentée au moyen d'un banc de filtres d'ondelette composé d'un filtre passe-bas et d'un filtre passe-haut, plusieurs types d'algorithmes ont été alors proposés pour générer les coefficients de ces filtres.



Pour cela, nous avons choisi de détailler la représentation polyphase des bancs de filtres d'ondelettes initiée par Vaidyanathan, ainsi que la méthode récursive proposée par Sherlock et Monro pour générer les différents coefficients des filtres d'ondelette. Cette méthode permet de générer les coefficients d'un filtre passe bas  $\{h_0, h_1, \dots, h_{2N-1}\}$  de longueur  $2N$ , ainsi que ceux du filtre passe haut correspondant à travers seulement  $N$  paramètres angulaires  $\{\theta_0, \theta_1, \dots, \theta_{N-1}\}$  prenant des valeurs appartenant à l'intervalle  $[0, 2\pi[$ . En conséquence, et au lieu d'utiliser une ondelette standard (Daubechies, Morlet, Symlet, Coiflet, ..., etc.), pour l'analyse des signaux vibratoires, notre contribution consiste en la conception d'une ondelette discrète dont les coefficients de ses filtres sont générés en se basant sur cette méthode.

## CHAPITRE III

# METHODES DE RECONNAISSANCE DE FORMES DANS LE CADRE DE DIAGNOSTIC DES MACHINES TOURNANTES

Un pessimiste voit la difficulté dans chaque opportunité,  
un optimiste voit l'opportunité dans chaque difficulté.

**Winston Churchill.**

## **Chapitre III : METHODES DE RECONNAISSANCE DES FORMES DANS LE CADRE DE DIAGNOSTIC DES MACHINES TOURNANTES**

### **3.1. Introduction**

Ces dernières décennies les systèmes industriels sont devenus de plus en plus complexes, et assujettis à des conditions de fonctionnement difficiles et non stationnaires. Pour cela, la technicité de supervision de ces systèmes exige que les outils d'analyse et de diagnostic soient adaptés, et performants permettant d'éviter les situations néfastes et catastrophiques sur le plan économique, humain et environnemental. Il s'avère que les méthodes classiques (exposées dans le chapitre précédent), utilisées dans la surveillance et le diagnostic des défauts de ces systèmes industriels présentent encore des limitations. De ce fait, il est primordial d'aller vers des nouvelles techniques efficaces de supervision [72], qui permettent d'établir des diagnostics fiables quand c'est difficile autrement, et sans l'intervention d'un expert.

Les méthodes de reconnaissance de formes (RdF) furent des solutions acclamées dans la littérature de diagnostic de par leur autonomie, leur fiabilité, leur facilité d'interprétation...etc.

Dans ce chapitre, nous allons développer les méthodes de reconnaissance des formes, leurs applications, leurs avantages et inconvénients, et des exemples pertinents de leurs mises en œuvre dans le diagnostic des machines tournantes.

### **3.2. Présentation générale**

La reconnaissance de formes a été considérée comme une discipline du domaine de l'intelligence artificielle ayant pour objectif de concevoir des systèmes qui possèdent la capacité d'apprendre, d'examiner, de décider, mais aussi d'interagir avec le monde réel, et de reconnaître les objets et les différentes formes. Cette technique est depuis son apparition, n'a pas cessé d'évoluer et de couvrir de nombreux domaines d'applications tels que la reconnaissance vocale [73], la reconnaissance de visages humains [74], des mots manuscrits, le diagnostic des machines industrielles, le diagnostic médical, la classification de documents, etc.

En effet, à partir d'un ensemble de données ou d'informations apprises, la reconnaissance des formes offre la possibilité d'interpréter toute nouvelle observation (ou forme). Les observations déjà connues sont regroupées en classes, constituant des formes types (prototypes) auxquels la nouvelle observation est comparée pour être classifiée. Ces prototypes sont des points représentatifs de l'espace appelé espace de représentation. Néanmoins, et à cause des perturbations (bruit de mesure, précision des capteurs...), la nouvelle observation sera rarement identique à l'un des prototypes. Ainsi, afin de traduire l'influence du bruit, les classes correspondent à des zones dans l'espace, regroupant les formes semblables. Ces formes ou objets sont généralement caractérisés par un vecteur appelé vecteur forme. Si l'on se place dans le contexte du diagnostic des machines industrielles, les paramètres du vecteur forme traduisent l'état du système étudié. Ils sont issus d'analyses effectuées sur les signaux mesurés par les capteurs implantés sur le système. Quant aux

différentes classes, elles correspondent aux modes de fonctionnement (sain ou avec défauts) connus des machines.

Parmi les approches de reconnaissance des formes (RdF) les plus reconnues, on peut citer : La comparaison à des motifs ou à des modèles [75], l'approche statistique [76], l'approche syntaxique ou structurelle [77].

Bien qu'on puisse trouver la majorité de ces approches employées dans le diagnostic des machines tournantes, l'approche de reconnaissance des formes du type "statistique" est celle qui offre le meilleur compromis facilité et utilité. Par conséquent, elle sera adoptée dans notre étude.

### 3.3. Principales étapes d'un système de reconnaissance des formes

Généralement, un système de reconnaissance des formes est constitué de plusieurs étapes séquentielles, destinée chacune à réaliser une tâche bien définie. Les différentes étapes sont détaillées ci-après :

#### 3.3.1. Acquisition des données

Cette première étape du processus de reconnaissance de formes consiste à transformer l'objet à reconnaître d'une forme réelle ou dite physique en une forme numérique adaptée au système de traitement utilisé. Cela peut être réalisé par une caméra ou un scanner dans une application de vision ou un microphone pour la parole ou le son. Dans le cas du diagnostic des machines tournantes, cette opération est réalisée à travers des capteurs implantés sur la machine, permettant de convertir des grandeurs physiques ou mécaniques produites par la machine en grandeurs électriques numériques ou analogiques mesurables. En littérature, beaucoup de sources d'information peuvent être utilisées. Plusieurs d'entre elles ont été présentées dans le premier chapitre. Bien que ces différentes sources d'information ont prouvé leur efficacité, l'analyse des signaux vibratoires reste la source d'information la plus utilisée pour la surveillance des états de fonctionnement des machines tournantes. Aussi, un choix judicieux de la chaîne de mesure consiste une étape cruciale pour l'acquisition des signaux vibratoires à étudier. Pour cela, le matériel composant cette étape d'acquisition doit être performant, et en adéquation avec les caractéristiques vibratoires fournies par les machines tournantes. En outre, la procédure d'acquisition doit être effectuée et contrôlée de façon à garantir que toutes les données soient collectées de manière identique et qu'il n'existe pas de dérive. Néanmoins, ces données acquises ne sont pas toutes aussi informatives. Elles peuvent correspondre à un bruit, peuvent être peu significatives, corrélées ou redondantes, aberrantes ou simplement inexploitable. Pour cela, ces données requièrent un prétraitement pour qu'elles soient exploitables.

#### 3.3.2. Prétraitement

Le prétraitement est une étape importante dans le processus de reconnaissance des formes. Selon le domaine d'application à traiter, des techniques inspirées du traitement du signal, ont été souvent employées pour le prétraitement des données recueillies des capteurs, comme par exemple le débruitage [78], le filtrage [79], le lissage [80], la normalisation [81], et le sous-échantillonnage [82].

L'essentiel, c'est de pouvoir préparer cette base de données à l'étape suivante qui consiste à extraire des caractéristiques représentatives ou descriptives.

### 3.3.3. Extraction des caractéristiques

Cette étape consiste à construire le vecteur forme, c'est-à-dire, sélectionner les  $d$  paramètres à extraire à partir des signaux ayant déjà subi un prétraitement. Les performances d'un système de diagnostic basé sur la reconnaissance des formes dépendront étroitement de la pertinence des  $d$  paramètres calculés. Il est donc préférable de disposer de paramètres robustes, insensibles au bruit, variant de manière significative en fonction des différents états de fonctionnement de la machine. En outre, ces paramètres doivent être choisis de telle sorte qu'ils soient informatifs, permettant de mieux discriminer les différents états de fonctionnement de la machine (état normal ou défaillant) et de bien séparer les classes qui les représentent.

Ainsi, chaque observation effectuée à un instant donné sur la machine sera caractérisée par un vecteur forme qui détermine la signature propre de cette observation. En pratique, il n'existe pas d'outils algorithmiques qui permettent de régler le choix de ce vecteur forme, seule la connaissance a priori que l'on a de la machine, permet de retenir les paramètres les plus pertinents. C'est pour cette raison que l'intervention d'un expert du processus à surveiller est souvent très utile pour orienter cette procédure. Dans le domaine du diagnostic des machines, par analyse vibratoire, un nombre assez important de paramètres peut être extrait, soit directement à partir du signal temporel (débruité ou non), soit via différentes méthodes de transformation et de traitement de signal. Parmi les paramètres les plus utilisés on peut citer le nombre de pics présents dans un signal, l'écart type des données, la moyenne quadratique (RMS), la valeur maximale ou minimale [83], le coefficient d'aplatissement (Kurtosis) [84], etc. Quant aux méthodes de transformation et de traitement de signal utilisées (décrits précédemment dans le § 2.5), on peut citer l'analyse temporelle, la transformée de Fourier, les méthodes Temps-Fréquence, les transformations en ondelettes [85], ..., etc.

Cependant, le nombre souvent élevé de paramètres du vecteur forme peut être pénalisant en terme de temps de calcul, et de capacité de mémoire de stockage. De plus tous les paramètres calculés ne seront pas forcément pertinents vis à vis des modes étudiés. Des méthodes de réduction de paramètres doivent donc être mises au point afin de ne conserver que les paramètres les plus représentatifs. C'est l'objectif de la prochaine étape de la procédure de RdF.

### 3.3.4. Réduction de l'espace de représentation

Etant donné que parmi les  $d$  paramètres constituant le vecteur forme, il peut y avoir des paramètres qui sont peu informatifs, corrélés ou même redondants. Réduire l'espace de représentation revient à déterminer les  $d'$  ( $d' < d$ ) paramètres du vecteur forme les plus pertinents et les plus représentatifs pour la reconnaissance, afin de diminuer la capacité de mémoire de stockage, de réduire le temps de décision relatif au classement d'une nouvelle observation d'une part, et d'améliorer les performances de classification d'autre part. L'opération de réduction de l'espace de représentation peut être réalisée soit par des méthodes d'extraction de paramètres [77], soit par des méthodes de sélection de paramètres [86].

### 3.3.5. Règles de décision

Une fois le vecteur d'entrée construit, l'étape suivante dans le cadre d'une procédure de diagnostic, est la construction des règles de décision. Ceci peut être fait via l'utilisation des outils de classification offerts par l'intelligence artificielle et la fouille de données « Data Mining ». Parmi les outils de classification les plus populaires on trouve, les systèmes experts, les réseaux de neurones artificiels (ANN), les machines à vecteurs de support (SVM), les classifieurs basés sur la logique floue tels que K plus proche voisins (KNN), K plus proche voisins Floue (F-KNN), ..., etc [87].

Dans ce qui suit, une description approfondie de quelques règles de décision (classifieurs) qui sont utilisées dans notre travail de thèse, sera présentée.

## 3.4. Différents types de classifieurs

### 3.4.1. Les Réseaux de Neurones Artificiels (Artificial Neural Network : ANN)

Parmi les méthodes les plus connues offertes par l'intelligence artificielle (Artificial Intelligence : AI), on trouve la méthode des réseaux de neurones artificiels (ANN). Cette technique connue sous des noms très différents (réseaux neuromimétiques, modèles connexionnistes, réseaux de neurones formels, réseaux d'automates cellulaires etc.), fait l'objet de recherches dans beaucoup de domaines tels que la compréhension et la synthétisation de la langue naturelle, la classification, le diagnostic, etc. L'origine de l'inspiration de la méthode des ANNs, remonte à 1890 où W. James, célèbre psychologue américain, a introduit le concept de mémoire associative. Il propose ce qui deviendra une loi de fonctionnement pour l'apprentissage des réseaux de neurones, connue plus tard sous le nom de loi de Hebb. Quelques années plus tard, soit, en 1943, deux neurologues Warren Sturgis McCulloch et Walter Pitts [88], ont été les premiers à procéder à la modélisation d'un neurone biologique communément appelé neurone formel. Ils ont également montré que théoriquement, les réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques complexes. En 1969 Rosenblatt propose le premier algorithme d'apprentissage, qui permet d'ajuster les paramètres d'un neurone. En 1982, Hopfield propose des réseaux de neurones associatifs et l'intérêt pour les réseaux de neurones renaît chez les scientifiques [89]. En 1986, Rumelhart, Hinton et Williams publient, l'algorithme de la rétropropagation de l'erreur qui permet d'optimiser les paramètres d'un réseau de neurones à plusieurs couches.

À partir de ce moment, la recherche sur les réseaux de neurones connaît un essor fulgurant et les applications commerciales de ce succès académique suivent au cours des années 90.

Le principe d'un neurone artificiel est montré dans la figure 3.1




Figure 3.1 Modèle d'un neurone artificiel

Les entrées du neurone sont désignées par  $x_i$  ( $i = 1, 2, \dots, n$ ). Chaque entrée est pondérée par un poids propre  $w_i$  que l'on nomme poids synaptique (en référence aux synapses du neurone biologique). Le neurone effectue la somme de toutes ces entrées pondérées selon l'équation donnée ci-après :

$$S = \sum_{i=1}^n w_i x_i \quad (3.1)$$

Cette somme  $S$  représente l'état interne du neurone. Elle est transmise à une fonction de transfert nommée fonction d'activation  $h$ . La sortie de cette fonction donne la sortie générale du neurone  $y$ . Le fonctionnement du neurone peut donc simplement s'écrire sous la forme de l'équation 3.2.

$$y = h \left( \sum_{i=1}^n w_i x_i \right) \quad (3.2)$$

Dans la littérature, différentes fonctions d'activation ont été développées [90], mais les plus largement utilisées sont : la fonction signe, la fonction linéaire saturée, la fonction sigmoïde, et la fonction gaussienne. La mise en relation de plusieurs neurones donne ainsi naissance à un réseau de neurones. Ce réseau est en général constitué d'une succession de couches dont chacune prend ses entrées sur la sortie de la précédente. Chaque couche ( $i$ ) est composée de  $N_i$  neurones prenant leur entrée sur les  $N_{i-1}$  neurones de la couche précédente. Cependant, aucune connexion n'est établie entre les neurones d'une même couche.

Ainsi, les différentes couches constituant un réseau de neurones sont définies comme suit :

- Une couche d'entrée qui reçoit les informations provenant de l'extérieur. Les neurones de cette couche sont d'un type particulier, car ils se contentent de transmettre l'information qui leur est présentée sans aucun traitement.
- Une ou plusieurs couches intermédiaires, encore appelées couches cachées car elles ne sont pas directement en contact avec le monde extérieur.
- Une couche de sortie, destinée à fournir un signal (ou plusieurs) de sortie.

Pour un système à diagnostiquer, bien que le nombre de neurones de la couche d'entrée et de sortie soit imposé par le nombre d'entrées du système (pour la couche d'entrée), ainsi que par la codification des différentes classes de défauts (pour la couche de sortie). Aucune règle mathématique au sens strict ne permet de déterminer le nombre de couches cachées à retenir, ni le nombre de neurones à fixer pour chacune de ces couches. Ce choix est spécifique à chaque application et, à ce jour, ce ne sont que des choix arbitraires dont on vérifie par la suite la validité. Une fois l'architecture ou la topologie du réseau (y compris le nombre de nœuds dans les couches cachées, les connexions réseau, les attributions de poids initiales et les fonctions d'activation) est élaborée, l'étape suivante, consiste à choisir un processus d'apprentissage, par lequel les poids synaptiques ainsi que les biais dans l'ensemble du réseau vont être ajustés de manière à satisfaire un critère d'optimisation, et par conséquent atteindre la réponse souhaitée.

Pour les réseaux de neurones artificiels, les deux modes d'apprentissage : supervisé et non supervisé peuvent être employés :

### 3.4.1.1. Les types d'apprentissage

#### 3.4.1.1.1. L'apprentissage supervisé

Ce mode d'apprentissage ne peut être utilisé que lorsque les combinaisons d'entrées sorties désirées sont connues. On présente au réseau des entrées bien identifiées, et auxquels on associe des sorties désirées. Au départ, les poids synaptiques  $w_i$  sont initialisés aléatoirement. Lorsque l'on présente un vecteur d'entrée au réseau, ce dernier doit se reconfigurer, c'est-à-dire ajuster ses poids synaptiques afin que la sortie qu'il donne corresponde bien à la sortie désirée. Cet ajustement est effectué sur la base de la minimisation d'un critère d'erreur entre la sortie calculée, et la réponse désirée. Un critère d'arrêt est souvent imposé, indiquant quand est ce que le processus d'apprentissage doit s'arrêter. Il peut s'agir d'une limite prédéterminée d'erreur absolue, d'une erreur quadratique moyenne (Mean Square Error : MSE) ou simplement d'un nombre maximal d'itérations du processus d'apprentissage. Parmi les algorithmes les plus connus pour ce type de tâche, l'algorithme de rétropropagation du gradient [91, 92]. Cet algorithme calcule une erreur quadratique telle que donnée dans l'équation (3.3) entre la sortie calculée par le Réseau de neurones artificiels (ANN) (au vu des entrées)  $y_i$  et la réponse  $k_i$  attendue pour le jeu d'entrées donné.

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - k_i)^2 \quad (3.3)$$



## Chapitre III : Méthodes de reconnaissance des formes dans le cadre de diagnostic des machines tournantes

---

L'algorithme procède à la propagation de cette erreur en sens inverse vers l'avant dernière couche, en ventilant l'erreur en fonction de l'importance des connexions, permettant un ajustement des poids par une méthode du gradient. Il faut préciser que l'algorithme de rétropropagation du gradient demande un nombre d'exemples d'apprentissage conséquent afin de trouver des frontières de classification correctes.

### 3.4.1.1.2. L'apprentissage non supervisé

Ce type d'apprentissage est choisit lorsqu'il n'y a pas de connaissance à priori des sorties désirés pour des entrées données. En fait, c'est de l'apprentissage par exploration où l'algorithme d'apprentissage ajuste les poids des liens entre neurones de façon à maximiser la qualité de classification des entrées.

### 3.4.1.2. Les types de Réseaux de Neurones

Dans la littérature, de nombreuses variantes de réseaux de neurones ont été développées en fonction de leur domaine d'application [93]. Parmi les réseaux de neurones les plus connus, et les plus utilisés dans le domaine du diagnostic des machines tournantes, on peut citer :

- Perceptron multicouches (en anglais : Multi Layer Perceptron : MLP) [94].
- Réseaux de neurones à fonction de base radiale (RBF) [95].

### 3.4.1.3. Domaines d'applications

Etant donné les multiples avantages de cette approche, tels que leur capacité à résoudre des problèmes non linéaires et multi-variables, leur faculté d'apprentissage, leur faible sensibilité aux bruits de mesures, ainsi que leur mémorisation d'un grand volume d'informations. Cette méthode a trouvé son application dans divers domaines, citons la classification, la reconnaissance des formes, l'identification et la commande de processus.

En effet, R. Dubois [96], a proposé une stratégie de lecture automatique du signal électrique représentative de l'électrocardiogramme (ECG). Par techniques neuronales (le RBF et le MLP), il procède à la classification des signatures d'ECG suivant des classes de pathologies cardiaques typiques. Kumar et al [97], ont choisi d'utiliser le réseau de neurones de type perceptron multicouches (MLP) à des fins de classification des caractéristiques vibratoires d'un roulement en trois classes : roulement sain, défaut bague intérieure, défaut bague extérieure. Le réseau de neurones a été testé avec trois types d'algorithme d'apprentissage : trainrp (Resilient back propagation algorithm), trainscg (Scaled conjugate gradient algorithm) et trainlm (Levenberg-Marquardt algorithm).

### 3.4.2. Machine à vecteurs de support (SVM)

#### 3.4.2.1. Introduction

La méthode SVM (Support Vector Machines) ou Machines à Vecteurs Support, connue également sous le nom de séparateurs à vaste marge, est définie comme étant un algorithme d'apprentissage supervisé capable de résoudre des problèmes de classification linéaires et non linéaires [98]. Initialement introduites par Vapnik-Chervonenkis en 1995 [99], les SVMs se sont révélés remarquablement efficaces dans de nombreuses applications telles que la reconnaissance de formes, le traitement des images, le diagnostic de défauts de machines, etc. [100]. En outre, des études comparatives ont montré que les SVMs sont très efficaces quand on ne dispose que de peu de données d'entraînement, et qu'ils possèdent une bonne capacité de généralisation par rapport à d'autres classifieurs tels que les réseaux de neurones artificiels (ANN) [101]. Cependant, quand les données sont trop nombreuses, les SVMs ont tendance à baisser en performance.

#### 3.4.2.2. Principe de fonctionnement

Etant donné un ensemble de données d'apprentissage avec deux classes, le principe de base de ce type de classifieur binaire (qui ne peut différencier que deux classes d'individus), est de placer une frontière linéaire  $H$  (appelée aussi hyperplan) entre les deux classes, et de l'orienter de telle sorte que la distance entre cette frontière et les points de données les plus proches dans chaque classe est maximale (c'est la période d'entraînement, nécessaire à tout algorithme d'apprentissage automatique).  $H_1$  et  $H_2$  étant les plans parallèles de  $H$  qui passent respectivement par ces points de données les plus proches des différentes classes. Ces deux plans parallèles  $H_1$  et  $H_2$  sont appelés les **Vecteurs Supports**. La distance entre ces Vecteurs Supports définit ainsi **la marge**.

La figure (3.2) donne un exemple du principe de fonctionnement d'un classifieur SVM.

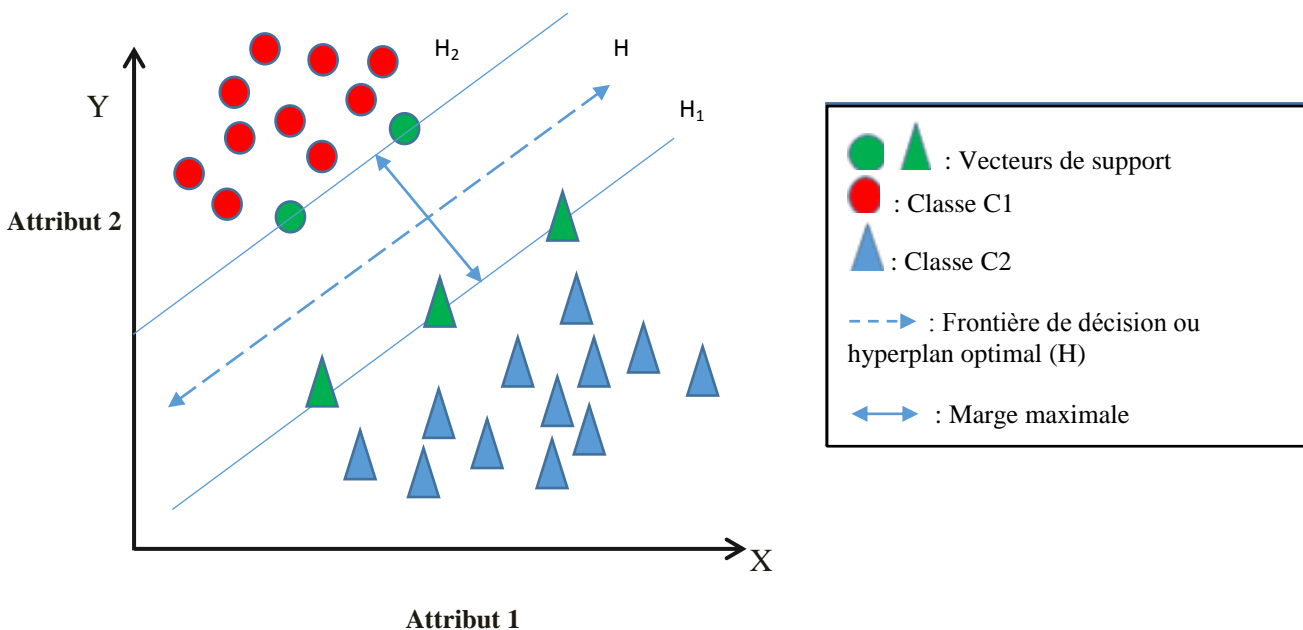


Figure 3.2 Principe de fonctionnement de la méthode SVM

Le but du classifieur SVM, est de chercher parmi une multitude d'hyperplans valides (figure 3.3), l'hyperplan optimal qui maximise la distance, ou la marge, entre les points de deux classes et cet hyperplan. C'est pourquoi l'on parle aussi de séparateurs à vaste marge [102].




Figure 3.3 Différentes frontières possibles d'un SVM

Mais, on se rend bien compte que ce type de technique ne peut réellement traiter qu'un nombre de problèmes restreint puisqu'il faut que les classes puissent être séparables par un hyperplan. Or, dans un grand nombre de problèmes concrets, ce n'est pas le cas. Nous distinguons donc deux types de problèmes pour les SVMs : les cas de classifications linéairement séparables, et les cas non-linéairement séparables (figure 3.4).




Figure 3.4 Illustrations de cas linéairement séparable et non-linéairement séparable

Pour les cas où les données sont linéairement séparables, la classification peut être résolue par un séparateur à vaste marge. Mais, pour les cas non-linéaires, SVM a introduit la notion de fonction noyau « Kernel Function » permettant de projeter les données de l'espace initial (où les données sont non-linéairement séparables) vers un nouvel espace, généralement de dimension plus élevée, dans lequel les projections des données sont linéairement séparables [90], [103].

En pratique, quelques familles de fonctions noyau paramétrables sont connues et il revient à l'utilisateur des SVMs d'effectuer des tests pour déterminer celle qui convient le mieux pour son application [90]. On peut citer les exemples de noyaux suivants :

- Le noyau linéaire :  $K(x_i, x_j) = x_i \cdot x_j$  (3.4)

- Le noyau polynomial :  $K(x_i, x_j) = (x_i \cdot x_j + 1)^q$  (3.5)

- Le noyau gaussien :  $K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{2 \cdot \delta^2}\right)$  (3.6)

- Le noyau sigmoïde :  $K(x_i, x_j) = \tanh(x_i \cdot x_j + \theta)$  (3.7)

Supposons maintenant que nous avons  $N$  échantillons d'apprentissage,  $x_i \in \mathfrak{R}^d$ , ( $i = 1, 2, \dots, N$ ) de l'espace des caractéristiques à  $d$  dimensions. Le classifieur SVM attribue à chaque échantillon des données d'apprentissage l'une des deux possibilités  $+1$  ou  $-1$ , il s'agit de la classe  $y_i \in \{-1, +1\}$ . De ce fait, nous pouvons écrire les données d'apprentissage sous la forme suivante :

$$(x_i, y_i), \text{ où } i = 1, 2, \dots, N; y_i \in \{-1, +1\}; x_i \in \mathfrak{R}^d$$

Admettons maintenant que les données soient linéairement séparables, c'est-à-dire que nous pouvons tracer une ligne droite qui sépare les deux classes  $x_1$  et  $x_2$  (pour  $d = 2$ ), le cas bidimensionnel est illustré sur la figure 3.5 et un hyperplan sur le graphique de  $x_1, x_2, \dots, x_d$  (pour  $d > 2$ ). Les points qui se trouvent sur l'hyperplan  $H$  de séparation satisfont l'équation suivante :

$$w \cdot x + b = 0; \quad w \in \mathfrak{R}^d, \quad b \in \mathfrak{R} \quad (3.8)$$

Où  $w$  désigne le vecteur poids de l'hyperplan  $H$  et  $b$  est un scalaire appelé biais.

Les points situés au-dessus et au-dessous de l'hyperplan  $H$  satisfont respectivement les inégalités suivantes :

$$x_i \cdot w + b \geq +1 \quad \text{pour } y_i = +1 \quad (3.9)$$

$$x_i \cdot w + b \leq -1 \quad \text{pour } y_i = -1 \quad (3.10)$$

Les équations (3.9) et (3.10) peuvent être combinées en une seule équation :

$$y_i(x_i \cdot w + b) - 1 \geq 0; \quad i = 1, 2, \dots, N \quad (3.11)$$

Maintenant, si nous considérons uniquement les points qui appartiennent aux hyperplans  $H_1$  et  $H_2$ , ces points satisfont aux équations suivantes :

$$x_i \cdot w + b = +1; \quad \text{pour } H_1 \quad (3.12)$$

$$x_i \cdot w + b = -1; \quad \text{pour } H_2 \quad (3.13)$$

Les points d'apprentissage qui satisfont aux équations (3.12) et (3.13), montrés sur la figure 3.2 (colorés en vert), sont appelés vecteurs de support. Ces points d'apprentissage représentent les points les plus proches de la surface de décision et sont donc les échantillons les plus difficiles à classer. Ces points jouent un rôle important dans la détermination de l'hyperplan de séparation optimal.

#### 3.4.2.2.1. Calcul de la marge

Si l'on prend un point  $x_i \in \mathbb{R}^d$ , on peut prouver que sa distance à l'hyperplan de vecteur support  $w$  et de biais  $b$  est donnée par :

$$\frac{y_i(x_i \cdot w + b)}{\|w\|} \quad (3.14)$$

Où  $\|w\|$  désigne la norme euclidienne de  $w$ .

La marge d'un hyperplan de paramètres  $(w, b)$  par rapport à un ensemble de points  $x_i$  est donnée par :

$$\min_i \frac{y_i(x_i \cdot w + b)}{\|w\|} \quad (3.15)$$

Pour rappel, la marge est la distance minimale de l'hyperplan à un des points d'apprentissage.

#### 3.4.2.2.2. Maximisation de la marge

Une fois la marge est déterminée, on veut trouver l'hyperplan de support  $w$  et de biais  $b$  qui permettent de maximiser cette marge, c'est-à-dire qu'on veut trouver un hyperplan avec la plus grande marge possible. Ceci revient à chercher l'unique hyperplan dont les paramètres  $(w, b)$  sont donnés par la formule :

$$\text{Arg max}_{w,b} \min_i \frac{y_i(x_i \cdot w + b)}{\|w\|} \quad (3.16)$$

Ainsi, même si on peut montrer que l'hyperplan optimal  $H$  est unique, il existe plusieurs couples  $(w, b)$  qui décrivent ce même hyperplan. En effet, tout couple de paramètres  $(\alpha w, \alpha b)$ , pour tout réel non nul  $\alpha$ , peut également décrire ce même hyperplan optimal  $H$ . Cependant, on va se limiter à ne considérer que l'unique paramétrage  $(w, b)$  tel que les vecteurs supports  $x_s$  vérifient l'équation :

$$y_s(x_s \cdot w + b) = 1 \quad (3.17)$$

## Chapitre III : Méthodes de reconnaissance des formes dans le cadre de diagnostic des machines tournantes

---

Par conséquent,  $\forall i, y_i(x_i \cdot w + b) \geq 1$ , et l'égalité est atteinte si  $x_i$  est un vecteur support. Autrement dit, cette normalisation sur  $w$  et  $b$  permet de garantir que la marge  $\min_i \frac{y_i(x_i \cdot w + b)}{\|w\|}$  est alors de  $\frac{1}{\|w\|}$ . Le problème d'optimisation de la marge  $\text{Arg max}_{w,b} \min_i \frac{y_i(x_i \cdot w + b)}{\|w\|}$  se simplifie ainsi en  $\text{Arg max}_{w,b} \frac{1}{\|w\|}$  tout en gardant en tête les hypothèses de normalisation, à savoir :

$\forall i, y_i(x_i \cdot w + b) \geq 1$ . On se retrouve donc avec le problème suivant :

$$\begin{cases} \text{Maximiser} & \frac{1}{\|w\|} \\ \text{Sous les contraintes} & y_i(x_i \cdot w + b) \geq 1 \quad i = 1, 2, \dots, N \end{cases} \quad (3.18)$$

Que l'on peut reformuler de la façon suivante :

$$\begin{cases} \text{Minimiser} & \|w\| \\ \text{Sous les contraintes} & y_i(x_i \cdot w + b) \geq 1 \quad i = 1, 2, \dots, N \end{cases} \quad (3.19)$$

Que, pour des raisons pratiques, on reformule à nouveau :

$$\begin{cases} \text{Minimiser} & \frac{\|w\|^2}{2} \\ \text{Sous les contraintes} & y_i(x_i \cdot w + b) \geq 1 \quad i = 1, 2, \dots, N \end{cases} \quad (3.20)$$

Cette dernière écriture est plus appropriée pour l'optimisation en utilisant la programmation quadratique (Quadratic Programming : QP). Parmi les diverses méthodes utilisées pour résoudre ce problème d'optimisation, on peut utiliser la méthode des multiplicateurs de Lagrange qui conduit à :

$$J(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^N \alpha_i [y_i(w \cdot x_i + b) - 1] \quad (3.21)$$

On détermine les valeurs de  $w$  et  $b$  de façon que l'équation (3.21) soit minimisée. Ceci est réalisé comme suit :

$$\frac{\partial J(w, b, \alpha)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^N \alpha_i y_i x_i \quad (3.22)$$

$$\frac{\partial J(w, b, \alpha)}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.23)$$

La substitution des équations (3.22) et (3.23) dans l'équation (3.21), conduira à une nouvelle fonction objective en fonction de  $\alpha$ .

$$\begin{cases} \text{Maximiser } Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i \cdot x_j \\ \text{Sous les contraintes } \sum_{i=1}^N \alpha_i y_i = 0 \text{ et } \alpha_i \geq 0 \quad i = 1, 2, \dots, N \end{cases} \quad (3.24)$$

Où  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_i)$  sont les multiplicateurs de Lagrange.

Pour résoudre l'équation (3.24), la programmation quadratique est utilisée pour déterminer les multiplicateurs de Lagrange optimaux  $\alpha_i$ . Supposons que  $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)$  est la solution optimale, alors le vecteur de poids de l'hyperplan à marge maximale recherché s'écrit :

$$w^* = \sum_{i=1}^N \alpha_i^* y_i x_i \quad (3.25)$$

Pour calculer la valeur du paramètre biais  $b$ , nous choisissons un parmi les vecteurs de support et par substitution dans l'une des équations (3.12) ou (3.13), cela dépend de la classe à laquelle appartient le vecteur de support, nous obtenons la valeur du biais  $b$  selon l'équation suivante :

$$b^* = 1 - w^* \cdot x_i \quad (3.26)$$

Maintenant, nous avons déterminé l'hyperplan de séparation optimal ( $w^*$  et  $b^*$ ). Il est évident d'après les étapes ci-dessus que les multiplicateurs de Lagrange ne sont que des paramètres intermédiaires. L'étape d'apprentissage est ainsi achevée, et notre classifieur SVM est maintenant capable de prédire à quelle classe appartient une entrée  $x$  qu'il n'avait jamais vue avant (donnée de l'ensemble test), et sans intervention humaine : c'est là tout l'intérêt de l'apprentissage automatique.

La tâche de classification est effectuée en utilisant la fonction décision suivante :

$$f(x) = \text{Sgn} \left( \sum_{j=1}^N \alpha_j^* \cdot y_j \cdot x_j \cdot x + b^* \right) \quad (3.27)$$

$\text{Sgn}$  : représente la fonction signe bipolaire

Si l'équation (3.27) est supérieure à zéro, alors la classe «+1» est affectée à l'entrée  $x$  considérée, sinon, la classe «-1». En d'autres termes, nous déterminons de quel côté de l'hyperplan (surface de décision) se trouve l'entrée  $x$  de test.

### 3.4.2.3. Systèmes multiclassés

L'approche SVM est initialement définie pour les problèmes de classification à deux classes. Cependant, la plupart des problèmes ne se contentent pas de deux classes de données, à titre d'exemple, le diagnostic des défauts de machines. Pour cela, en littérature, il existe plusieurs méthodes pour faire la classification multiclassés [104]. Les deux stratégies les plus utilisées sont les suivantes :

#### 3.4.2.3.1. Un-contre-Un (One-Against-One: OAO)

Cette méthode consiste à utiliser un classifieur par couple de catégories (classes). Le classifieur indicé par le couple  $(k, l)$  (avec  $1 \leq k < l \leq N$ ), est destiné à distinguer la catégorie d'indice  $k$  de celle d'indice  $l$ . Pour affecter une donnée, on la présente donc à  $N(N-1)/2$  classifieurs ( $N$  : représente le nombre de classes), et la décision s'obtient habituellement en effectuant un vote majoritaire « Max-wins voting » [105].

#### 3.4.2.3.2. Un-contre-Tous (One-Against-All: OAA)

Cette approche est la plus simple et la plus ancienne des méthodes de décomposition. Elle consiste à utiliser un classifieur binaire (à valeurs réelles) par classe. Le  $k^{\text{ième}}$  classifieur est destiné à distinguer la classe d'indice  $k$  de toutes les autres. Pour affecter une donnée, on la présente donc à  $N$  classifieurs ( $N$  : représente le nombre de classes), et la décision s'obtient en application du principe « Winner-takes-all » : l'étiquette retenue est celle associée au classifieur ayant renvoyé la valeur la plus élevée [106].

#### 3.4.2.4. Domaines d'applications

Bien que c'est une méthode relativement très récente, la SVM a été développée avec succès ces dernières années, et a montré son efficacité dans de nombreux domaines d'applications tels que le traitement d'image, la catégorisation de textes, diagnostic des défauts des systèmes mécaniques, ...etc. Aussi, plusieurs variantes de SVM ont été développées surtout dans le domaine du diagnostic des machines tournantes. A titre d'exemples, Konar et al [107] ont utilisé la transformée en ondelettes et la SVM pour détecter les défauts de palier dans les moteurs à induction. Zhang [108] a utilisé une variante de SVM appelée « Particle Swarm Optimization for SVM » (SVM - PSO) ou Optimisation par essais particuliers pour le SVM », qui représente une version de SVM avec une fonction noyau de type « Radial Basis Function (RBF) ». Dans ce travail, la SVM-PSO a été employée après l'extraction et la sélection des indicateurs de défauts. Des signaux vibratoires pour un roulement en différents états de fonctionnement ont été choisis pour servir d'ensemble d'apprentissage de la méthode. Enfin, Cheng, et al [109], ont proposé une décomposition en valeurs singulières et une SVM basée sur l'EMD (Empirical Mode Decomposition) pour effectuer le diagnostic des défauts des roulements et des engrenages.



### 3.4.3. Les K plus proches voisins (K Nearest Neighbors : KNN)

Ces dernières années, les techniques de classification des objets sont devenues d'une importance capitale dans divers domaines d'applications, tels que la reconnaissance des formes, l'intelligence artificielle, la psychologie cognitive, et la médecine [110]. Parmi ces techniques de classification, on peut distinguer les méthodes statistiques, paramétriques ou non paramétriques. Les méthodes paramétriques supposent la connaissance des lois de probabilité des classes et des observations. En effet, tout vecteur  $x$  suit dans une classe donnée  $\Omega_c$  une loi de probabilité  $f(x|\Omega_c)$ . Par ailleurs, les classes  $\Omega_c$  ( $c = 1, \dots, M$ ) sont caractérisées par leurs probabilités a priori  $P_r(\Omega_c)$ . Ces probabilités vérifient la condition d'orthogonalité suivante :

$$\sum_{c=1}^M P_r(\Omega_c) = 1 \quad (3.28)$$

Dans ce contexte, la règle la plus couramment utilisée est la règle de Bayes [111]. Néanmoins, en pratique, et surtout dans les problèmes de diagnostic des machines industrielles, les informations sur les lois de probabilités des classes et des observations sont rarement disponibles, ce qui conduit alors à s'orienter vers les méthodes non paramétriques permettant une estimation de ces lois de probabilité. Parmi les estimateurs usuels, on distingue l'estimateur de Parzen permettant d'estimer la probabilité conditionnelle [112], et l'estimateur des K-Plus Proches Voisins (KNN), permettant l'estimation des probabilités a posteriori d'appartenance aux classes, à partir de l'ensemble d'apprentissage, basé sur le principe des distances de Cover et Hart [113]. Ce deuxième estimateur (utilisé dans notre travail de thèse) sera présenté en détail dans le paragraphe suivant.

#### 3.4.3.1. Méthode des K Plus Proches Voisins

La méthode des K plus proches voisins s'écrit souvent KNN de l'anglais *K Nearest Neighbors*, est une technique de discrimination non-paramétrique [113], c'est à dire qu'aucune estimation de paramètres n'est nécessaire à son exécution. K étant un nombre entier positif généralement petit. Cette technique qui a été initialement introduite par Fix et Hodges [114], a été par la suite largement utilisée avec succès par de nombreux chercheurs à des fins de classification [115]. Cet algorithme ne nécessite pas d'apprentissage mais simplement le stockage des données d'apprentissage, c'est pour cette raison que certains scientifiques l'ont qualifié d'algorithme paresseux (*Lazy Learning*) car il n'apprend rien pendant la phase d'apprentissage. Pour prédire la classe d'une nouvelle donnée d'entrée, il va chercher ses K voisins les plus proches dans la base de données d'apprentissage (au sens d'une métrique choisie) et choisira la classe des voisins majoritaires [116].

##### 3.4.3.1.1 Présentation de la méthode

Soit  $X_a = (x_1, x_2, \dots, x_N)$ , l'ensemble des données d'apprentissage composé de N vecteurs indépendants, chacun étiqueté à l'une des M classes connues  $\Omega_c$  ( $c = 1, \dots, M$ ).

Le principe de la règle des KNN pour la classification d'une nouvelle observation  $x$ , est basé sur le calcul de la distance entre cette nouvelle observation et chacune des observations présentes dans l'ensemble d'apprentissage. Ensuite, on sélectionne les  $K$  voisins ayant la distance la plus faible avec la nouvelle observation. Au vu des classes d'appartenance des  $K$  plus proches voisins, on décide de la classe d'appartenance de la nouvelle observation. Généralement, on attribue la classe de la nouvelle observation comme étant la classe la plus représentée parmi ses  $K$  plus proches voisins [117].

La figure 3.5, ci-après, présente un exemple de classification par la règle des KNN.

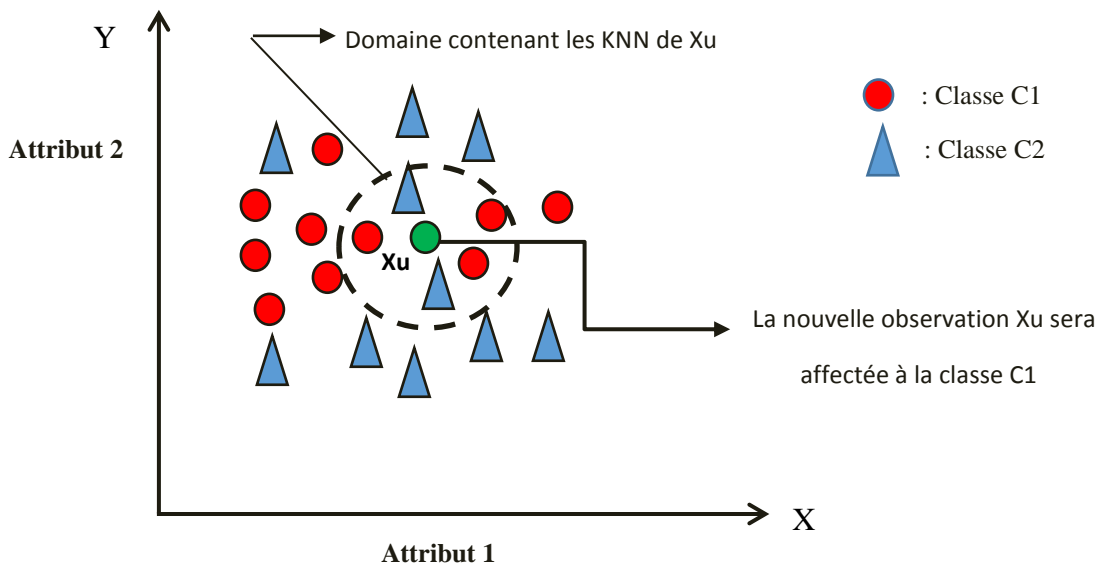


Figure 3.5 Illustration de l'affectation par la règle des KNN, avec  $K = 5$

### 3.4.3.1.2 Algorithme 1-NN (One Nearest Neighbor)

La méthode du plus proche voisin développée par Cover et Hart [113] affecte une nouvelle observation à la classe d'appartenance de l'observation de l'ensemble d'apprentissage qui lui est la plus proche, au regard des variables caractéristiques utilisées. La détermination de leur similarité est basée sur des mesures de distance.

Formellement, soit  $L$  l'ensemble de données d'apprentissage :

$$L = \{(y_i, x_i), \quad i = 1, 2, \dots, n_L\}$$

Où  $y_i \in \{1, \dots, c\}$  dénote la classe de l'individu  $i$  et le vecteur  $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$  représente les variables de l'individu  $i$ .

La détermination du plus proche voisin est basée sur une fonction distance arbitraire  $d(.,.)$ .

## Chapitre III : Méthodes de reconnaissance des formes dans le cadre de diagnostic des machines tournantes

---

La distance Euclidienne ou dissimilarité entre deux individus  $(x, u)$  caractérisés par  $p$  variables est définie par :

$$d\left((x_1, x_2, \dots, x_p), (u_1, u_2, \dots, u_p)\right) = \sqrt{(x_1 - u_1)^2 + (x_2 - u_2)^2 + \dots + (x_p - u_p)^2} \quad (3.29)$$

Ainsi, pour une nouvelle observation  $(y, x)$  le plus proche voisin  $(y_{(1)}, x_{(1)})$  dans l'ensemble d'apprentissage est déterminé par :

$$d(x, x_{(1)}) = \min_i (d(x, x_i)) \quad (3.30)$$

$\hat{y} = y_{(1)}$ , la classe du plus proche voisin, est sélectionnée pour la prédiction de  $y$ .

Les notations  $x_{(j)}$  et  $y_{(j)}$  représentent respectivement le  $j^{\text{ième}}$  plus proche voisin de  $x$  et sa classe d'appartenance.

La définition de la notion de plus proches voisins est liée au choix d'une distance. A cet effet, plusieurs types de distance peuvent être employés afin de fournir un indice de similarité entre deux vecteurs  $x_i$  et  $x_j$ . Parmi les plus connus, dans le cas des données numériques, la métrique de Minkowski est très utilisée :

$$d(x_i, x_j) = \left[ \sum_{s=1}^p |x_{is} - x_{js}|^q \right]^{1/q} \quad q \geq 1 \quad (3.31)$$

Où  $p$  désigne la dimension des vecteurs.

La métrique de Minkowski possède les propriétés d'une mesure de distance car elle vérifie :

- $d(x_i, x_j) = 0$  si et seulement si  $x_i = x_j$
- $d(x_i, x_k) \leq d(x_i, x_j) + d(x_j, x_k)$

Les distances les plus utilisées pour certaines valeurs de  $q$  sont :

1. La distance Euclidienne classique pour  $q = 2$  (déjà présentée dans l'éq. 3.29) :

$$d(x_i, x_j) = \left[ \sum_{s=1}^p |x_{is} - x_{js}|^2 \right]^{1/2} = \left[ (x_i - x_j)^t (x_i - x_j) \right]^{1/2} \quad (3.32)$$

2. La distance de Manhattan ou city – block pour  $q = 1$  :

$$d(x_i, x_j) = \sum_{s=1}^p |x_{is} - y_{js}| \quad (3.33)$$

3. La distance du "Max" pour  $q \rightarrow \infty$  :

$$d(x_i, x_j) = \max_{1 \leq s \leq p} |x_{is} - x_{js}| \quad (3.34)$$

4. La distance de Mahalanobis :

$$d^2(x_i, x_j) = (x_i - x_j)^t S^{-1} (x_i - x_j) \quad (3.35)$$

Où  $S$  désigne la matrice variance-covariance. L'avantage de ce type de distance, est qu'elle prend en compte la dispersion de l'ensemble d'apprentissage, dans chaque dimension. Bien d'autres expressions de distance peuvent être utilisées [118].

### 3.4.3.1.3 Algorithme KNN

Une première extension de cette idée, qui est largement et communément utilisée en pratique, est la méthode des  $K$  plus proches voisins. La plus proche observation n'est plus la seule observation utilisée pour la classification. Nous utilisons désormais les  $K$  plus proches observations. Ainsi la décision est en faveur de la classe majoritairement représentée par les  $K$  voisins. Soit  $K_r$  le nombre d'observations issues du groupe des plus proches voisins appartenant à la classe  $r$

$$\sum_{r=1}^c K_r = K \quad (3.36)$$

Ainsi une nouvelle observation est prédite dans la classe  $l$  avec :

$$l = \max_r (K_r) \quad (3.37)$$

Ceci évite que la classe prédite ne soit déterminée seulement à partir d'une seule observation. Le degré de localité de cette technique est déterminé par le paramètre  $K$  : pour  $K=1$ , on utilise la méthode du seul plus proche voisin comme technique locale maximale, pour  $K \rightarrow n_l$  on utilise la classe majoritaire sur l'ensemble intégral des observations (ceci impliquant une prédiction constante pour chaque nouvelle observation à classifier).

### 3.4.3.2. Variantes de la règle des KNN

Pour la méthode des KNN, et comme son nom l'indique, seuls les  $K$  plus proches voisins influencent la prédiction de la classe de la nouvelle observation  $(y, \mathbf{x})$ . Néanmoins, cette influence est identique pour chacun de ces voisins, indépendamment de leur degré de similarité avec la nouvelle observation  $(y, \mathbf{x})$  à classer. Deux inconvénients majeurs peuvent apparaître :

D'une part, cette méthode suppose que les frontières entre les classes sont parfaitement définies, ce qui n'est pas toujours vrai en pratique, puisque des situations de classes contiguës ou même disjointes peuvent se présenter. Par conséquent, ces situations causent souvent des difficultés de classification, puisqu'une observation située en bordure de classes contiguës, ou entre deux classes disjointes, peut signifier un état transitoire entre ces deux classes.

D'autre part, cette méthode renseigne sur l'appartenance d'une observation à une classe, mais ne donne aucune indication sur sa localisation dans la zone de la classe concernée. En effet, une observation située au centre d'une classe et une observation située en bordure (proche du seuil limite de rejet en distance) de celle-ci n'ont pas la même représentativité, et pourtant, ces deux observations sont affectées de la même manière à cette classe.

Pour pallier à ces deux inconvénients, plusieurs variantes du classificateur KNN, ont été suggérées [119, 120, 121]. Parmi ces variantes, on peut citer :

- ❖ Méthode des K Plus Proches Voisins Pondéré (Weighted-KNN: W-KNN).
- ❖ Méthode des K Plus Proches Voisins Floue (Fuzzy-KNN: F-KNN).

Dans ce qui suit, nous allons développer la deuxième variante (Fuzzy-KNN) qui a été utilisée dans notre travail de thèse.

### 3.4.4. Méthode des K Plus Proches Voisins Floue (Fuzzy- KNN : F-KNN)

Cette variante d'amélioration de la méthode KNN, a été développée en se basant sur la notion des ensembles flous. Depuis son introduction par L. Zadeh en 1965 [122], la théorie des ensembles flous, a été largement utilisée avec succès dans plusieurs domaines diversifiés tels que, la production industrielle [123], le secteur énergétique [124], la médecine [125], l'économie [126] ..., etc.

La notion d'ensembles flous a pour objectif de représenter les informations imprécises, incertaines, vagues, ou incomplètes. Elle permet une gradation dans l'appartenance d'une observation à une classe [127]. En d'autres termes, elle autorise une observation à appartenir plus ou moins fortement à une classe. L'appartenance à une classe s'exprime par l'intermédiaire d'un degré d'appartenance, compris entre 0 et 1 ; plus l'appartenance est forte, plus le degré est proche de 1, et inversement. Dans la littérature, différentes approches basées sur la logique floue, ont été proposées comme des extensions des modèles KNN classiques, ayant pour but d'améliorer les performances de classification.

Selon une revue établie par Joaquin Derrac et al. [128], ces classificateurs ont été groupés en six grandes familles (Fuzzy Sets, Type-2 Fuzzy Sets, Possibilistic Methods, Intuitionistic Fuzzy Sets,

Fuzzy Rough Sets and Preprocessing Methods via Data Reduction). Le nom de chaque famille fait référence à la technique principale spécifique utilisée pour développer une méthode spécifique. Cependant, le classificateur Fuzzy-KNN de la famille (Fuzzy Sets), s'est avéré être l'un des plus performant dans la pratique. Cet algorithme attribut à une observation donnée un vecteur de degrés d'appartenance aux différentes classes plutôt que d'affecter cette observation à une classe particulière, comme dans le cas du KNN standard. Keller et al. [110], ont démontré que le classificateur Fuzzy-KNN présente non seulement une erreur plus faible dans la classification des observations, mais également une plus grande mesure de confiance de la classification. Néanmoins, face à ces améliorations, deux inconvénients peuvent surgir lors de l'utilisation de cet algorithme pour la classification des données à grande échelle :

- Augmentation du temps d'exécution de l'algorithme (F-KNN).
- Consommation importante de la mémoire de stockage des données d'apprentissage et de test.

Ces difficultés ont encouragé les chercheurs à concevoir des modèles de Fuzzy-KNN distribués en utilisant des technologies conçues pour les bases de données importantes telles que (Map Reduce paradigm et Apache Spark Platform) [129].

Etant donné qu'on a utilisé ce classificateur Fuzzy-KNN (F-KNN) dans notre travail de thèse, une présentation détaillée lui sera consacrée dans la section suivante.

### 3.4.4.1. Algorithme Fuzzy-KNN (F-KNN)

La méthode des K plus proches voisins floue, comme son nom l'indique, introduit la notion de flou dans la règle de décision de la méthode des K plus proches voisins classique [110], [130].

Soit  $X_a = (x_1, x_2, \dots, x_N)$ , l'ensemble des données d'apprentissage composé de N observations indépendantes  $x_j$  ( $j = 1, 2, \dots, N$ ), chacune étiquetée à l'une des M classes connues  $C_i$  ( $i = 1, \dots, M$ ). L'algorithme Fuzzy-KNN est constitué de deux phases différentes : Une phase d'étiquetage flou de l'ensemble des données d'apprentissage, et une deuxième phase de classification d'une nouvelle observation dont la classe est inconnue.

#### 3.4.4.1.1. Phase d'étiquetage

Cette phase consiste à rechercher pour chaque observation  $x_j$  de l'ensemble d'apprentissage les K observations plus proches en calculant les distances entre l'observation  $x_j$  et toutes les autres observations de  $X_a$ , en utilisant une métrique choisie. Une fois les K observations les plus proches pour chaque observation  $x_j$  sont déterminées, l'algorithme F-KNN procède au calcul des degrés d'appartenance  $\mu_{ij}$  de chaque observation  $x_j$  par rapport à toutes les classes  $C_i$  selon l'équation ci-après :

$$\mu_{ij} = \begin{cases} \beta + \left(\frac{n_i}{K}\right) * (1 - \beta) & \text{si } C_i = C_j \\ \left(\frac{n_i}{K}\right) * (1 - \beta) & \text{si } C_i \neq C_j \end{cases} \quad (3.38)$$

$n_i$  : est le nombre des voisins de  $x_j$  appartenant à la classe  $C_i$  parmi ses  $K$  plus proches voisins.  
 $C_i$  : est la classe correspondante de  $x_j$  dans l'ensemble d'apprentissage.

$\beta \in [0,1]$  : est un paramètre de biaise, décrivant à quel degré  $C_j$  est impliquée dans la procédure d'étiquetage. Quelques cas particuliers pour la valeur de  $\beta$  peuvent se présenter :

- ❖  $\beta = 1$  : entraînant à un étiquetage solide (Crisp labeling en anglais) qui consiste à assigner à chaque observation  $x_j$  de l'ensemble d'apprentissage un degré d'appartenance égal à 1 pour sa classe spécifique et 0 pour toutes les autres classes.
- ❖  $\beta = 0$  : les degrés d'appartenance sont assignés selon la méthode des KNN classique.

$\mu_{ij}$  : est le degré d'appartenance à la classe  $C_i$  de l'observation  $x_j$

$\mu_{ij}$  : doit satisfaire les propriétés suivantes :

$$\begin{aligned} \sum_{i=1}^c \mu_{ij} &= 1 \\ 0 < \sum_{j=1}^N \mu_{ij} &< N \\ \mu_{ij} &\in [0,1] \end{aligned} \quad (3.39)$$

En conclusion, chaque observation de l'ensemble d'apprentissage est alors représentée par un vecteur de coefficients d'appartenance à chacune des  $M$  classes, au lieu d'être affectée à une seule classe particulière, comme le cas du classifieur KNN classique.

#### 3.4.4.1.2. Phase de classification

Dans cette phase, l'algorithme F-KNN procèdera à associer à chaque nouvelle observation  $x$  un degré d'appartenance  $\mu_i(x)$  à chacune des  $M$  classes.

Pour cela, on détermine les  $k$  plus proches voisins comme dans la première phase, mais cette fois-ci entre la nouvelle observation  $x$  à classer et l'ensemble des observations d'apprentissage ( $k$  peut être différent du  $K$  choisi dans la première phase d'étiquetage). Ensuite, au lieu d'affecter la nouvelle observation  $x$  à la classe majoritairement représentée par les  $k$  plus proches voisins comme dans le cas du KNN, l'algorithme F-KNN, proposé par Keller [110] calculera le degré d'appartenance  $\mu_i(x)$  en fonction de la distance entre  $x$  et ses  $k$  plus proches voisins, et des degrés d'appartenance de ses voisins aux différentes classes  $C_i$  selon l'équation suivante :

$$\mu_i(x) = \frac{\sum_{j=1}^k \mu_{ij} \left(1/|x - x_j|^{2/m-1}\right)}{\sum_{j=1}^k \left(1/|x - x_j|^{2/m-1}\right)} \quad (3.40)$$

Où  $|x - x_j|$  est la distance entre  $x$  et son  $j^{\text{ième}}$  plus proche voisin. Le paramètre  $m$  sert à ajuster la valeur de l'appartenance selon l'importance de la distance  $|x - x_j|$ . Un choix judicieux de ce paramètre est  $m = 2$  [110].  $\mu_{ij}$  est le degré d'appartenance à la classe  $C_i$  du  $j^{\text{ième}}$  plus proche voisin de la nouvelle observation  $x$ . La prise de décision, concernant la nouvelle observation  $x$ , consiste à affecter celle-ci à la classe dont la fonction d'appartenance est maximale. La règle de décision de Bayes ou bien celle de la méthode des K plus proches voisins classique devient alors comme suit :  $x$  sera classée dans la classe  $C_i$  si :

$$\mu_i(x) = \max_{i=1,\dots,c} (\mu_i(x)) \quad (3.41)$$

### 3.5. Conclusion

Les systèmes industriels, devenus aujourd'hui très complexes, assujettis à des conditions de fonctionnement difficiles et non stationnaires, doivent répondre aux contraintes de sécurité et de fiabilité tout en préservant leurs disponibilités et leurs performances. Néanmoins, il s'avère que les techniques classiques (exposées dans le chapitre précédent), utilisées dans la surveillance et le diagnostic des défauts de ces systèmes industriels présentent encore des limitations.

Afin de pallier à ces limitations, ce troisième chapitre a été consacré à présenter des nouvelles techniques issues de l'intelligence artificielle à savoir les méthodes de reconnaissance de formes (RdF).

En premier lieu, une présentation générale de la technique de reconnaissance des formes, ses différentes approches les plus reconnues, et les plus employées, ainsi que les différents domaines d'applications, en particulier dans le diagnostic des machines industrielles a été donnée. Ensuite, nous avons détaillé les principales étapes d'un système de reconnaissance des formes, partant de l'acquisition des signaux vibratoires des machines, jusqu'à la phase finale de classification de ces signaux (Etat sain de la machine ou présentant des défauts), en passant par l'étape de prétraitement de ces signaux vibratoires, d'extraction des caractéristiques, de sélection de celles qui sont les plus pertinentes et plus informatives. En dernier lieu, nous avons présenté en détails, les principes de fonctionnement, les avantages et inconvénients, de quelques règles de décision (classifieurs) les plus utilisées dans les techniques de reconnaissance des formes. Parmi ces règles de décision, on peut citer les Réseaux de Neurones Artificiels (ANNs), les Machines à Vecteurs de Support (SVMs), les méthodes des K Plus Proches Voisins (KNN), ainsi que son extension floue (F-KNN).



# CHAPITRE IV

## ALGORITHMES D'OPTIMISATION

Je ne suis pas tellement intelligent, mais je me concentre sur les problèmes plus longtemps.

**Albert Einstein.**

## Chapitre IV : ALGORITHMES D'OPTIMISATION

### 4.1 Introduction

De nos jours l'optimisation est devenue un domaine indispensable pour résoudre plusieurs problèmes que ce soit dans l'industrie ou d'autres secteurs. Comme son nom l'indique, l'optimisation cherche à trouver une solution optimale à un problème donné. C'est ainsi que cette discipline occupe actuellement une place importante dans la communauté des ingénieurs, des scientifiques et des décideurs intervenant dans leurs domaines d'activité qui sont très divers, comme la conception de systèmes mécaniques, le traitement d'images, systèmes de classification des défauts, ou la recherche opérationnelle, etc.

Parmi les objectifs ciblés par le processus d'optimisation, est de mieux planifier les tâches d'une chaîne de production industrielle, minimiser leur temps d'exécution, améliorer les propriétés physiques et mécaniques des différents équipements (solidité, efficacité, durabilité et fiabilité), et ce afin d'augmenter leurs performances. Cette conception doit aussi satisfaire d'autres contraintes strictes telles que le coût, la faisabilité industrielle, et enfin la commercialisation.

### 4.2 Problème d'optimisation

Un problème d'optimisation est défini par un ensemble de variables pouvant être de nature diverse (réelle, entière, booléenne, ..., etc.), une fonction « objectif », et un ensemble de contraintes. L'espace de recherche est l'ensemble des solutions possibles du problème. Pour des raisons pratiques et de temps de calcul, cet espace doit être de dimension finie.

Résoudre un problème d'optimisation consiste à trouver la ou les meilleures solutions (en minimisant et/ou maximisant la/les fonctions objectifs du problème posé), tout en satisfaisant un ensemble de contraintes d'égalité (ou d'inégalité) définies par l'utilisateur.

Un problème d'optimisation peut être statique ou dynamique (i.e. la fonction objectif change avec le temps), mono-objectif ou multiobjectif (i.e. plusieurs fonctions « objectifs » doivent être optimisées) et avec ou sans contraintes.

Dans la littérature, une grande variété de techniques d'optimisation a été mise en œuvre pour résoudre des problèmes d'optimisations. Ces techniques peuvent être classifiées en deux groupes : déterministes et stochastiques.

Les méthodes déterministes, appelées aussi méthodes exactes, permettent de résoudre certains types de problèmes d'optimisation et d'obtenir la solution optimale du problème, en un temps raisonnable. Ces méthodes nécessitent que la fonction « objectif » présente un certain nombre de caractéristiques telles que la convexité, la continuité ou la dérivabilité.

Nous pouvons citer, parmi les méthodes les plus connues, les méthodes de programmation linéaire [131], la technique de programmation quadratique [132] et/ou la programmation dynamique [133], la méthode de Newton [132], la méthode du simplexe [134] ou encore la méthode du gradient [135]. Toutefois, les méthodes déterministes ne sont pas adaptées à toutes les problématiques, et donc certains problèmes sont trop complexes à résoudre par ces méthodes. Parmi ces problématiques, nous pouvons citer l'existence de discontinuités, l'absence de convexité stricte, la non-dérivabilité, la présence de bruit ou encore la fonction « objectif » peut ne pas être définie

précisément (quand c'est un coût). En outre, ces méthodes de résolution exacte peuvent avoir un temps de résolution trop long. Dans ce cas, le problème d'optimisation est dit difficile, car aucune méthode exacte n'est capable de le résoudre en un temps raisonnable. Pour faire face à ces problématiques, les chercheurs ont développé des méthodes approchées, appelées méthodes heuristiques qui fournissent un résultat sans garantie de l'optimalité.

### 4.3 Algorithmes d'optimisation approchée

#### 4.3.1 Heuristiques

Le terme « heuristique » vient du grec « heurein » et signifie « découvrir ». Il qualifie tout ce qui sert à la découverte, à l'invention et à la recherche.

Contrairement aux méthodes déterministes, les méthodes heuristiques sont des algorithmes itératifs qui explorent l'espace des solutions par essais successifs en recherchant les directions les plus favorables. Ayant un comportement aléatoire approximatif, ces méthodes fournissent pour un problème d'optimisation difficile, une solution approchée, de qualité satisfaisante en un temps de calcul en général raisonnable, mais sans toutefois garantir l'optimalité de la solution obtenue.

Aussi, ces méthodes heuristiques demandent un nombre important d'évaluations de la fonction « objectif » en comparaison avec les méthodes déterministes exploitant la dérivée de la fonction « objectif ».

Il y a une multitude d'heuristiques qui ont déjà été proposées dans la littérature. Nous pouvons citer des heuristiques très simples telles que les algorithmes gloutons [136] ou les approches par amélioration itérative [137]. Le principe des méthodes gloutonnes est de faire une succession de choix optimaux localement, jusqu'à ce que l'on ne puisse plus améliorer la solution.

#### 4.3.2 Métaheuristiques

Des heuristiques plus poussées, adaptables à un grand nombre de problèmes différents, sans changements majeurs dans l'algorithme, ont été mises au point et ont donné naissance à une nouvelle famille d'algorithmes d'optimisation : les métaheuristiques. Le terme métaheuristique a été inventé par Fred Glover en 1986, lors de la conception de la recherche « tabou » [138]. L'arrivée de cette nouvelle famille d'algorithmes a marqué une grande révolution dans le domaine de l'optimisation. En effet, les métaheuristiques visent à résoudre des problèmes d'optimisation difficile, pour lesquels les méthodes classiques s'avèrent inefficaces. Elles peuvent être considérées comme des algorithmes stochastiques itératifs, où elles manipulent une ou plusieurs solutions à la recherche de l'optimum.

L'état de départ des solutions de l'algorithme est souvent choisi aléatoirement, ensuite les itérations successives doivent permettre à l'algorithme de progresser d'une solution de mauvaise qualité à une solution optimale. L'algorithme s'arrête après avoir atteint un critère d'arrêt, consistant généralement en l'atteinte du temps d'exécution imparti ou en une précision demandée. Ces méthodes tirent leurs intérêts de leur capacité à éviter la convergence prématurée vers un optimum local, soit en acceptant des dégradations de la fonction « objectif » au cours du traitement, soit en utilisant une population de points comme méthode de recherche.

Parmi les divers types de métaheuristiques qui ont été mis en œuvre au profit des utilisateurs, nous pouvons citer :

- ❖ Les Métaheuristiques pour l'optimisation multi-objective [139] : où il faut optimiser plusieurs objectifs contradictoires. Le but ne consiste pas ici à trouver un optimum global, mais à trouver un ensemble d'optima, qui forment une surface de compromis pour les différents objectifs du problème ;
- ❖ Les Métaheuristiques pour l'optimisation multimodale [140] : où l'on ne cherche plus l'optimum global, mais l'ensemble des meilleurs optima globaux et/ou locaux ;
- ❖ Les Métaheuristiques pour l'optimisation de problèmes bruités : où il existe une incertitude sur le calcul de la fonction objectif, dont il faut tenir compte dans la recherche de l'optimum ;
- ❖ Les Métaheuristiques pour l'optimisation dynamique [141] : où la fonction « objectif » varie dans le temps, ce qui nécessite d'approcher l'optimum à chaque pas de temps ;
- ❖ Les Métaheuristiques hybrides [142] : qui consistent à combiner différentes métaheuristiques, afin de tirer profit des avantages respectifs ;
- ❖ Les Métaheuristiques parallèles [143] : où l'on cherche à accélérer le calcul, en répartissant la charge de calcul sur des unités fonctionnant de concert. Le problème revient alors à adapter les métaheuristiques pour qu'elles soient distribuées.

La majorité des métaheuristiques sont inspirées des systèmes naturels qui relèvent de la physique (recuit simulé qui est inspiré d'un processus métallurgique), de la biologie et des principes de l'évolution Darwinienne (les algorithmes évolutionnaires et les algorithmes génétiques), de la mémoire des êtres humains (algorithme de la recherche tabou), ou encore de l'éthologie ou l'intelligence d'essaim (les algorithmes de colonies de fourmis ou l'optimisation par essaim particulière).

Dans ce qui suit nous présentons quelques algorithmes métaheuristiques les plus étudiées et les plus utilisées dans la littérature, tels que l'algorithme de colonies de fourmis, les algorithmes évolutionnaires (algorithmes génétiques), et l'optimisation par essaims particuliers (Partical Swarm Optimisation : PSO). Ce dernier algorithme sera revu un peu plus en détail vu qu'il est adopté dans notre travail de thèse.

#### 4.4 L'algorithme de colonie de fourmis

L'optimisation par colonie de fourmis (Ant Colony Optimization (ACO)) est une méthode métaheuristique qui a été initiée en 1996 par Coloni, Dorigo et Maniezzo [144]. Comme son nom l'indique, cette méthode est inspirée du comportement coopératif des colonies de fourmis. Ces dernières accomplissent des tâches impossibles à accomplir par une fourmi seule.

Ainsi, lors du fourrage de la nourriture, les fourmis commencent généralement par se déplacer au hasard (figure 4.1 (a)). Puis, lorsqu'elles trouvent de la nourriture, elles retournent vers leur colonie, en marquant leur chemin par la sécrétion de substances chimiques appelées phéromone. Si d'autres fourmis rencontrent ce chemin, il y a de fortes chances qu'elles arrêtent leurs déplacements aléatoires et qu'elles rejoignent le chemin marqué, en renforçant le marquage à leur retour, s'il mène bien vers la nourriture. Par conséquent, le chemin le plus court sera davantage parcouru, et donc plus renforcé et plus attractif. Par conséquent, le nombre de fourmis suivant cette trajectoire augmente (figure 4.1 (b)). Inversement, sur les chemins de moins en moins utilisés, il y a évaporation de la phéromone. L'utilisation de la phéromone est un exemple de communication stigmergique puisque les fourmis ne communiquent pas de manière directe, mais altèrent leur environnement et communiquent à travers. Par conséquent, cette technique d'optimisation adopte pour la recherche de la solution, la notion du plus court chemin.



(a)



(b)

Figure 4.1 Chemin de fourmis

L'ACO a été appliquée avec succès à divers problèmes d'optimisation [145], qu'il s'agisse de problèmes statiques (dont les caractéristiques ne changent pas durant toute la vie du problème, tels que le voyageur de commerce ou le coloriage de graphe) ou dynamiques (qui démarrent d'un état initial puis évoluent, tel que le routage dans un réseau téléphonique).

#### 4.5 Les algorithmes évolutionnaires

Les algorithmes évolutionnaires (AEs), élaborés au cours des années 1950 [146], sont des techniques de recherche inspirées par l'évolution biologique des espèces. Ils s'inspirent de la théorie de l'évolution des espèces vivantes échafaudée par Charles Darwin, et publiée en 1859 dans son ouvrage célèbre « L'origine des espèces par la sélection naturelle ».

L'idée ici est que, lorsqu'une population est soumise aux contraintes d'un milieu naturel, seuls les individus possédant des caractères bien adaptés à ce milieu survivent et génèrent une descendance, alors que les plus faibles ont tendance à disparaître. Au cours des générations, la sélection naturelle permet l'apparition d'individus de mieux en mieux adaptés au milieu naturel, au détriment de ceux se montrant notoirement inadaptés, assurant ainsi la pérennité de l'espèce.

Depuis les années 1970, de nombreuses approches inspirées de cette théorie d'évolution ont été développées à des fins de résolution automatisée des problèmes. Parmi ces approches, nous pouvons citer :

- Les Algorithmes Génétiques (GA) qui ont été introduits par John Henry Holland [147], conçus pour résoudre des problèmes d'optimisation à variables discrètes, en modélisant l'évolution génétique ;
- La Programmation Génétique (GP) qui a été introduite par John Koza [148] basée sur les algorithmes génétiques, mais où les individus (ou chromosomes) sont des programmes informatiques, représentés en utilisant une structure d'arbre ;
- La Programmation Evolutionnaire (EP) qui a été introduite par Fogel [149].

Généralement, les principales étapes de base des algorithmes évolutionnaires (AEs) se résument comme suit :

1. Initialisation de la population de  $\mu$  individus
2. Evaluation des  $\mu$  individus
3. Tant que le critère d'arrêt n'est pas satisfait faire
4. Sélection de  $\rho$  individus en vue de la phase de reproduction
5. Croisement des  $\rho$  individus sélectionnés
6. Mutation des  $\lambda$  enfants obtenus
7. Evaluation des  $\lambda$  enfants obtenus
8. Sélection pour le remplacement
9. Fin

### **Algorithme évolutionnaire générique.**

#### **4.5.1 Les algorithmes génétiques**

Les algorithmes génétiques sont sans doute la classe la plus représentative et la plus populaire parmi les algorithmes évolutionnaires. Ainsi, en 1975 les premiers travaux ont été lancés aux États-Unis par John H. Holland à l'Université de Michigan [147]. Dans son ouvrage "Adaptation of Natural and Artificial System", il formalise les algorithmes génétiques dans le cadre de l'optimisation mathématique. Ensuite, la parution de l'ouvrage de David Goldberg en 1989 [150] décrivant l'utilisation de ces algorithmes pour la résolution des problèmes concrets, a permis de mieux faire connaître ces derniers dans la communauté scientifique et a marqué le début d'un nouvel intérêt pour cette technique d'optimisation.

Par analogie au processus de l'évolution naturelle des êtres vivants et de la génétique, les algorithmes génétiques (GAs) appliquent d'une manière itérative, des opérations de transformations

génétiques nécessaires sur une population initiale jusqu'à l'obtention des individus les mieux adaptés au problème traité (solution optimale).

Le principe de fonctionnement d'un algorithme génétique consiste tout d'abord en une génération aléatoire de  $N$  individus (chromosomes) dans l'espace de recherche permis (la population). Chaque chromosome se compose d'une chaîne de cellules concaténées également appelées gènes. La valeur de chaque gène s'appelle allèle [147], qui correspond à un codage d'un paramètre dans l'espace de recherche. Plusieurs types de codage peuvent être utilisés. Parmi ces types, nous pouvons citer : codage binaire, gray, ou réel. Le nombre  $S$  de gènes (bits de codage) constitue la longueur du chromosome. La population initiale forme donc une matrice ( $N \times S$ ), dans laquelle le nombre de lignes représente le nombre d'individus  $N$  et le nombre de colonnes représente le nombre de bits  $S$  de chaque individu.

$$Population = \begin{bmatrix} p_{1,1} & \cdots & p_{1,S} \\ \vdots & \ddots & \vdots \\ p_{N,1} & \cdots & p_{N,S} \end{bmatrix}$$

Une fois la population initiale est générée, vient l'étape d'évaluation, où chaque chromosome est évalué selon une fonction de fitness prédéfinie (appelée aussi fonction de qualité ou fonction coût). Les valeurs de fitness de tous les chromosomes sont estimées en calculant la fonction « objectif » considérée.

Des études de recherche utilisant les algorithmes génétiques (GAs), ont montré que la représentation du chromosome, et la fonction « objectif » sont des paramètres dépendants du problème à traiter. Un mauvais choix de ces deux paramètres affectera la performance des GAs. Une fois les valeurs de fitness de tous les chromosomes sont calculées, les chromosomes ayant des valeurs de fitness élevées (appelés parents), ont plus de probabilité qu'ils soient sélectionnés pour l'accouplement afin de générer de nouveaux chromosomes (appelés enfants) [151]. Les méthodes de sélection les plus connues sont les suivantes :

- ✚ Sélection à la roulette
- ✚ Sélection par classement
- ✚ Sélection par tournoi

Une fois le processus de sélection terminé, l'étape suivante est consacrée à la reproduction de la nouvelle population. Ceci est réalisé par des opérateurs génétiques tels que les opérateurs de croisement et de mutation. Ces opérateurs ont l'avantage de pouvoir diversifier la population au cours des générations et d'explorer l'espace de recherche. Les chromosomes de la population actuelle sont ensuite remplacés par leurs enfants, utilisant une stratégie de remplacement. Parmi les stratégies de remplacement existantes dans la littérature, deux stratégies sont les plus utilisées : le remplacement stationnaire et le remplacement élitiste [152]. Le cycle de l'algorithme génétique est répété jusqu'à ce qu'un critère de convergence défini par l'utilisateur soit atteint. Si tout se passe bien tout au long de ce processus d'évolution simulée, les meilleurs chromosomes de la population finale seront les solutions les plus adaptées au problème traité.

La figure 4.2, résume les différentes étapes d'un algorithme génétique :

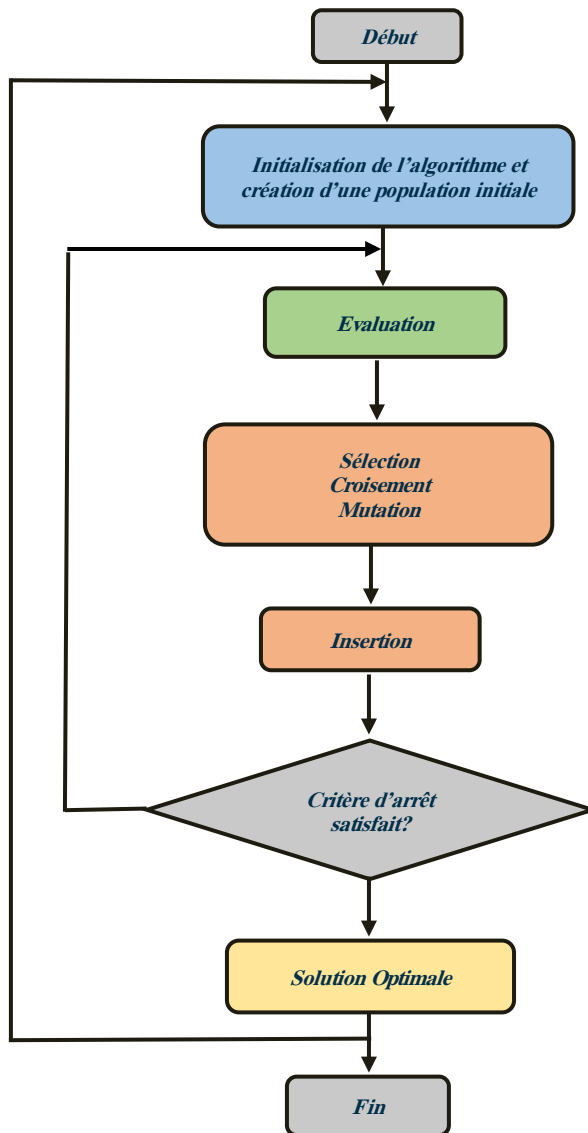


Figure 4.2 Etapes d'un Algorithme Génétique simple

## 4.6 Optimisation par Essaims Particulaires

### 4.6.1 Introduction

L'optimisation par essaim particulaire ("Particle Swarm Optimization" : PSO) est une métaheuristique d'optimisation, qui a été proposée pour la première fois aux Etats Unis en 1995 par Russel Eberhart (ingénieur en électricité) et James Kennedy (socio-psychologue) [153]. Semblable aux algorithmes de calcul évolutifs précédemment présentés, tels que les algorithmes de colonies de fourmis, les algorithmes génétiques, le Particle Swarm Optimization (PSO) est un algorithme qui s'appuie particulièrement sur le modèle développé par le biologiste Craig Reynolds à la fin des années 1980 permettant de simuler le déplacement grégaire de certains animaux tels que les



troupeaux de bovins, les nuées d'oiseaux migrateurs, les bancs de poissons, ...etc., et ce lors de la recherche des sources de nourriture, ou encore les positions perchoirs.

En effet, on peut observer chez ces animaux des dynamiques de déplacement relativement complexes, alors qu'individuellement chaque individu a une intelligence limitée et une connaissance seulement locale de sa situation dans le groupe. Un individu du groupe n'a pour connaissance que la position et la vitesse de ses plus proches voisins. Chaque individu utilise donc, non seulement, sa propre mémoire, mais aussi l'information locale sur ses plus proches voisins pour décider de son propre déplacement. Des règles simples, telles que « aller à la même vitesse que les autres », « se déplacer dans la même direction » ou encore « rester proche de ses voisins » suffisent à maintenir la cohésion du groupe et permettent la mise en œuvre de comportements collectifs complexes et adaptatifs.

De ce fait, Kennedy et Eberhart se sont alors inspirés de ces comportements sociaux pour créer l'algorithme PSO afin d'approximer des solutions pour des problèmes d'optimisation. La figure 4.3 ci-dessous montre quelques exemples de déplacement en groupe.




Figure 4.3 Exemples de déplacements en groupe :  
(a) : Essaim d'oiseaux (b) : Banc de poissons

#### 4.6.2 Algorithme PSO

L'algorithme PSO est un algorithme itératif à base de population d'individus appelés particules. Cette population de particules est nommée « essaim », d'où le nom d'optimisation par essaim de particules. Au début de l'exécution du processus d'optimisation, l'essaim composé de ces particules est initialisé au hasard, et où chaque particule  $i$  représentant une solution potentielle, est positionnée (aléatoirement) dans l'espace de recherche du problème. Ensuite, et afin d'atteindre l'optimum global du problème, chaque particule  $i$  se déplace dans l'espace de recherche du problème, en ajustant sa vitesse  $V_i$  et sa position de recherche  $X_i$  en fonction de l'expérience de la population de particules  $P_g$  (c'est-à-dire l'expérience des particules voisines) et de sa propre expérience  $P_i$  (c'est-à-dire la meilleure position parcourue par elle-même).

Les meilleures valeurs de chaque particule (meilleure valeur personnelle, aussi appelée personal best :  $P_{best_{i,j}}$ , meilleure valeur globale, aussi appelée global best :  $G_{best_{i,j}}$ ) sont évaluées par une fonction dite « fonction objectif » ou « fitness ». Ces meilleures valeurs sont accumulées pour être utilisées à l'étape suivante et également pour obtenir la valeur optimale. Ce processus sera

répété autant d'itérations jusqu'à ce qu'une condition de convergence soit remplie. Ainsi, le déplacement d'une particule est influencé par les trois composantes suivantes :

1. Une composante d'inertie : la particule tend à suivre sa direction courante de déplacement.
2. Une composante cognitive : la particule tend à se diriger vers le meilleur site par lequel elle est déjà passée.
3. Une composante sociale : la particule tend à se fier à l'expérience de ses congénères et, ainsi, à se diriger vers le meilleur site déjà atteint par ses voisins.

La stratégie de déplacement d'une particule est illustrée dans la figure 4.4

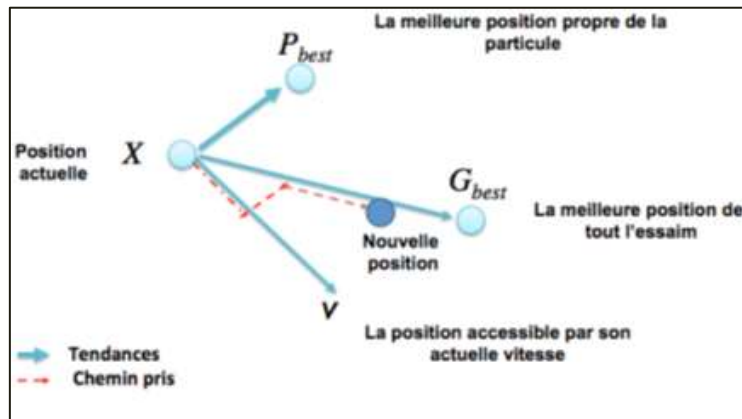


Figure 4.4: Stratégie de déplacement d'une particule.

### 4.6.3 Formalisation

Soit un problème dont l'espace de recherche est de dimension  $N$ . Supposons que l'essaim est de taille  $S$ . Chaque particule  $p_i$  ( $i = 1, 2, \dots, S$ ) de l'essaim est modélisée par son vecteur position  $p_i = (p_{i1}, p_{i2}, \dots, p_{iN})$  et par son vecteur vitesse  $v_i = (v_{i1}, v_{i2}, \dots, v_{iN})$ . La qualité de sa position est déterminée par la valeur de la fonction « objectif » en ce point. Cette particule garde en mémoire la meilleure position par laquelle elle est déjà passée, que l'on note  $P_{bi} = (p_{bi1}, p_{bi2}, \dots, p_{biN})$ . La meilleure position atteinte par les particules de l'essaim est notée  $P_g = (P_{g1}, P_{g2}, \dots, P_{gN})$ . Nous nous référons à la version globale de PSO, où toutes les particules de l'essaim sont considérées comme voisines de la particule  $i$ , d'où la notation  $P_g$  (global best). Au départ de l'algorithme, les particules de l'essaim sont initialisées de manière aléatoire dans l'espace de recherche du problème. Ensuite, à chaque itération, chaque particule se déplace, en combinant linéairement les trois composantes citées ci-dessus (i.e. d'inertie, cognitive et sociale). En effet, à l'itération  $t + 1$ , le vecteur « vitesse » et le vecteur « position » sont calculés à partir des équations (4.1) et (4.2) ci-dessous :

$$v_i(t + 1) = w v_i(t) + c_1 \cdot r_1 [P_{bi}(t) - p_i(t)] + c_2 \cdot r_2 [P_g(t) - p_i(t)] \quad (4.1)$$

$$p_i(t + 1) = p_i(t) + v_i(t) \quad (4.2)$$

Où  $w$  est le coefficient d'inertie qui permet de contrôler l'influence de la direction de la particule sur le déplacement futur. Le but de l'introduction de ce paramètre est de réaliser un équilibre entre la recherche locale (exploitation) et la recherche globale (exploration). Une valeur élevée de  $w$  permet une exploration globale de l'espace de recherche alors qu'une faible valeur favorise une exploitation locale. Les études menées par [154] indiquent une meilleure convergence pour  $w$  entre 0.8 et 1.2.

Les paramètres  $c_1$  et  $c_2$  sont deux constantes, appelées coefficients d'accélération. Ils contrôlent respectivement les vitesses relatives par rapport aux meilleures positions locales et globales.  $c_1$  est appelé paramètre cognitif, car il détermine l'influence de la meilleure position locale,  $c_2$  est appelé paramètre social, car il détermine l'influence de la meilleure position globale. Habituellement,  $c_1$  et  $c_2$  sont tirés de l'intervalle  $[0, 2]$ , les valeurs typiques sont  $c_1 = c_2 = 2$ . Enfin,  $r_1$  et  $r_2$  sont des variables aléatoires uniformes tirées dans  $[0, 1]$  pour fournir une pondération stochastique des composantes impliquées dans l'équation (4.1).

Les trois composantes mentionnées ci-dessus (i.e. d'inertie, cognitive et sociale) sont représentées dans l'équation (4.1) par les termes suivants :

1.  $w v_i(t)$  : correspond à la composante d'inertie du déplacement, où le paramètre  $w$  contrôle l'influence de la direction de déplacement sur le déplacement futur ;
2.  $c_1 \cdot r_1 [P_{bi}(t) - p_i(t)]$  : correspond à la composante cognitive du déplacement, où le paramètre  $c_1$  contrôle le comportement cognitif de la particule ;
3.  $c_2 \cdot r_2 [P_g(t) - p_i(t)]$  : correspond à la composante sociale du déplacement, où le paramètre  $c_2$  contrôle l'aptitude sociale de la particule.

Une fois le déplacement des particules effectué, les nouvelles positions sont évaluées et les deux vecteurs  $P_{bi}$  et  $P_g$  sont mis à jour, à l'itération  $t + 1$ , suivant les deux équations (4.3) (dans le cas d'une minimisation) et (4.4) (dans une version globale de PSO), respectivement.

$$P_{bi}(t + 1) = \begin{cases} P_{bi}(t), & \text{si } f(p_i(t + 1)) \geq P_{bi}(t) \\ p_i(t + 1), & \text{sinon} \end{cases} \quad (4.3)$$

$$P_g(t + 1) = \arg \min_{P_{bi}} f(P_{bi}(t + 1)), \quad 1 \leq i \leq S \quad (4.4)$$

Cette procédure est présentée dans l'Algorithme ci-après, où  $S$  est le nombre de particules de l'essaim.

#### Algorithme

1. Initialiser aléatoirement  $S$  particules : position et vitesse.
2. Evaluer les positions des particules.
3. Pour chaque particule  $i$ ,  $P_{bi}(t) = p_i(t)$ .
4. Calculer  $P_g$  selon (4.4).
5. Tant que le critère d'arrêt n'est pas satisfait faire
6. Déplacer les particules selon (4.1) et (4.2)
7. Evaluer les positions des particules.
8. Mettre à jour  $P_{bi}$  et  $P_g$  selon (4.3) et (4.4).
9. Fin.

#### 4.6.4 Topologie de voisinage

Comme nous l'avons vu précédemment que l'algorithme PSO est une méthode d'optimisation stochastique inspirée d'un comportement social. Ce comportement a été modélisé par les deux équations (4.1) et (4.2) pour guider les particules durant le processus de déplacement. Le choix d'une topologie (le réseau de communication entre les particules) a donc une influence importante sur les performances de PSO. En littérature, plusieurs types de topologie de voisinages ont été développés dont les plus utilisées sont mentionnées ci-dessous [155] :

- ✚ **Topologie en anneau** (figure 4.5) : Dans cette approche, chaque particule communique avec  $n$  particules, (généralement  $n = 3$ ). Chaque particule tend à se diriger vers la meilleure position dans son voisinage local notée (local best :  $lbest$ ), c'est la topologie la plus utilisée.




Figure 4.5. Voisinage Anneau

- ✚ **Topologie en rayon** (figure 4.6) : la communication entre les particules est faite via une particule centrale, seule cette dernière ajuste sa position vers la meilleure, s'il y a amélioration de sa position, l'information est alors propagée à ses congénères.




Figure 4.6. Voisinage rayon

- ✚ **Topologie en étoile** (figure 4.7) : chaque particule est reliée à toutes les autres, le réseau social est complet, i.e. L'optimum du voisinage est l'optimum global (global best : gbest).




Figure 4.7. Voisinage étoile

Le choix de la topologie de voisinage a un grand effet sur la propagation de la meilleure solution trouvée par l'essaim. En utilisant le modèle *gbest* la propagation est très rapide (c.-à-d. toutes les particules dans l'essaim seront affectées par la meilleure solution trouvée dans l'itération  $t$ , immédiatement dans l'itération  $t + 1$ ). Cependant, en utilisant les topologies anneau et rayon ralentiront la convergence parce que la meilleure solution trouvée doit propager par plusieurs voisinages avant d'affecter toutes particules dans l'essaim. Cette propagation lente permettra aux particules d'explorer plus les secteurs dans l'espace de recherche et diminuent ainsi la chance de la convergence.

#### 4.6.5 Le critère d'arrêt

Malgré que l'algorithme PSO ait montré ses performances dans le domaine de l'optimisation, il s'est avéré nécessaire de le doter d'un critère d'arrêt, puisque sa convergence vers une solution optimale globale n'est pas toujours garantie. Ce critère d'arrêt (appelé aussi critère de convergence) dépend étroitement du problème d'optimisation posé et des contraintes de l'utilisateur. De ce fait, plusieurs études ont été menées dans ce sens [156], et différentes propositions ont eu lieu : l'algorithme doit alors s'exécuter tant que l'un des critères de convergence n'a pas été atteint. Cela peut-être : la meilleure valeur de la fonction de fitness adoptée et/ou simplement sur un nombre maximum d'itérations défini par l'utilisateur.

## 4.7 Conclusion

Un problème d'optimisation est généralement défini par un ensemble de variables pouvant être de nature diverse (réelle, entière, booléenne, ..., etc.), une fonction « objectif » et un ensemble de contraintes. L'espace de recherche est l'ensemble des solutions possibles du problème. Résoudre un problème d'optimisation consiste à trouver la ou les meilleures solutions (en minimisant et/ou maximisant la/les fonctions objectifs du problème posé), tout en satisfaisant un ensemble de contraintes d'égalité (ou d'inégalité) définies par l'utilisateur.

Dans ce chapitre, nous avons présenté une variété de techniques les plus utilisées pour résoudre des problèmes d'optimisation. Ces techniques peuvent être classifiées en deux grandes familles : déterministes et stochastiques.

Dans une première partie, nous avons exposé brièvement les techniques déterministes, ainsi que leurs conditions de mise en œuvre, et avantages. Parmi ces techniques, nous pouvons citer : la programmation linéaire, la technique de programmation quadratique, la programmation dynamique, la méthode de Newton, la méthode du simplexe ou encore la méthode du gradient. Néanmoins, il s'avère que ces techniques ne sont pas adaptées à toutes les problématiques, et présentent quelques limitations devant certains problèmes complexes (problème d'optimisation difficile).

Dans la deuxième partie du chapitre, et afin de surmonter ces contraintes, nous avons présenté en détails la deuxième famille de techniques appelées « méthodes approchées » ou méthodes heuristiques. Contrairement aux méthodes déterministes, les méthodes heuristiques sont des algorithmes itératifs qui explorent l'espace des solutions par essais successifs en recherchant les directions les plus favorables. Ces techniques présentent l'avantage de fournir, pour un problème d'optimisation difficile, une solution approchée, de qualité satisfaisante en un temps de calcul en général raisonnable, mais sans toutefois garantir l'optimalité de la solution obtenue.

La troisième partie de ce chapitre a été consacrée à la présentation des métaheuristiques. Cette famille d'algorithmes d'optimisation qui n'est en fait qu'une extension des méthodes heuristiques pouvant être adaptables à un grand nombre de problèmes différents sans changements majeurs dans l'algorithme. Ces algorithmes commencent généralement avec une population d'individus choisie aléatoirement. Ensuite, des itérations successives doivent permettre à l'algorithme de progresser d'une solution de mauvaise qualité à une solution optimale. L'algorithme s'arrête après avoir atteint un critère d'arrêt, consistant généralement en l'atteinte du temps d'exécution imparti, nombre d'itérations fixé, ou en une précision demandée. La majorité de ces algorithmes métaheuristiques sont inspirés des systèmes naturels, et des comportements coopératifs de certains animaux et insectes (troupeaux de bovins, nuées d'oiseaux migrateurs, bancs de poissons, colonies de fourmis, ...etc.). Enfin, nous avons exposé quelques algorithmes métaheuristiques les plus étudiées et les plus utilisées dans la littérature, tels que l'algorithme de colonies de fourmis, les algorithmes génétiques (algorithmes évolutionnaires), et l'optimisation par essaims particuliers (Particle Swarm Optimisation : PSO). Ce dernier algorithme a été largement détaillé, vu qu'on l'a adopté dans notre application pour rechercher les  $N$  meilleurs paramètres angulaires  $\theta_i$  liés à la représentation polyphase des filtres d'ondelettes afin d'améliorer les performances de classification des défauts des machines tournantes.

# CHAPITRE V

## SIMULATIONS ET RESULTATS

La force ne vient pas des capacités physiques ; elle vient d'une indomptable volonté.

**Mahatma Gandhi.**

## CHAPITRE V : SIMULATIONS ET RESULTATS

### 5.1 Introduction

Aujourd'hui, l'énergie électrique est devenue un facteur primordial au développement économique, dans tous les pays du monde. Son importance relative s'accroît avec les progrès techniques, l'industrialisation et le besoin de confort moderne. C'est pour cette raison que les industriels des centrales électriques exigent la mise en place de stratégies de maintenance efficaces et robustes, permettant une disponibilité maximale des machines stratégiques et équipements vitaux, dans un environnement d'hygiène et de sécurité, d'une part, et d'éviter des arrêts imprévus, et des opérations d'entretiens non programmés, d'autre part. Aujourd'hui, la maintenance préventive conditionnelle par analyse vibratoire est devenue l'une des stratégies pilotes, permettant d'atteindre ces objectifs. Dans cette optique, notre travail expérimental s'articule essentiellement sur la surveillance et le diagnostic des défaillances des machines tournantes d'un groupe turbogénérateur.

Pour cela, trois parties expérimentales ont été réalisées, en utilisant diverses techniques de traitement et d'analyse des signaux vibratoires sur des données issues de plusieurs campagnes d'essais (industriels et sur banc d'essais).

### 5.2 Première partie expérimentale

#### 5.2.1 Description succincte de la centrale électrique F'kirina

La centrale de production d'électricité de F'kirina est parmi les centrales que compte le groupe Sonelgaz d'Algérie (Société Nationale d'électricité et gaz). Elle est implantée dans la commune de F'kirina (Wilaya d'Oum el Bouaghi-Algérie), et est constituée de deux (02) groupes turbogénérateurs à gaz, de puissance unitaire 146,2 MW. Le tableau ci-dessous donne quelques caractéristiques de cette centrale.

Centrale	N° Gr	Constructeur	Technologie	Type	Contrôle Commande	Année de mise en service	Puissance installée (MW)
F'kirina	1 & 2	ALSTOM	ALSTOM	GT13E2	ADVANT EGATROL8	2004	146,2

Tableau 5.1 Caractéristiques techniques de la centrale turbine à gaz de F'kirina






Figure 5.1 Schéma synoptique d'un groupe TG centrale F'kirina

**P1** : palier compresseur. **P2** : palier intermédiaire. **P3** : palier échappement turbine.  
**P4** : palier avant Alternateur. **P5** : palier Arrière Alternateur.

**5.2.2 Phase d'acquisition des signaux vibratoires**

La base de données collectée est constituée de 765 signaux vibratoires temporels de 2048 échantillons chacun. Ces signaux sont recueillis à une vitesse de rotation du rotor turbocompresseur de 3000 tr/mn, avec une fréquence d'échantillonnage de 1280 Hz, et une durée d'acquisition estimée à 1,6 secondes. Ces signaux vibratoires représentent différentes signatures (état sain, défaut de balourd, défaut d'alignement, et enfin défaut de roulement), du groupe turboalternateur d'une part, et de quelques machines tournantes auxiliaires (Motopompe à huile lubrification, motopompe eau de refroidissement, et motopompe HP) d'autre part.

**5.2.3 Phase de traitement et analyse des signaux vibratoires**

Cette phase a été scindée en deux étapes :

**5.2.3.1 Analyse spectrale**

Dans cette étape, nous avons réalisé une analyse spectrale (Transformée de Fourier) des différents signaux vibratoires afin de déceler les différents défauts. Ensuite ces défauts ont été regroupés en quatre classes (Etat sain, défaut de balourd, défaut d'alignement, et défaut de roulements). Un état récapitulatif des différents états, est donné dans le tableau ci-dessous :


Classe	Etat sain	Défaut de balourd	Défaut d'alignement	Défaut de roulements
Fréquence de manifestation	/	1 x fr*	De 2 à 4 x fr*	> 5 x fr*
Nombre de signaux	109	108	115	433
Total	765 signaux			

Tableau 5.2 Total des signaux par classe de défaut


\* fr : fréquence de rotation des différents équipements (fr = 50 Hz)

Les figures ci-dessous représentent quelques signaux temporels ainsi que leurs analyses spectrales.

**1. Défaut de balourd :**




(a)




(b)

Figure 5.2 Défaut de balourd : (a) : Signal vibratoire temporel (b) : Analyse spectrale

**2. Défaut d'alignement :**




(a)




(b)

Figure 5.3 Défaut d'alignement : (a) : Signal vibratoire temporel (b) : Analyse spectrale

**3. Défaut de roulements :**



(a)



(b)

Figure 5.4 Défaut de roulement (a) : Signal vibratoire temporel (b) : Analyse spectrale

**Commentaires :** D'après ces échantillons des signaux vibratoires, on peut constater ce qui suit :

1. Les différents signaux vibratoires temporels sont exprimés en accélération ( $m/s^2$ )
2. Les différents signaux vibratoires temporels présentent des amplitudes assez faibles, ceci peut être expliqué par le fait que les différentes machines tournantes de la centrale électrique sont toujours en bon état vibratoire (plage vibratoire Bonne).
3. La durée des signaux vibratoires est de l'ordre de 1,6 seconde.
4. Pour les différentes analyses spectrales, les différents types de défauts sont distingués selon les fréquences de manifestation du défaut :
  - a. Défaut balourd : l'amplitude maximale dominante se situe à la fréquence  $1xfr$ , soit 50 Hz (figure 5.2).
  - b. Défaut d'alignement : les amplitudes maximales dominantes se situent entre  $2xfr$  et  $4xfr$ . Dans la figure 5.3 le défaut se manifeste à la fréquence 150 Hz.
  - c. Défaut de roulement : les défauts se manifestent à hautes fréquences supérieures à  $5xfr$ . Dans la figure 5.4 le défaut se manifeste à la fréquence 600 Hz.

### 5.2.3.2 Analyse des signaux vibratoires par transformée en ondelettes

Dans cette deuxième étape, nous avons procédé à l'analyse des signaux vibratoires temporels par une transformation en ondelette. Pour cela, trois familles d'ondelette (Daubechies, Symlet, et Coiflet) ont été employées. En utilisant un banc de filtres de deux canaux (filtre passe bas et filtre passe haut), une convolution est effectuée entre le signal vibratoire et les deux filtres obtenant un vecteur de coefficients d'approximation  $cA1$  et un vecteur de coefficients de détails  $cD1$ . Les résultats des deux filtres sont sous échantillonnés par un facteur 2. Dans l'analyse multi résolution (MRA), le résultat du filtre passe bas ( $cA1$ ) est encore filtré par le même banc de filtres, puis sous échantillonné par le facteur 2. Cette opération est répétée selon le niveau de décomposition désiré. Un exemple de décomposition en niveau  $Nd = 3$  est représenté dans la figure 2.6

Les deux filtres passe bas et passe haut, ont leurs réponses impulsionnelles respectives  $h(n)$  et  $g(n)$ , avec :

$$g(n) = -1^n h(1 - n) \quad (5.1)$$

### 5.2.4 Phase d'extraction des caractéristiques

Une fois les coefficients d'approximation  $cA_k$  et de détails  $cD_j$  ( $1 \leq j \leq k$ ) sont déterminés, on a procédé à l'extraction de trois caractéristiques de chaque signal vibratoire :

- Energie
- Kurtosis
- Valeur efficace (RMS)

Ainsi, pour une décomposition à  $k$  niveaux :

- **L'énergie totale** du signal est donnée par :

$$E_{tot} = EA_k + \sum_{j=1}^k ED_j \quad (5.2)$$

Avec :

$$EA_k = \sum_n |a_{k,n}|^2 \quad \text{L'énergie du coefficient d'approximation } cA_k$$

Et :  $ED_j = \sum_n |d_{j,n}|^2$  Les énergies des k coefficients de détails  $D_j$

- **Kurtosis (Ku)** : du coefficient  $cA_k$  et des coefficients  $cD_j$  en utilisant l'équation 2.3
- **La valeur efficace (RMS)** du coefficient  $cA_k$  et des coefficients  $cD_j$  en utilisant l'équation 2.1

Au total, on aura un vecteur de caractéristiques des différents coefficients d'approximation et de détails :  $[E, Ku, RMS]$ .

### 5.2.5 Phase de classification

Afin de valider les performances des différentes ondelettes utilisées pour l'identification et le diagnostic des différents défauts, les trois paramètres extraits ont été utilisés pour alimenter trois (03) divers classifieurs :

1. Les K plus proches voisins (K-Nearest Neighbors : KNN).
2. Les K plus proches voisins Floue (Fuzzy K-Nearest Neighbors : F-KNN).
3. Machine à Vecteurs de Support (Support Vector Machine : SVM).

L'analyse des signaux vibratoires, ainsi que le diagnostic des différents défauts ont été traitées avec le logiciel MATLAB 2017b.

### 5.2.6 Résultats expérimentaux et commentaires

Le but de cette deuxième étape est de réaliser une étude comparative entre les trois familles d'ondelettes (Daubechies, Symlet et Coiflet) pour l'analyse des signaux vibratoires, et ce pour déterminer l'ondelette la mieux adaptée à la détection précoce et au diagnostic des défauts en termes de précision de classification.

La base de données initiale est composée de 765 signaux vibratoires, englobant quatre états de fonctionnement (Tableau 5.2). Cependant et vu que la centrale électrique de F'kirina n'est pas trop sollicitée pour le fonctionnement (disponible à l'arrêt), d'une part, et que les signaux vibratoires recueillis sont d'amplitudes relativement faibles, reflétant généralement des états sains, ou bien des débuts d'apparition des défauts (défauts naissants dus au respect des plannings de maintenance :

systematique et conditionnelle instaurés par la centrale), d'autre part. Nous avons décidé d'éliminer la classe état sain (109 signaux vibratoires), et de ne maintenir que les trois états avec défauts :

- Défaut de balourd.
- Défaut d'alignement
- Défaut de roulement

La nouvelle base de données est composée de 656 signaux. Elle a été partitionnée aléatoirement en 456 signaux (70%) pour la phase d'apprentissage, et le reste 200 signaux (30%) pour la phase de test. Les tests de simulation ont été effectués à l'aide des trois familles d'ondelettes de base (Daubechies, Symlet et Coiflet), avec différents ordres, et des niveaux de décomposition allant de 1 à 5.

- (db1, db2, db3, db4, db5, db6, db7, db8, db9, db10).
- (Sym1, Sym2, Sym3, Sym4, Sym5, Sym6, Sym7, Sym8).
- (Coif 1, Coif 2, Coif 3, Coif 4, Coif 5).

Les résultats obtenus sont résumés ci-après :

**I. Taux de classification en fonction des différentes caractéristiques**

**1. Ondelette Daubechies :**

Caractéristiques	Ondelette Daubechies		
	KNN	F-KNN	SVM
Energie	91.31	90.82	89.80
<b>Energie+ Kurtosis</b>	88.27	88.78	<b>91.33</b>
Energie+ Kurtosis+ RMS	88.27	88.27	90.82

Tableau 5.3 Taux de classification de l'ondelette Daubechies

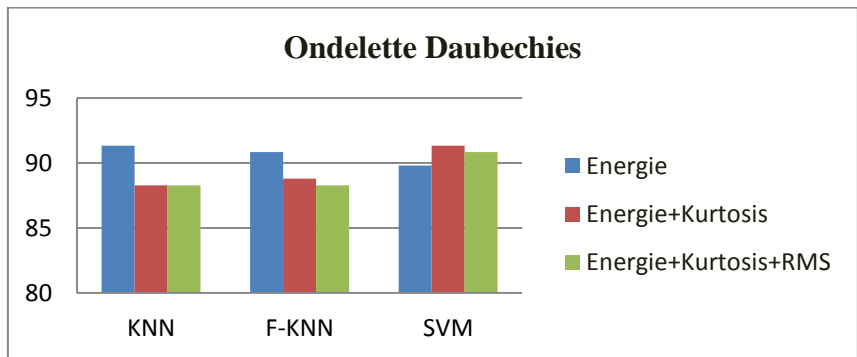


Figure 5.5 Taux de classification de l'ondelette Daubechies

2. Ondelette Symlet :

Caractéristiques	Ondelette Symlet		
	KNN	F-KNN	SVM
Energie	90.31	90.82	88.27
<b>Energie+ Kurtosis</b>	86.73	88.78	<b>90.82</b>
Energie+ Kurtosis+ RMS	86.73	88.27	90.82

Tableau 5.4 Taux de classification de l'ondelette Symlet

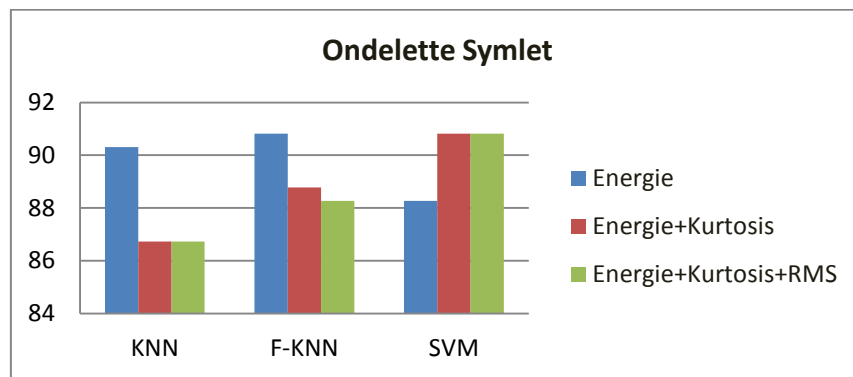


Figure 5.6 Taux de classification de l'ondelette Symlet

3. Ondelette Coiflet :

Caractéristiques	Ondelette Coiflet		
	KNN	F-KNN	SVM
Energie	88.27	88.78	89.29
<b>Energie+ Kurtosis</b>	86.22	88.27	<b>91.33</b>
Energie+ Kurtosis+ RMS	86.22	87.76	91.33

Tableau 5.5 Taux de classification de l'ondelette Coiflet




Figure 5.7 Taux de classification de l'ondelette Coiflet

## II. Comparaison entre les trois familles d'ondelettes

Ondelette	Classifieur		
	KNN	F-KNN	SVM
Daubechies	<b>88.27</b>	<b>88.78</b>	<b>91.33</b>
Symlet	86.73	88.78	90.82
Coiflet	86.22	87.76	91.33

Tableau 5.6 Taux Max de classification (%)




Figure 5.8 Taux Max de classification (%)

## III. Taux de classification de l'ondelette Daubechies en fonction du niveau de décomposition Nd

Classifieur	Niveau de décomposition : Nd				
	1	2	3	4	5
KNN	83.67	86.22	87.24	88.27	87.76
F-KNN	85.71	87.76	88.78	86.73	86.22
SVM	87.24	90.82	89.80	89.80	<b>91.33</b>

Tableau 5.7 Taux de classification de l'ondelette Daubechies en fonction du niveau de décomposition






Figure 5.9 Taux de classification de l'ondelette Daubechies en fonction du niveau de décomposition

### 5.2.7 Conclusion

D'après les résultats de simulation obtenus, on peut constater ce qui suit :

1. Malgré que la base de données collectée de la centrale électrique de F'kirina, n'est pas assez importante en nombre de signaux vibratoires, on remarque que les trois familles d'ondelette (Daubechies, Symlet, et Coiflet), ont pu donner des taux de classification acceptables, variant entre 86% et 91%, et ce avec les trois classifieurs (KNN, F-KNN, et SVM) employés.
2. D'après les taux de classification obtenus, en fonction des diverses caractéristiques :
  - Energie
  - Kurtosis
  - La valeur efficace (RMS)

On peut constater que l'utilisation seulement des deux caractéristiques (Energie et Kurtosis) a pu donner les meilleurs taux, et qu'au-delà de ces deux caractéristiques, les taux de classification sont relativement stables. Ceci peut certainement s'expliquer par le fait que les signaux vibratoires recueillis des différentes machines tournantes de cette centrale électrique ont généralement reflété des états sains, ou bien des débuts d'apparition des défauts (balourd, désalignement, ou défaut de roulement).

3. L'ondelette Daubechies combinée avec le classifieur SVM, peut être considérée comme étant la combinaison la mieux adaptée pour la séparation des différentes classes des défauts (balourd, désalignement, ou défaut de roulements), et détecter l'apparition des défauts même à un stade précoce.

### 5.3 Deuxième partie expérimentale

#### 5.3.1 Banc d'essais

Les signaux vibratoires sur lesquels nous avons effectués notre deuxième étude expérimentale sont recueillis de différents états de roulements (état sain, et états défectueux) d'un banc d'essais (figure 5.10) appartenant à l'Unité de Recherche en Matériaux Avancés (URMA) (Université Badji Mokhtar, Annaba, Algérie) du Centre de Recherche en Technologie Industrielle (CRTI).



Figure 5.10 Banc d'essais

#### 5.3.2 Constitution du banc d'essais

Le banc d'essai est constitué des équipements principaux suivants :

1. Un moteur triphasé de puissance 0.37 kW.
2. Un collecteur/Analyseur de signaux vibratoires temporels de marque : VibraQuest software (VQ-DT8) de fréquence d'échantillonnage ( $F_e = 25.6$  kHz) et temps d'acquisition ( $T_a = 10$  secondes).
3. Un variateur de vitesse de type : Lenze ESV371N01SXB
4. Trois accéléromètres piézoélectriques industriels de type : CTC AC 140-2D avec une sensibilité de 100 mV/g
5. Un jeu de roulements de type ER12K-0114, sous différents états :
  - a. Etat sain (sans défaut)
  - b. Roulement avec défaut de la bague interne (Inner Race : IR)
  - c. Roulement avec défaut de la bague externe (Outer Race : OR)
  - d. Roulement avec défaut de bille (Ball defect : B)
  - e. Roulement avec défaut combiné (Combined defect : CB)

La figure 5.11 représente les différents états de fonctionnement de roulements :



Figure 5.11 : Différents défauts de roulements :

- (a) : Défaut de bague interne (IR)
- (b) : Défaut de bille (B)
- (c) : Défaut de bague externe (OR)
- (d) : Défaut combiné (CD)

Les caractéristiques techniques des roulements utilisés sont données dans le tableau 5.8.

Modèle du roulement	ER12K-0114
Diamètre de la bague interne (mm)	29.31
Diamètre de la bague externe (mm)	47.00
Diamètre de la bille (mm)	7.93
Angle de contact (degré)	0°

Tableau 5.8 Caractéristiques techniques des roulements

### 5.3.3 Constitution de la base de données

La base de données initiale disponible contient 36 signaux vibratoires recueillis à différentes vitesses de rotation du rotor (1800 tr/mn, 2100 tr/mn, 2400 tr/mn, 2700 tr/mn, 3000 tr/mn). Chaque signal vibratoire issu du banc d’essais comporte 262146 échantillons, avec une fréquence d’échantillonnage de 25.6 kHz, soit une durée d’acquisition ( $T_a$ ) de 10 s.

Quinze (15) signaux vibratoires ont été sélectionnés : trois (03) signaux pour chaque type d’état (Etat sain, défaut de la bague interne, défaut de la bague externe, défaut de bille, et défaut combiné). Nous avons sélectionné la vitesse de rotation du rotor égale à 2700 tr/mn, soit une fréquence de rotation ( $f_r$ ) de 45 Hz correspondant à une période  $T_r$  de 0.02 s. Donc, le nombre de périodes de rotation pendant la durée d’acquisition  $T_a$  est égal à 500 périodes. On a  $f_r = 45$  Hz et la fréquence d’échantillonnage égale à 25.6 kHz. Pour calculer le nombre d’échantillons couvrant une période  $T_r$ , on divise la période de rotation  $T_r$  sur la période d’échantillonnage  $T_e$ . Le nombre

d'échantillons obtenu sera 500 échantillons. Donc la durée de 500 échantillons est égale à 20 ms. Vu le grand nombre de données (262146 échantillons), il est difficile de les traiter dans leur totalité, donc, on doit choisir un nombre permettant de ne pas perdre beaucoup d'informations. Pour cela, nous avons subdivisé chaque signal de taille 262146 en 50 signaux de 5243 échantillons chacun. La base de données temporelles finale obtenue est composée de 750 signaux vibratoires (15 x 50) de 5243 échantillons chacun.

Un état récapitulatif des cinq états de roulements, est donné dans le tableau ci-dessous :

Classe	Etat sain	Défaut de bague interne	Défaut de bague externe	Défaut de billes	Défaut combiné
Nombre de signaux	150	150	150	150	150
Total	750				

Tableau 5.9 Différents défauts de roulements

La figure 5.12 donne des exemples de signaux temporels des cinq différents états de roulement.




Figure 5.12 Représentation temporelle des signaux vibratoires des différents états de roulement issus du banc d'essais

La base de données utilisée, composée de 750 signaux vibratoires, a été partitionnée aléatoirement en 525 signaux (70%) pour la phase d'apprentissage, et le reste 225 signaux (30%) pour a phase de test.

De la même manière que la première partie expérimentale, les tests de simulation ont été exécutés à l'aide des trois fonctions d'ondelettes de base (Daubechies, Symlet et Coiflet) avec des ordres et des niveaux de décomposition différents:

- (db1, db2, db3, db4, db5, db6, db7, db8, db9, db10).
- (Sym1, Sym2, Sym3, Sym4, Sym5, Sym6, Sym7, Sym8).
- (Coif 1, Coif 2, Coif 3, Coif 4, Coif 5).

Les deux caractéristiques statistiques des signaux vibratoires à savoir : l'énergie et le Kurtosis, qui sont calculées à partir des coefficients d'ondelettes (Equations : 5.5 et 5.6) sont utilisées comme entrées pour les trois classifieurs employés (KNN, F-KNN et SVM) pour évaluer l'efficacité de chaque type d'ondelette utilisée.

#### 5.3.4 Résultats expérimentaux obtenus et discussions

L'objectif de cette deuxième partie de notre travail est de réaliser une étude comparative entre les trois familles d'ondelettes différentes (Daubechies, Symlet et Coiflet) pour l'analyse des signaux vibratoires, et ce pour déterminer l'ondelette la mieux adaptée à la détection et au diagnostic des défauts de roulement en termes de précision de classification.

Comme mentionné précédemment, cinq états de roulement ont été prises en compte : Etat sans défaut ou normal (N), défaut de la bague intérieure (IR), défaut de bille (B), défaut de la bague extérieure (OR) et défaut combiné (CB).

##### I. Ondelette Daubechies

Dans les tableaux 5.10, on présente les résultats de classification obtenus avec l'ondelette Daubechies à différents ordres, et en utilisant cinq (05) différents niveaux de décomposition.

**(A) : Classifieur KNN**

Ondelette	Niveau de décomposition				
	1	2	3	4	5
<b>db1</b>	94.14	95.55	95.55	92.7	94.14
<b>db2</b>	95.03	95.55	95.11	95.25	91.92
<b>db3</b>	93.7	92.36	<b>95.55</b>	95.11	89.98
<b>db4</b>	91.7	92.81	92.36	94.14	92.81
<b>db5</b>	92.81	92.36	93.7	92.01	92.81
<b>db6</b>	93.25	91.92	92.9	94.14	91.92
<b>db7</b>	93.25	92.81	91.47	92.7	93.25
<b>db8</b>	95.47	91.92	93.92	92.26	91.47
<b>db9</b>	93.25	91.92	93.7	93.7	93.25
<b>db10</b>	93.25	92.36	92.36	93.25	90.58
<b>Valeur Max.</b>	95.47	95.55	<b>95.55</b>	95.25	94.14
<b>Valeur Moyenne</b>	93.76	93.19	<b>93.83</b>	93.68	92.39

**(B): Classifieur F-KNN**

Ondelette	Niveau de décomposition				
	1	2	3	4	5
<b>db1</b>	93.33	93.77	94.66	94.22	94.22
<b>db2</b>	93.33	93.77	93.77	94.22	92.89
<b>db3</b>	93.77	94.22	<b>95.11</b>	94.22	95.11
<b>db4</b>	93.77	93.77	93.33	92.89	94.66
<b>db5</b>	92.44	93.33	94.66	93.54	93.33
<b>db6</b>	92.89	93.77	94.66	94.45	92.89
<b>db7</b>	92.44	94.22	92.89	94.66	93.11
<b>db8</b>	92.00	93.33	93.33	93.89	94.66
<b>db9</b>	92.44	94.22	94.66	94.22	94.66
<b>db10</b>	92.89	93.77	94.22	94.22	94.99
<b>Valeur Max.</b>	93.77	94.22	<b>95.11</b>	94.66	95.11
<b>Valeur Moyenne</b>	93.01	93.85	<b>94.22</b>	94.11	94.15

**(C): Classifieur SVM**

Ondelette	Niveau de décomposition				
	1	2	3	4	5
<b>db1</b>	96.00	95.11	94.66	92.44	90.66
<b>db2</b>	95.11	95.11	93.33	92.00	90.22
<b>db3</b>	95.11	95.55	<b>96.95</b>	92.88	91.11
<b>db4</b>	94.66	96.00	96.00	91.11	89.77
<b>db5</b>	95.55	94.66	95.11	92.00	90.66
<b>db6</b>	95.11	95.55	95.55	92.00	92.44
<b>db7</b>	94.66	94.22	94.22	91.55	89.33
<b>db8</b>	95.55	95.55	96	92.88	90.22
<b>db9</b>	95.11	95.1	95.55	90.66	90.22
<b>db10</b>	96.00	95.77	96.00	92.44	91.55
<b>Valeur Max.</b>	96.00	96.00	<b>96.95</b>	92.88	92.44
<b>Valeur Moyenne</b>	95.29	95.26	<b>95.34</b>	92.00	90.62

Tableau 5.10. Taux de classification des défauts de roulements avec l'ondelette Daubechies à différents ordres et différents niveaux de décomposition :  
(A) : Classifieur KNN, (B) : Classifieur F-KNN, (C) : Classifieur SVM

**II. Ondelette Symlet**

Dans les tableaux 5.11, on présente les résultats de classification obtenus avec l'ondelette Symlet à différents ordres, et en utilisant cinq (05) différents niveaux de décomposition.

**(A) : Classifieur KNN**

Ondelette		Niveau de décomposition				
		1	2	3	4	5
<b>Symlet</b>	<b>1</b>	94.94	94.15	95.00	93.44	94.44
	<b>2</b>	92.33	94.55	94.9	95.05	94.22
	<b>3</b>	94.88	94.66	<b>95.11</b>	95.11	92.88
	<b>4</b>	95.00	95.11	94.66	95.11	92.44
	<b>5</b>	94.00	93.33	95.11	94.44	95.00
	<b>6</b>	94.55	95.11	95.11	93.44	95.00
	<b>7</b>	94.11	94.66	94.88	94.95	94.88
	<b>8</b>	95.00	94.22	95.00	94.88	93.66
<b>Valeur Max.</b>		95.00	95.10	<b>95.11</b>	95.10	95.00
<b>Valeur Moyenne</b>		94.40	94.50	<b>94.97</b>	94.60	94.10

**(B): Classifieur F-KNN**

Ondelette		Niveau de décomposition				
		1	2	3	4	5
Symlet	1	92.24	92.68	93.57	93.13	93.13
	2	92.24	92.68	93.68	93.13	92.02
	3	92.68	93.13	<b>94.02</b>	94.02	92.02
	4	91.8	93.13	93.13	92.68	94.02
	5	91.35	91.8	93.13	93.13	93.57
	6	91.35	92.68	93.13	93.57	93.02
	7	91.8	92.24	93.13	93.57	93.57
	8	91.35	93.13	93.57	93.13	94.02
<b>Valeur Max.</b>		92.68	93.13	<b>94.02</b>	94.02	94.02
<b>Valeur Moyenne</b>		91.85	92.68	<b>93.42</b>	93.30	93.17

**(C): Classifieur SVM**

Ondelette		Niveau de décomposition				
		1	2	3	4	5
Symlet	1	95.00	95.11	95.66	92.44	90.66
	2	96.44	95.11	94.33	92.00	90.22
	3	95.11	95.55	94.66	92.88	91.11
	4	94.22	95.55	<b>96.44</b>	92.00	88.88
	5	96.00	95.55	95.55	91.55	88.88
	6	94.66	94.66	94.66	92.00	89.77
	7	95.55	95.55	95.81	92.00	89.33
	8	94.66	95.11	95.55	92.00	90.22
<b>Valeur Max.</b>		96.44	95.55	<b>96.44</b>	92.88	91.11
<b>Valeur Moyenne</b>		95.21	95.27	<b>95.33</b>	92.11	89.88

Tableau 5.11 Taux de classification des défauts de roulements avec l'ondelette Symlet à différents ordres et différents niveaux de décomposition :

(A) : Classifieur KNN (B) : Classifieur F-KNN (C) : Classifieur SVM



### III. Ondelette Coiflet

Dans les tableaux 5.12, on présente les résultats de classification obtenus avec l'ondelette Coiflet à différents ordres, et en utilisant cinq (05) différents niveaux de décomposition.

#### (A) : Classifieur KNN

Ondelette		Niveau de décomposition				
		1	2	3	4	5
Coiflet	1	93.70	92.36	<b>94.14</b>	94.14	92.81
	2	92.25	91.92	92.81	94.58	93.70
	3	93.25	92.36	93.25	95.03	94.58
	4	93.25	92.81	93.7	93.25	93.70
	5	92.25	92.81	92.81	94.14	93.70
Valeur Max.		93.70	92.81	<b>94.14</b>	95.03	94.58
Valeur Moyenne		93.05	92.45	<b>93.35</b>	92.23	93.70

#### (B): Classifieur F-KNN

Ondelette		Niveau de décomposition				
		1	2	3	4	5
Coiflet	1	92.27	92.71	93.16	93.16	94.05
	2	91.83	92.71	93.16	93.6	94.05
	3	91.83	93.16	93.6	93.16	94.05
	4	91.83	93.16	93.16	93.16	93.60
	5	91.38	93.16	<b>94.05</b>	93.16	93.16
Valeur Max.		92.27	93.16	<b>94.05</b>	93.6	94.05
Valeur Moyenne		91.83	92.98	<b>93.43</b>	93.25	93.78

(C): Classifieur SVM

Ondelette		Niveau de décomposition				
		1	2	3	4	5
Coiflet	1	96.00	95.55	95.55	93.33	89.77
	2	95.11	95.55	<b>96.00</b>	92.00	91.11
	3	94.66	94.66	93.77	90.22	89.33
	4	94.66	94.66	95.55	90.22	90.66
	5	94.66	94.66	94.22	92.00	90.22
Valeur Max.		96.00	95.55	<b>96.00</b>	93.33	91.11
Valeur Moyenne		95.02	95.02	<b>95.02</b>	91.55	90.22

Tableau 5.12 Taux de classification des défauts de roulements avec l’ondelette Coiflet à différents ordres et différents niveaux de décomposition :

(A) : Classifieur KNN (B) : Classifieur F-KNN (C) : Classifieur SVM

Un état récapitulatif des valeurs maximales de classification obtenues par les trois différentes familles d’ondelettes avec les trois classifieurs employés, est illustré dans le tableau 5.13, et représenté dans la figure 5.13

Ondelette	Classifieur		
	KNN	F- KNN	SVM
<b>Daubechies</b>	<b>95.55</b>	<b>95.11</b>	<b>96.95</b>
Symlet	95.11	94.02	96.44
Coiflet	94.14	94.05	96.00

Tableau 5.13. Taux Maximum de classification.




Figure 5.13 Taux Maximum de classification.

Aussi, les meilleures valeurs moyennes des taux de classification (correspondants au niveau de décomposition :  $N_d=3$ ), sont affichés au tableau 5.14, et représentés dans la figure 5.14

Ondelette	Classifieur		
	KNN	F- KNN	SVM
Daubechies	93.83	94.22	95.34
Symlet	94.97	93.42	95.33
Coiflet	93.35	93.43	95.02

Tableau 5.14. Taux Moyen de classification.




Figure 5.14 Taux Moyen de classification.

### 5.3.5 Conclusion

D'après les résultats de simulation obtenus, nous pouvons conclure ce qui suit :

- ❖ Les trois familles d'ondelettes présentent des taux très acceptables de classification des défauts des roulements, et ce avec les trois classifieurs.
- ❖ Pour la phase de prétraitement des signaux vibratoires, et d'après les valeurs moyennes calculées (mentionnées dans le tableau 5.14, et représentées dans la figure 5.14), on peut conclure que le niveau 3 est relativement le niveau de décomposition le plus approprié donnant les meilleures performances pour les trois familles d'ondelettes, et ce quel que soit le type de classifieur utilisé.
- ❖ Pour les classifieurs KNN et F-KNN, le nombre de voisins utilisé  $K = 3$ , s'est avéré être la valeur optimale après avoir testé plusieurs valeurs de 1 à 10.
- ❖ Un état comparatif a été établi entre les valeurs maximales des taux de classification trouvées (mentionnées dans le tableau 5.13, et représenté dans la figure 5.13). Cet état révèle que l'ondelette Daubechies surpasse les autres ondelettes en matière de classification des défauts de roulements, et ce pour les différents classifieurs utilisés.

Cette deuxième partie a fait l'objet de participation à une conférence internationale sur les énergies renouvelables, systèmes et applications (ICSRESA 19), tenue en Décembre 2019, à Tébessa (Algérie), par un article intitulé « Bearing Faults Diagnosis Using Discrete Wavelets and Artificial Intelligence Approaches » [157].

## 5.4 Troisième partie expérimentale

Etant donné que la transformée en ondelettes discrète (DWT) peut être implémentée au moyen d'un banc de filtres d'ondelette composé d'un filtre passe-bas et un filtre passe-haut à réponses impulsionnelles finies. Et au lieu d'utiliser des ondelettes standards telles que (Ondelette de Morlet, Daubechies, Symlet, .... etc.), pour la décomposition et l'analyse des signaux vibratoires, cette troisième partie de notre travail de thèse est consacrée à proposer une nouvelle technique basée sur la conception de filtres d'ondelettes, les mieux adaptés au diagnostic des défauts de roulements.

Inspirée de la méthode récursive proposée par Sherlock et al qui est basée sur la représentation polyphase. Cette technique permet de générer les coefficients d'un filtre passe bas  $\{h_0, h_1, \dots, h_{2N-1}\}$  de longueur  $2N$ , ainsi que ceux du filtre passe haut correspondant à travers seulement  $N$  paramètres angulaires  $\{\theta_0, \theta_1, \dots, \theta_{N-1}\}$  prenant des valeurs appartenant à l'intervalle  $[0, 2\pi[$ . Parmi les algorithmes d'optimisation étudiés au chapitre 4, l'algorithme PSO a été choisi pour optimiser les coefficients des filtres d'ondelette conduisant à la conception de l'ondelette la mieux adaptée pour la classification des défauts de roulements. La fonction « Objectif » ou « fitness » adoptée, est basée sur le taux d'erreur de classification.

En conséquence, la conception d'une transformation d'ondelette discrète DWT, peut être considérée comme un problème d'optimisation dans l'espace  $\mathcal{R}^N$  des paramètres angulaires  $\theta_i$ .

En plus des trois types de classifieurs utilisés dans les deux parties expérimentales précédentes, un quatrième classifieur a été rajouté (Artificial Neural Network : ANN).

Une étude comparative a été menée entre la meilleure ondelette (ondelette Daubechies), approuvée dans la deuxième partie du travail, et notre ondelette optimisée PSO-DWT pour le diagnostic des défauts de roulements.

### 5.4.1 Procédure d'optimisation des filtres d'ondelette

La procédure d'optimisation des filtres d'ondelette (illustrée selon l'organigramme de la figure 5.15), pour un ordre de filtre fixe et un niveau de décomposition donné, est implémentée selon les étapes suivantes :

1. Définir l'ordre du filtre d'ondelette  $N_o = \text{ordre\_min}$
2. Définir le niveau de décomposition  $N_d = \text{décomp\_min}$
3. Générez une population initiale de particules. où chaque particule est un vecteur de position angulaire  $\{\theta_0, \theta_1, \dots, \theta_{N_o-1}\}$  sélectionné aléatoirement dans l'intervalle  $[0, 2\pi[$ .
4. Pour chaque particule, évaluez la fonction de fitness :
  - a. Insérez le vecteur des  $\theta_i$ 's dans l'algorithme itératif pour produire les  $2N_o + 2$  coefficients du filtre passe-bas selon les équations (2.23) et (2.24).
  - b. Déterminez les coefficients du filtre passe-haut  $\{g_i\}$  en utilisant l'algorithme de retournement alterné donné par l'équation (2.25).
  - c. En utilisant les filtres passe-bas et passe-haut ainsi obtenus. appliquez la décomposition d'ondelette discrète selon le niveau prédéfini  $N_d$  au signal de vibration pour extraire le vecteur de caractéristiques composé des énergies et du Kurtosis:
 
$$[E_1, E_2, \dots, E_{N_d+1}, K_1, K_2, \dots, K_{N_d+1}]$$
  - d. Utilisez le vecteur des caractéristiques comme vecteur d'entrée au classifieur et évaluez le pourcentage de taux d'erreur de la classification.
5. Mettez à jour la vitesse et la position de chaque particule selon les éqs. (4.1) et (4.2).
6. Répétez les étapes 4 à 5 jusqu'à ce que les conditions de convergence soient satisfaites. Notez que lorsqu'il n'y a plus d'amélioration du pourcentage du taux d'erreur de classification pendant 20 itérations consécutives, la convergence est considérée atteinte.
7. Incrémentez le niveau de décomposition  $N_d \leftarrow N_d + 1$  et répétez les étapes 3 à 6.
8. Incrémentez l'ordre du filtre  $N_o \leftarrow N_o + 2$  et répétez les étapes 2 à 7.

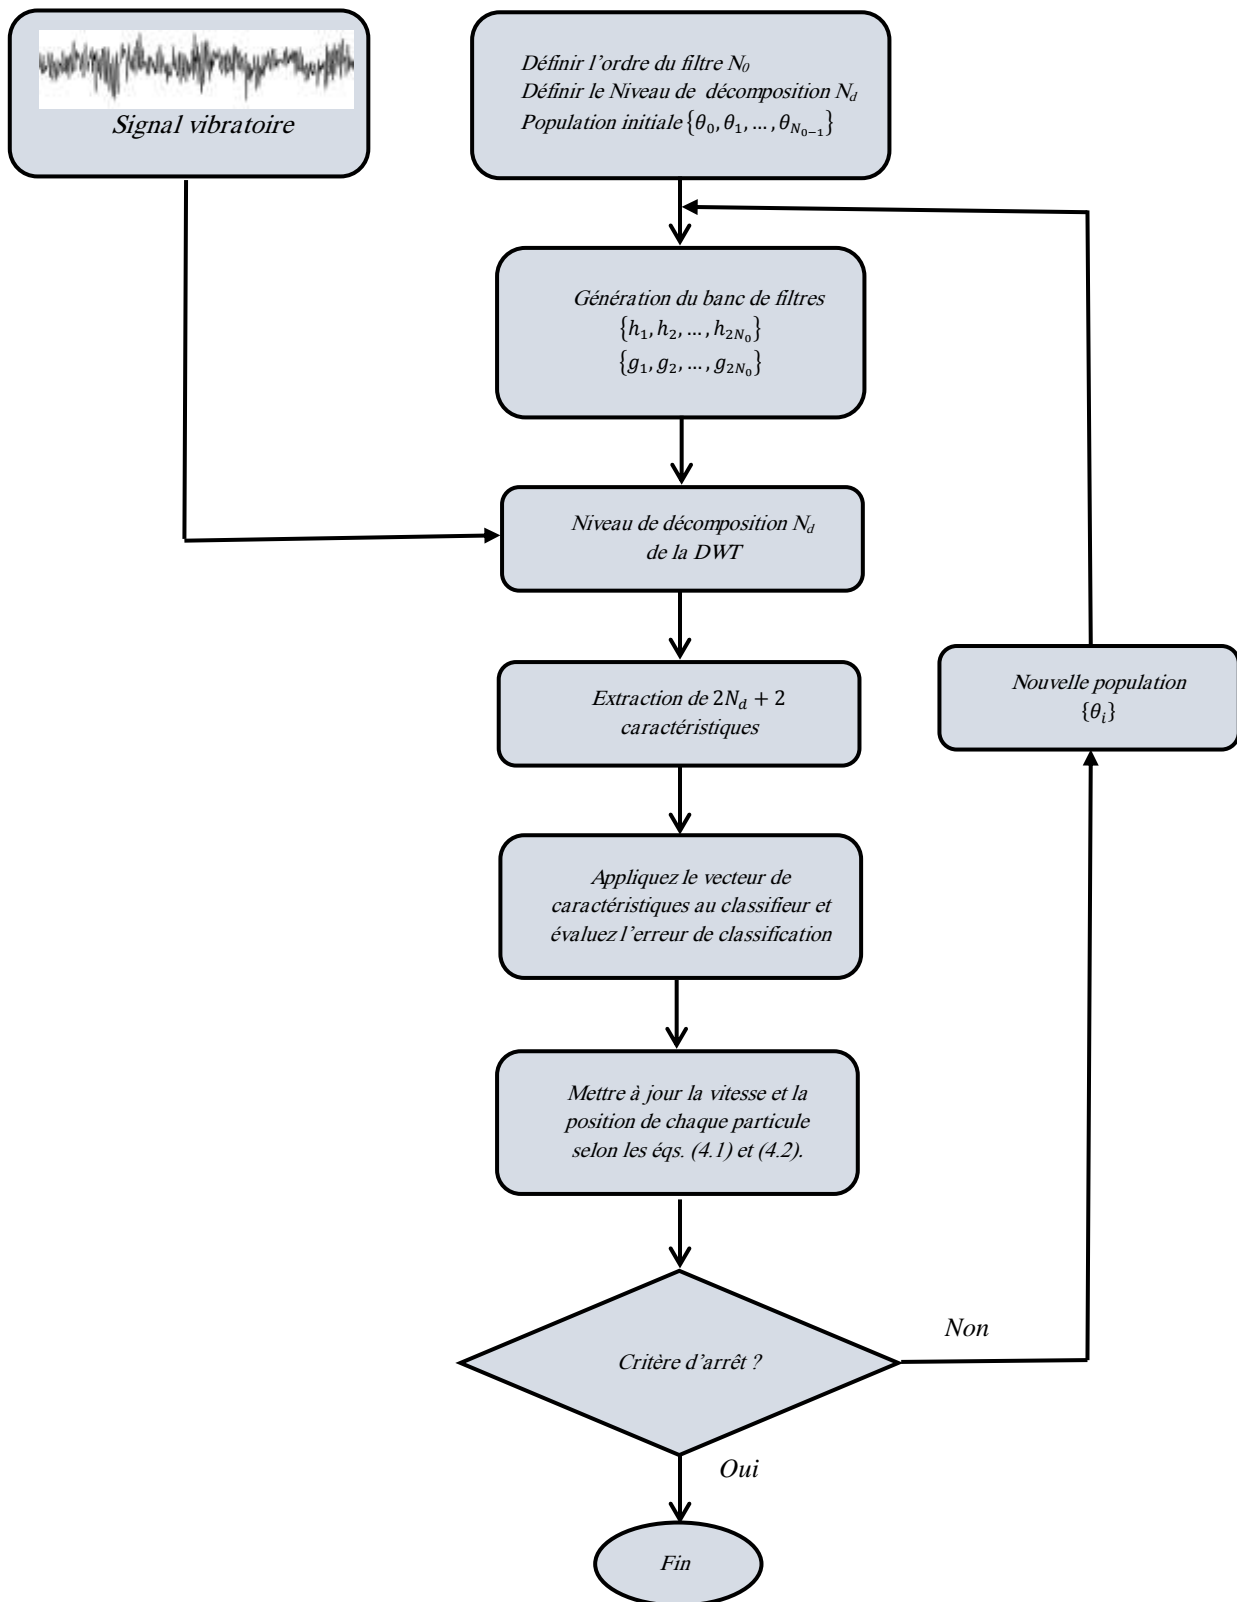


Figure 5.15 Organigramme d'optimisation des filtres d'ondelette basée sur l'algorithme PSO

### 5.4.2 Résultats expérimentaux et discussions

Pour évaluer les performances de la méthode d'optimisation des filtres d'ondelette proposée, et pour juger l'efficacité des caractéristiques d'ondelettes extraites par rapport à la précision de la classification, plusieurs tests de simulation, ont été réalisés à l'aide de quatre classifieurs à savoir : K-Nearest Neighbors (KNN), Fuzzy K-Nearest Neighbors (FKNN), Artificial Neural Network (ANN) et Support Vector Machine (SVM). Notez que la même base de données utilisée précédemment, composée de 750 signaux vibratoires, partitionnée aléatoirement en 525 signaux (70%) pour la phase d'apprentissage, et le reste 225 signaux (30%) pour la phase de test, a été employée. Généralement, la taille de l'essaim de particules est un compromis entre les performances de l'algorithme et le temps nécessaire de son exécution [158]. De plus, le nombre maximum d'itérations est un paramètre important qui peut affecter les performances de l'algorithme PSO, où une valeur entre 50 et 200 est une suggestion appropriée qui peut conduire à de bons résultats [159].

Dans notre travail, la taille de l'essaim de particules est choisie égale à 25 et le nombre maximum de générations est fixé à 100. Pour obtenir de bons résultats, un poids d'inertie ( $w$ ) décroissant linéaire est adopté et les paramètres cognitifs et sociaux sont fixés à  $c_1 = 1,5$  et  $c_2 = 2,0$  respectivement [159]. Pour éviter l'effet du choix initial de la population, 20 simulations sont exécutées à chaque fois, et les meilleurs résultats sont enregistrés. Etant donné qu'il a été montré dans la deuxième partie du travail, que l'ondelette Daubechies surpassait les autres ondelettes (Symlet et Coiflet) en matière de classification des défauts de roulements, et ce pour les différents classifieurs utilisés (Voir tableau 5.13, et figure 5.14). Alors, cette étude comparative des performances de classification va se limiter entre l'ondelette proposée PSO-DWT, et l'ondelette Daubechies en utilisant les quatre différents classifieurs.

Dans le tableau 5.15, on présente les résultats de classification obtenus pour les quatre classifieurs, en utilisant cette fois-ci l'ondelette Daubechies avec huit (08) différents niveaux de décomposition.

Classifieur	Niveau de décomposition $N_d$							
	1	2	3	4	5	6	7	8
KNN	93.77	92.36	95.55	95.11	89.98	92.44	90.67	88.67
F-KNN	93.77	94.22	95.11	94.22	95.11	96.33	95.89	94.44
ANN	92.89	90.67	96.00	91.11	91.11	89.78	87.56	90.67
SVM	95.11	95.55	96.95	92.88	91.11	93.44	95.10	95.23

Tableau 5.15. Taux de classification (%) en utilisant l'ondelette Daubechies en fonction des niveaux de décomposition pour les quatre classificateurs




Figure 5.16 Taux de classification (%) en utilisant l’ondelette Daubechies en fonction des niveaux de décomposition pour les quatre classificateurs

En utilisant les étapes d’optimisation des filtres d’ondelettes décrites dans la section 5.4.1, et en fixant le niveau de décomposition  $N_d = 3$ .

Les résultats de classification des quatre classifieurs adoptés, donnés dans le tableau 5.16 et la figure 5.17, montrent que l’ondelette optimisée fournit les meilleures performances de classification à des ordres de filtre supérieurs ou égaux à 6. Par conséquent, un ordre de filtre en ondelettes de 6 représenterait un choix optimal.

Ordre du Filtrer $N_\theta$	Performances de l’ondelette optimisée (%)			
	KNN	FKNN	ANN	SVM
4	97,33	98,22	96,89	97,33
6	97,47	98,87	97,78	98,40
8	97,47	98,87	97,78	98,40
10	97,47	98,87	97,78	98,40
12	97,47	98,87	97,78	98,40

Tableau 5.16 Taux de classification (%) de l’ondelette optimisée PSO-DWT en fonction de l’ordre des filtres pour les quatre classificateurs



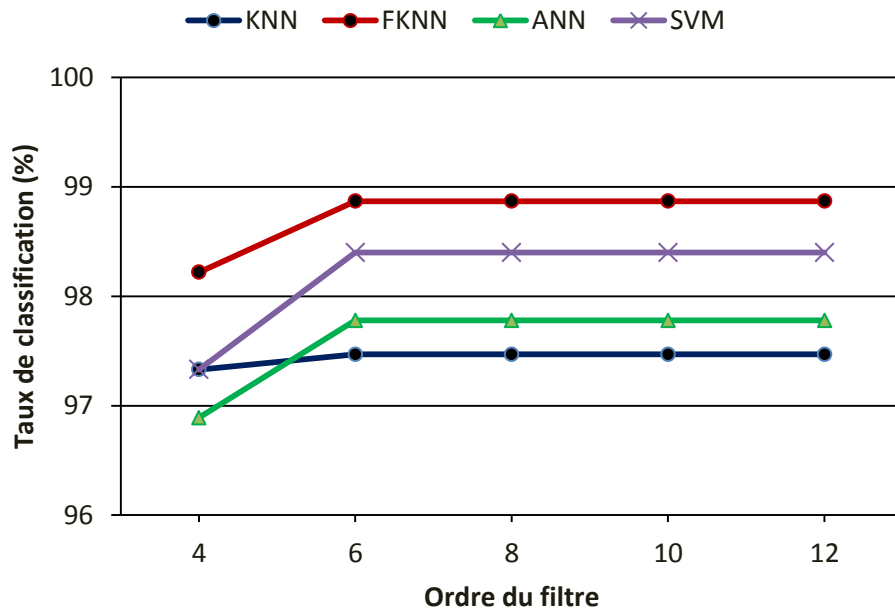


Figure 5.17. Taux de classification (%) de l’ondelette optimisée PSO-DWT en fonction de l’ordre des filtres pour les quatre classificateurs

Ainsi, le système de détection et de diagnostic des défauts de roulements proposé PSO-DWT est de niveau de décomposition  $N_d = 3$ , et dont les coefficients des filtres d’ondelette (ordre  $N_0 = 6$ ) sont reportés dans le tableau 5.17 pour les quatre classificateurs.

Coefficients des filtres d’ondelette						
KNN	0.3828	0.1919	0.6180	-0.0707	-0.2937	0.5859
FKNN	0.6097	0.3238	-0.0462	0.6537	0.1436	-0.2704
ANN	0.8507	0.4723	-0.1191	0.1907	-0.0244	0.0440
SVM	0.4407	0.0038	0.2650	0.8456	0.0012	0.1424

Tableau 5.17 Coefficients des filtres d’ondelettes conçues d’ordre 6

Enfin, l’étude comparative réalisée, révèle que les taux de classification de l’ondelette PSO-DWT proposée surpassent ceux obtenus par l’ondelette Daubechies, et ce quel que soit le type du classifieur utilisé.

Les taux de classification obtenus, rapportés dans le tableau 5.18 et représentées sur la figure 5.18, montrent clairement que l’ondelette optimisée améliore la précision de classification avec un gain en pourcentage moyen d’environ 2%, soit des taux de classification avoisinant 98,4 %.

	KNN	FKNN	ANN	SVM
Ondelette Daubechies (db)	95,55	95,11	96	96,95
Ondelette PSO-DWT	97,47	97,87	97,78	98,4

Tableau 5.18 Etude comparative des taux de classification des défauts de roulement




Figure 5.18. Etude comparative des taux de classification des défauts de roulement

### 5.4.3 Conclusion

D'après les résultats de simulation obtenus, on peut conclure ce qui suit :

- ❖ L'ondelette optimisée PSO-DWT a fourni des taux très élevés de classification des défauts de roulements, et ce quel que soit le classifieur utilisé.
- ❖ Les paramètres de l'algorithme d'optimisation ont été bien sélectionnés, permettant d'atteindre ces taux de classification.
- ❖ L'ordre des filtres d'ondelette optimisée PSO-DWT supérieur ou égal à 6, présente les meilleures performances de classification. Par conséquent, un ordre de filtre en ondelettes de 6 représenterait un choix optimal.
- ❖ L'ondelette PSO-DWT proposée, a apporté une amélioration de la précision de classification avec un gain en pourcentage moyen d'environ 2% par rapport à la meilleure ondelette (Daubechies), sélectionnée dans la deuxième partie expérimentale.

Enfin, cette troisième partie expérimentale, a fait l'objet d'une publication d'article intitulé « Discrete Wavelet Design for Bearing Fault Diagnosis Using Particle Swarm Optimization » dans le Journal Européen des Systèmes Automatisés (JESA) [160].

---

## Conclusion Générale

Dans le cadre de la maintenance préventive conditionnelle appliquée aux machines tournantes, les signatures vibratoires figurent parmi les meilleurs indicateurs d'état. Leur acquisition, leur suivi et surtout leur analyse constituent alors des étapes déterminantes pour un diagnostic fiable permettant d'augmenter la disponibilité de ces machines et d'éviter des arrêts intempestifs pouvant amputer lourdement la capacité de production et donc accroître le prix de revient. L'analyse vibratoire en maintenance permet d'intervenir à trois niveaux d'analyse à partir de mesures vibratoires : la surveillance à l'aide d'indicateurs dits globaux, le diagnostic avec des techniques avancées et le suivi qui permet de prédire le comportement de l'élément étudié.

Dans ce travail de thèse, nous avons mis en œuvre un système de diagnostic automatisé en vue de quantifier et de localiser les sources vibratoires générées par les principaux défauts pouvant altérer le bon fonctionnement d'un groupe turbogénérateur d'une centrale électrique.

Pour aborder ce travail, nous avons tout d'abord présenté un historique succinct sur la production de l'énergie électrique, et son rôle stratégique dans le développement des pays et le confort des populations à travers le monde entier. Ensuite, nous avons dressé un état descriptif d'un groupe turbogénérateur d'une centrale électrique. Le mode de fonctionnement d'une turbine à gaz, ainsi que ses différents équipements principaux et auxiliaires, ont été également présentés.

Par la suite, nous avons rappelé les différentes stratégies de maintenance appliquées dans le monde industriel. Une étude détaillée a été menée principalement sur la maintenance préventive conditionnelle, ainsi que ses principaux objectifs. Une synthèse des principaux défauts pouvant exister dans les machines tournantes a été présentée.

Dans la littérature, et afin de concrétiser une démarche de surveillance et de diagnostic des machines tournantes, deux grandes familles de méthodes peuvent être envisagées : celles qui utilisent un modèle mathématique du système à surveiller, appelées aussi les méthodes internes, et celles qui consistent à analyser les signaux mesurés, appelées aussi les méthodes externes. Les comparaisons effectuées entre ces méthodes nous amènent à privilégier les méthodes externes, ne nécessitant pas d'élaboration de modélisations complexes et pouvant se passer d'une information exhaustive souvent indisponible. Parmi les diverses techniques issues des méthodes externes qui ont été présentées dans notre travail, une description approfondie a été consacrée à l'analyse vibratoire objet de notre thèse. Ensuite, un état de l'art des différentes techniques classiques et récentes de traitement de signal permettant l'analyse des signaux vibratoires révélateurs de défauts a été dressé. Une attention particulière a été réservée à la technique de transformation par ondelettes.

Enfin, et étant donné qu'une ondelette peut être implémentée au moyen d'un banc de filtres comprenant un filtre passe-bas et un filtre passe-haut, nous avons développé la notion de représentation polyphase d'un banc de filtres d'ondelette. Pour cela, et en utilisant la procédure de factorisation de matrice polyphase initiée par Vaidyanathan, ainsi que la méthode récursive proposée par Sherlock et Monro, nous avons pu concevoir une ondelette en générant les différents coefficients de ses filtres, en fonction des paramètres angulaires.

En outre, et vu que les méthodes classiques d'analyse et de diagnostic des machines tournantes, précédemment exposées présentent encore des limitations. Une autre partie du travail de la thèse a consisté à introduire la procédure de mise en œuvre d'un système de décision basé sur la reconnaissance des formes. Le mécanisme de mise en place d'un système de diagnostic à base de

reconnaissance des formes nécessite tout d'abord l'existence d'une base de mesures de signaux vibratoires réalisées sur le processus et totalement étiquetées. Un ensemble d'apprentissage et un ensemble de test, totalement disjoints, en sont extraits. L'ensemble d'apprentissage est utilisé pour effectuer le choix des paramètres caractéristiques des défauts recherchés. Ces paramètres sont rassemblés dans un vecteur forme, appelé aussi signature caractéristique du processus à surveiller. Afin d'éliminer les paramètres du vecteur forme qui sont peu informatifs, corrélés ou même redondants, et de ne maintenir que ceux les plus pertinents et les plus représentatifs pour la reconnaissance, plusieurs techniques de sélection et de transformation de l'information peuvent être employées.

Une fois le vecteur d'entrée construit, la dernière étape consiste à la construction des règles de décision permettant la classification automatique d'une nouvelle mesure vibratoire ou observation, c'est à dire de décider automatiquement du mode de fonctionnement (sain ou défectueux), que représente cette mesure. Un état de l'art a été présenté pour quelques règles de décision issues de l'intelligence artificielle, dont quatre ont été utilisées dans notre travail de thèse, à savoir : Les Réseaux de Neurones Artificiels (ANN), Machines à Vecteurs Support (SVM), la méthode des K Plus Proches Voisins (KNN), ainsi que son extension floue (F-KNN). Pour finir, des techniques Métaheuristiques d'optimisation, ont été employées à des fins d'amélioration des performances de classification.

Enfin, et dans le but de la validation des procédures d'analyse et de diagnostic des différents défauts pouvant se manifester au niveau des machines tournantes d'un groupe turbogénérateur, notre travail a été scindé en trois parties expérimentales :

Dans la première partie expérimentale, nous avons employé deux outils de traitement de signal à savoir l'analyse spectrale, et l'analyse temps-échelle. Une base de données réelles a été collectée de la centrale électrique de F'kirina (2 x 146,2 MW). Cette base de données est composée de signaux vibratoires, recueillis des différents équipements principaux et auxiliaires des groupes turbogénérateurs. Plusieurs caractéristiques statistiques des signaux vibratoires à savoir : L'énergie, le Kurtosis, la valeur efficace (RMS), le Skewness, et la moyenne absolue, ont été extraites des coefficients d'approximation et de détails des ondelettes. Ces caractéristiques ont été par la suite, employées pour alimenter différents classifieurs. Une étude comparative de performance de classification des différents défauts (défaut de balourd, désalignement, et défaut de roulements), a été menée entre trois familles d'ondelettes (Ondelette Daubechies, Symlet, et Coiflet). Cette comparaison a été validée à travers trois différents classifieurs (KNN, F-KNN, et SVM).

Cette validation nous a permis de constater que malgré que la base de données collectée de la centrale électrique de F'kirina, n'est pas assez riche en termes de signaux vibratoires, les trois familles d'ondelette (Daubechies, Symlet, et Coiflet), ont pu donner des taux de classification acceptables atteignant les 91.50%, et ce avec les trois classifieurs (KNN, F-KNN, et SVM) employés. Aussi, les simulations effectuées nous ont montré que les deux caractéristiques (Energie et Kurtosis), étaient suffisantes pour donner les meilleurs résultats et qu'au-delà de ces deux caractéristiques, les taux de classification sont relativement stables. Ceci peut certainement s'expliquer par le fait que les signaux vibratoires recueillis des différentes machines tournantes de cette centrale électrique ont généralement reflété des états sains, ou bien des débuts d'apparition des défauts. Enfin, l'ondelette Daubechies combinée avec le classifieur SVM, peut être considérée comme étant la combinaison la mieux adaptée pour la séparation des différentes classes des défauts

(balourd, désalignement, ou défaut de roulements), et pour détecter l'apparition de ces défauts même à un stade précoce.

Dans la deuxième partie expérimentale, et vu que les roulements constituent des composants indispensables dans le parc des machines tournantes des centrales électriques. En outre, ces composants par leur dégradation, peuvent causer environ 30% des indisponibilités des groupes turbogénérateurs des centrales électriques. Nous avons proposé de faire une étude approfondie sur les différents défauts pouvant se manifester principalement dans les roulements. Pour cela, un banc d'essais expérimental du Centre de Recherche en Technologie Industrielle (CRTI) de l'université d'Annaba, a été utilisé. Les signaux vibratoires, ont été collectés sous cinq états de fonctionnement de roulements : Etat sans défaut ou normal (N), défaut de la bague intérieure (Inner Race : IR), défaut de bille (Ball : B), défaut de la bague extérieure (Outer Race : OR) et défaut combiné (Combined Defect : CB). Deux caractéristiques des défauts des signaux vibratoires (Energie et le Kurtosis) extraites des coefficients d'approximation et de détails des ondelettes, ont été employées pour alimenter les trois classifieurs (KNN, F-KNN, et SVM). Les résultats de simulation obtenus, nous ont permis de conclure que ces trois familles d'ondelettes sont bien adaptées pour l'analyse des signaux vibratoires des roulements. Les taux de classification obtenus sont très encourageants atteignant 96,95%. L'état comparatif a révélé que l'ondelette Daubechies dépasse les autres ondelettes en termes de classification des défauts de roulements, et ce quel que soit le classifieur utilisé.

Dans la troisième partie expérimentale, et comme ça était déjà mentionné que toute ondelette discrète peut être implémentée au moyen d'un banc de filtres comprenant un filtre passe-bas et un filtre passe-haut. Et au lieu d'utiliser des ondelettes standards pour l'analyse des signaux vibratoires des roulements, notre contribution a consisté à proposer un algorithme de conception d'une ondelette discrète basé sur la représentation polyphase des bancs de filtres. Cet algorithme nous a permis de générer les coefficients des deux filtres passe bas et passe haut, de cette ondelette. La mise au point d'un algorithme d'optimisation par essais particuliers (PSO), et son utilisation dans un processus d'optimisation nous ont permis d'obtenir l'ondelette discrète PSO-DWT la mieux adaptée pour l'analyse et le diagnostic des défauts de roulements.

Une étude comparative a été menée entre la meilleure ondelette approuvée dans la deuxième partie, en termes de performance de classification (ondelette Daubechies), et l'ondelette optimisée PSO-DWT pour le diagnostic des défauts de roulements. Cette comparaison a été validée à travers, en plus des trois classifieurs déjà utilisés (KNN, F-KNN, et SVM), un quatrième classifieur (ANN). Cette validation nous a permis de conclure qu'en plus de sa simple implémentation, l'ondelette PSO-DWT proposée, surpassait les autres types d'ondelettes en termes de performance de classification, en réalisant une amélioration de la précision de classification avec un gain en pourcentage d'environ 2% par rapport à la meilleure ondelette (Daubechies), soit un taux de classification réalisé d'environ 98,40%. Les simulations effectuées nous ont aussi confirmé que les paramètres de l'algorithme d'optimisation ont été bien sélectionnés, permettant d'atteindre ces taux de classification.

En conséquence, la combinaison des techniques de traitement des signaux et de l'intelligence artificielle a permis en plus de fournir des outils de diagnostic efficaces, de quantifier la pertinence des sources d'information exploitées. Aussi, on peut conclure que l'ondelette PSO-DWT conçue, présente un outil très efficace et précieux dans le cadre d'analyse des signaux vibratoires, et du diagnostic précoce des défauts de roulements dans les machines tournantes.

Enfin, les travaux réalisés dans le cadre de cette thèse pourraient donner lieu à des études supplémentaires sur plusieurs points :

- ❖ Une méthode de sélection des paramètres caractéristiques pourrait être intégrée dans le processus, car cela permettrait d'utiliser plusieurs paramètres et d'en sélectionner les plus pertinents.
- ❖ Une étude approfondie sur l'évolution des classes ("saine" et "défectueuse") en fonction de changement des conditions de fonctionnement (variation de vitesse, variation de charges, etc.) sera bien utile pour compléter l'étude menée dans ce travail.
- ❖ Utiliser d'autres algorithmes d'optimisation des paramètres angulaires, tel que l'algorithme génétique.
- ❖ Enfin, appliquer cette démarche de diagnostic sur d'autres équipements tel que : les engrenages.

---

# Bibliographie

- [1] DIOUF, Saliou. Contribution au diagnostic industriel de défauts de roulement et de balourd par techniques neuronales : application à la machine asynchrone à cage. 2007. Thèse de doctorat. Paris 12.
- [2] SALLES, Gaël. Surveillance et diagnostic des défauts de la charge d'un entraînement par machine asynchrone. 1997. Thèse de doctorat de l'Université Claude Bernard Lyon1.
- [3] WANG, Fengtao, SUN, Jian, YAN, Dawen, et al. A feature extraction method for fault classification of rolling bearing based on PCA. In: Journal of Physics: Conference Series. IOP Publishing, 2015. p. 012079.
- [4] ARDJANI, Fatima, SADOUNI, Kaddour, et BENYETTOU, Mohamed. Optimization of SVM multiclass by particle swarm (PSO-SVM). In: 2010 2nd International Workshop on Database Technology and Applications. IEEE, 2010. p. 1-4.
- [5] FARGE, Marie. Wavelet transforms and their applications to turbulence. Annual review of fluid mechanics, 1992, vol. 24, no 1, p. 395-458.
- [6] RIOUL, Olivier et VETTERLI, Martin. Wavelets and signal processing. IEEE signal processing magazine, 1991, vol. 8, no 4, p. 14-38.
- [7] SHERLOCK, Barry G. et MONRO, Donald M. On the space of orthonormal wavelets. IEEE Transactions on Signal Processing, 1998, vol. 46, no 6, p. 1716-1720.
- [8] HONGTAO, XUE. Study on Intelligent Condition Diagnosis Based on Vibration Information and Support Vector Machine for Plant Machinery. 2014.
- [9] MATTIOLI, Juliette, ROBIC, Pierre-Olivier, et REYDELLET, Thomas. L'intelligence artificielle au service de la maintenance prévisionnelle. In : 4ème conférence sur les Applications Pratiques de l'Intelligence Artificielle APIA2018. 2018.
- [10] DUCHEMIN, Gilles. Maintenance des machines et des moteurs. Ed. Techniques Ingénieur, 2006.
- [11] LUCE, Stéphane. Amélioration de la disponibilité des équipements de production par l'optimisation de la gestion des stocks de maintenance. 1994. Thèse de doctorat. Reims.
- [12] RANDALL, Robert Bond. Vibration-based condition monitoring: industrial, aerospace and automotive applications. John Wiley & Sons, 2011.
- [13] HENG, Jean. Pratique de la Maintenance préventive » édition" Dunod. 2002.

- [14] BRENEUR, Claire. Eléments de maintenance préventive de machines tournantes dans le cas de défauts combinés d'engrenages et de roulements. 2002. Thèse de doctorat. Lyon, INSA.
- [15] KERROUMI, Sanaa. Extraction des paramètres et classification dynamique dans le cadre de la détection et du suivi de défaut de roulements. 2016. Thèse de doctorat. Université de Reims Champagne-Ardenne.
- [16] KAIDI, Ismahene et KABOUCHE, Abdallah. Analyse du défaut de balourd dans un palier hydrodynamique. Synthèse : Revue des Sciences et de la Technologie, 2018, vol. 36, p 87-102.
- [17] MOREL, Jacques. Surveillance vibratoire et maintenance prédictive. Techniques de l'ingénieur. Mesures et contrôle, 2002, no R6100, p. R6100. 1-R6100. 20.
- [18] BOURAS, Abdelkrim. Détection Prédictive des Anomalies des Moteurs de Moyenne Tension lors des Défauts Combinés. 2015. Thèse de doctorat. Université Badji Mokhtar, Annaba, 2015.
- [19] OULMANE, Abdelhak. Surveillance et diagnostic des défauts des machines tournantes dans le domaine temps-fréquences utilisant les réseaux de neurones et la logique floue. 2014. Thèse de doctorat. École Polytechnique de Montréal.
- [20] MORET, M. et GUAY, P. Roulements-Les différents types et montages. Techniques de l'ingénieur, 2013.
- [21] CHIEMENTIN, Xavier. Localisation et quantification des sources vibratoires dans le cadre d'une maintenance préventive conditionnelle en vue de fiabiliser le diagnostic et le suivi de l'endommagement des composants mécaniques tournants : application aux roulements à billes. 2007. Thèse de doctorat. Reims.
- [22] ONDEL, Olivier. Diagnostic par reconnaissance des formes : Application à un ensemble convertisseur-machine asynchrone. 2006. Thèse de doctorat. Ecole Centrale de Lyon.
- [23] COLLACOTT, Ralph Albert. Vibration Monitoring and Diagnosis : Techniques for cost-effective plant maintenance. G. Godwin, 1979.
- [24] ISERMANN, Rolf. Process fault detection based on modeling and estimation methods—A survey. Automatica, 1984, vol. 20, no 4, p. 387-404.
- [25] MOBLEY, R. Keith. La maintenance prédictive. Masson, 1992.
- [26] RAYMOND, J. et GUYER, A. Rolling Bearings Handbook and Troubleshooting Guide. Radnor, PA : Chilton, 1996.



- [27] BELMADH D.K., *Technic of maintenance*, 2<sup>ème</sup> édition, Université Pierre et Marie Curie- Paris VI, 2006.
- [28] MIGEON, C. *Emission Acoustique et Analyse Vibratoire Pour l'Etude des Défauts de Roulements pour Différents Régimes Moteurs*. Thèse de doctorat. Université de Reims Champagne-Ardenne, 2011.
- [29] ZANI, Marie-Line. *Mesures mécaniques : surveillance des machines tournantes*. Guide d'achat, Mesures, 2003, no 757, p. 77-84.
- [30] PUSEY, Henry C. et HOWARD, Paul L. *An historical view of mechanical failure prevention technology*. *Sound and Vibration*, 2008, p. 11.
- [31] MOREL, Jacques. *Vibrations des machines et diagnostic de leur état mécanique*. 1992.
- [32] GOURIVEAU, R., MEDJAHHER, Kamal, RAMASSO, Emmanuel, et al. *PHM-Pronostics and Heath management-De la surveillance au pronostic de défaillances de systèmes complexes*. *Techniques de l'Ingénieur*, 2013, vol. 9.
- [33] KHOV, Makara. *Surveillance et diagnostic des machines synchrones à aimants permanents Détection des courts-circuits par suivi paramétrique*. 2009. Thèse de doctorat. Institut National Polytechnique de Toulouse.
- [34] JARDINE, Andrew KS, LIN, Daming, et BANJEVIC, Dragan. *A review on machinery diagnostics and prognostics implementing condition-based maintenance*. *Mechanical systems and signal processing*, 2006, vol. 20, no 7, p. 1483-1510.
- [35] DJEBILI, Omar. *Contribution à la maintenance prédictive par analyse vibratoire des composants mécaniques tournants. Application aux butées à billes soumises à la fatigue de contact de roulement*. 2013. Thèse de doctorat. Université de Boumerdés.
- [36] BOGARD, Fabien. *Développement d'une approche numérique visant à optimiser le suivi vibratoire des constituants d'une machine tournante*. 2000. Thèse de doctorat. Reims.
- [37] GIBERT, Dominique. *Éléments de traitement du signal*. 1994.
- [38] Imaouchen Yacine. *Mesure et analyse des vibrations des machines électriques tournantes*. 2015. Thèse de Doctorat. Université de Béjaia.
- [39] TANDON, Naresh et CHOUDHURY, Achintya. *A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings*. *Tribology international*, 1999, vol. 32, no 8, p. 469-480.

- 
- [40] ESTOCQ, Philippe. Une approche méthodologique numérique et expérimentale d'aide à la détection et au suivi vibratoire de défauts d'écaillage de roulements à billes. 2004. Thèse de doctorat. Université de Reims.
- [41] BOULENGER, Alain et PACHAUD, Christian. Diagnostic vibratoire en maintenance préventive. Dunod, 1998.
- [42] BENNEVAULT, B. Détection précoce et analyse des défauts dans les roulements : analyse d'enveloppe et facteur de crête. Matériaux mécanique électricité N°427 septembre 1988.
- [43] MARTIN, H. R. et HONARVAR, F. Application of statistical moments to Bearing failure detection. Applied acoustics, 1995, vol. 44, no 1, p. 67-77.
- [44] BOULENGER, Alain et PACHAUD, Christian. Surveillance des machines par analyse des vibrations : du dépistage au diagnostic. Association française de normalisation, 1995.
- [45] WU, Qiang et ZHOU, Ding-Xuan. SVM soft margin classifiers: linear programming versus quadratic programming. Neural computation, 2005, vol. 17, no 5, p. 1160-1187.
- [46] DRON, J. P. Elaboration et adaptation d'outils pour l'étude et le suivi de l'endommagement de composants mécaniques par analyse vibratoire. 1995. Thèse de doctorat. Université de Reims.
- [47] COOLEY, J. et TUKEY, J. An algorithm for machine calculation of complex Fourier series. Mathematics of computing, reprinted 1972. Digital signal processing. IEEE Press, New York, NY, 1965, p. 223-227.
- [48] RUBINI, Riccardo et MENEGHETTI, U. Application of the envelope and wavelet transform analyses for the diagnosis of incipient faults in ball bearings. Mechanical systems and signal processing, 2001, vol. 15, no 2, p. 287-302.
- [49] FLANDRIN, P. Temps-Fréquence. Traité des Nouvelles Technologies, série Traitement du Signal, Hermes. 93] S. Geman and D. Geman (1984): Stochastic Relaxation, Gibbs Distributions and Bayesian Restoration of Images. IEEE Proc. Pattern Ana. Mach. Intell, 1993, vol. 6, p. 721-741.
- [50] QUINQUIS, André et IOANA, Cornel. Représentations Temps-Fréquence et Temps-Echelle. ENSIETA, Brest, France, 2002.
- [51] BOASHASH, Boualem et O'SHEA, Peter. A methodology for detection and classification of some underwater acoustic signals using time-frequency analysis techniques. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1990, vol. 38, no 11, p. 1829-1841.
- [52] MEYER, Yves. Ondelettes et opérateurs : Opérateurs de Calderón-Zygmund. Hermann, 1990.

- 
- [53] SUN, Qiao et TANG, Ying. Singularity analysis using continuous wavelet transform for bearing fault diagnosis. *Mechanical Systems and signal Processing*, 2002, vol. 16, no 6, p. 1025-1041.
- [54] WANG, Changting et GAO, Robert X. Wavelet transform with spectral post-processing for enhanced feature extraction. In: *IMTC/2002. Proceedings of the 19th IEEE Instrumentation and Measurement Technology Conference*. IEEE, 2002, p. 315-320.
- [55] PENG, Z. K. et CHU, F. L. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mechanical systems and signal processing*, 2004, vol. 18, no 2, p. 199-221.
- [56] MISITI, Michel, MISITI, Yves, OPPENHEIM, Georges, et al. *Les ondelettes et leurs applications*. Hermès science publications, 2003.
- [57] MALLAT Stéphane. *Une exploration des signaux en ondelettes*. Edit. Ecole Polytechnique 2000
- [58] YAN, Ruqiang, GAO, Robert X., et CHEN, Xuefeng. Wavelets for fault Diagnosis of rotary machines: A review with applications. *Signal processing*, 2014, vol. 96, p. 1-15.
- [59] MALLAT, Stephane G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, 1989, vol. 11, no 7, p. 674-693.
- [60] TRAJIN, Baptiste. *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*. 2009. Thèse de doctorat. Institut National Polytechnique de Toulouse-INPT.
- [61] ADDISON, Paul S. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. CRC press, 2017.
- [62] WU, Jian-Da et HSU, Chuang-Chin. Fault gear identification using vibration signal with discrete wavelet transform technique and fuzzy–logic inference. *Expert systems with applications*, 2009, vol. 36, no 2, p. 3785-3794.
- [63] WU, Jian-Da et LIU, Chiu-Hong. Investigation of engine fault diagnosis using discrete wavelet transform and neural network. *Expert Systems with Applications*, 2008, vol. 35, no 3, p. 1200-1213.
- [64] LOU, Xinsheng et LOPARO, Kenneth A. Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical systems and signal processing*, 2004, vol. 18, no 5, p 1077-1095

- [65] PRABHAKAR, S., MOHANTY, A. R., et SEKHAR, A. S. Application of discrete wavelet transform for detection of ball bearing race faults. *Tribology International*, 2002, vol. 35, no 12, p. 793-800.
- [66] VIJAY, G. S., SRINIVASA PAI, P., et NS, Sriram. Discrete wavelet transform for fault diagnosis of rolling element bearing. In: *National Conference on Advances in Mechanical Engineering*, Manipal Institute of Technology, Manipal. 2011. p. 3-5.
- [67] LIU, Bao, LING, Shih-Fu, et MENG, Qingfeng. Machinery diagnosis based on wavelet packets. *Journal of vibration and control*, 1997, vol. 3, no 1, p. 5-17.
- [68] ZHANG, Sheng, MATHEW, Joseph, MA, Lin, et al. Best basis-based intelligent machine fault diagnosis. *Mechanical systems and signal processing*, 2005, vol. 19, no 2, p. 357-370.
- [69] NIKOLAOU, N. G. et ANTONIADIS, I. A. Rolling element bearing fault diagnosis using wavelet packets. *Ndt & E International*, 2002, vol. 35, no 3, p. 197-205.
- [70] BELLANGER, Maurice, BONNEROT, Georges, et COUDREUSE, Michel. Digital filtering by polyphase network: Application to sample-rate alteration and filter banks. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1976, vol. 24, no 2, p. 109-114.
- [71] VAIDYANATHAN, P. P. *Multirate Systems and Filter Banks*. Prentice Hall. Englewood Cliffs. 1993.
- [72] MOOSAVIAN, Ashkan, AHMADI, Hojat, et TABATABAEEFAR, Ahmad. Fault diagnosis of main engine journal bearing based on vibration analysis using Fisher linear discriminant, K-nearest neighbor and support vector machine. *Journal of Vibroengineering*, 2012, vol. 14, no 2, p. 894-906.
- [73] YELLA, Siril, GUPTA, Narendra K., et DOUGHERTY, Mark S. Comparison of pattern recognition techniques for the classification of impact acoustic emissions. *Transportation Research Part C: Emerging Technologies*, 2007, vol. 15, no 6, p. 345-360.
- [74] WEIHONG Li, WEIGUO Gong, YIXIONG Liang., and WEIMING Chen. *Pattern recognition and image analysis*, Springer 2005. 36, 42
- [75] WATANABE, Satosi. *Pattern recognition: human and mechanical*. John Wiley & Sons, Inc., 1985.
- [76] FUKUNAGA, Keinosuke. *Introduction to statistical pattern recognition*. Elsevier, 2013.
- [77] JAIN, Anil K., DUIN, Robert P. W., et MAO, Jianchang. Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intel.*, 2000, vol. 22, no 1, p. 4-37.

- 
- [78] ABBASION, Saeed, RAFSANJANI, A., FARSHIDIANFAR, Anoshirvan, et al. Rolling element bearings multi-fault classification based on the wavelet denoising and support vector machine. *Mechanical systems and signal processing*, 2007, vol. 21, no 7, p. 2933-2945.
- [79] MA, Lia, WANG, Yunhong, TAN, Tieniu, et al. Iris recognition based on multichannel Gabor filtering. In: *Proc. Fifth Asian Conf. Computer Vision*. 2002. p. 279-283.
- [80] MAMAR, Z. Hamou. Analyse temps-échelle et reconnaissance des formes pour le diagnostic du système de guidage d'un tramway sur pneumatiques. 2008. Thèse de doctorat. Université Blaise Pascal, Clermont-Ferrand II.
- [81] PEI, Soo-Chang et LIN, Chao-Nan. Image normalization for pattern recognition. *Image and Vision computing*, 1995, vol. 13, no 10, p. 711-723.
- [82] YAMAGUCHI, Osamu, FUKUI, Kazuhiro, et MAEDA, K.-i. Face recognition using temporal image sequence. In: *Proceedings Third IEEE International Conference on Automatic Face and Gesture Recognition*. IEEE, 1998. p. 318-323.
- [83] SEGRETO, T., KARAM, S., TETI, R., et al. Feature extraction and pattern recognition in acoustic emission monitoring of robot assisted polishing. *Procedia CIRP*, 2015, vol. 28, p. 22-27.
- [84] SOHN, Hoon, ALLEN, David W., WORDEN, Keith, et al. Structural damage classification using extreme value statistics. *J. Dyn. Sys., Meas., Control*, 2005, vol. 127, no 1, p. 125-132.
- [85] BHAVARAJU, Kalyan M., KANKAR, P. K., SHARMA, Satish C., et al. A comparative study on bearings faults classification by artificial neural networks and self-organizing maps using wavelets. *International Journal of Engineering Science and Technology*, 2010, vol. 2, no 5, p. 1001-1008.
- [86] FISHER, Ronald A. The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 1936, vol. 7, no 2, p. 179-188.
- [87] FILIPPETTI, Fiorenzo, FRANCESCHINI, Giovanni, TASSONI, Carla, et al. Recent developments of induction motor drives fault diagnosis using AI techniques. *IEEE transactions on industrial electronics*, 2000, vol. 47, no 5, p. 994-1004.
- [88] JODOUIN, Jean-François. *Les réseaux de neurones : principes et définitions*. Hermès, 1994.
- [89] TOUZET, Claude. *Les réseaux de neurones artificiels, introduction au connexionnisme*. 1992.
- [90] DUDA, Richard O., HART, Peter E., et STORK, David G. *Pattern classification second edition* John Wiley & sons. New York, 2001, vol. 58, p. 16.

- 
- [91] IE CUN, Y. A learning procedure for asymmetric threshold network. Proceedings of Cognitiva, 1985, vol. 85, p. 599-604.
- [92] RUMELHART, David E., HINTON, Geoffrey E., et WILLIAMS, Ronald J. Learning representations by back-propagating errors. Nature, 1986, vol. 323, no 6088, p. 533-536.
- [93] PICTON, Phil. Introduction to neural networks. Macmillan Basingstoke. England, 1994.
- [94] FREEMAN, James A. et SKAPURA, David M. Neural networks: algorithms, applications, and programming techniques. Addison Wesley Longman Publishing Co., Inc., 1991.
- [95] SAMANTA, Biswanath, AL-BALUSHI, Khamis R., et AL-ARAIMI, Saeed A. Artificial neural networks and genetic algorithm for bearing fault detection. Soft Computing, 2006, vol. 10, no 3, p. 264-271.
- [96] DUBOIS, Rémi. Application des nouvelles méthodes d'apprentissage à la détection précoce d'anomalies en électrocardiographie. Thèse de Doctorat de l'Université Pierre et Marie Curie, 2004.
- [97] KUMAR, H. S., PAI, P. Srinivasa, SRIRAM, N. S., et al. ANN based evaluation of performance of wavelet transform for condition monitoring of rolling element bearing. Procedia engineering, 2013, vol. 64, p. 805-814.
- [98] LI, Shutao, KWOK, James T., ZHU, Hailong, et al. Texture classification using the support vector machines. Pattern recognition, 2003, vol. 36, no 12, p. 2883-2893.
- [99] Vapnik V., The nature of statistical learning theory, Springer Verlag, New York, 1995.
- [100] Xiaojun, Gu. Research on Support Vector Machine Method for Rotating Machine and Intelligent Fault Diagnosis System. Zhejiang University, Hangzhou, 2006.
- [101] SAMANTA, B. Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. Mechanical systems and signal processing, 2004, vol. 18, no 3, p. 625-644.
- [102] BOSER, Bernhard E., GUYON, Isabelle M., et VAPNIK, Vladimir N. A training algorithm for optimal margin classifiers. In: Proceedings of the fifth annual workshop on Computational learning theory. 1992. p. 144-152.
- [103] HASTIE, Trevor, TIBSHIRANI, Robert, et FRIEDMAN, Jerome. The elements of statistical learning: data mining, inference, and prediction. Springer Science & Business Media, 2009.
- [104] YUAN, ShengFa et LI, Ming. Fault diagnosis using binary tree and sphere-structured support vector machines. Journal of mechanical science and technology, 2012, vol. 26, no 5, p. 1431-1438.

- 
- [105] ZHOU, Shenghan, QIAN, Silin, CHANG, Wenbing, et al. A novel bearing multi-fault diagnosis approach based on weighted permutation entropy and an improved SVM ensemble classifier. *Sensors*, 2018, vol. 18, no 6, p. 1934.
- [106] SCHILKOP, P. B., BURGEST, Chris, et VAPNIK, Vladimir. Extracting support data for a given task. In: *Proceedings, First International Conference on Knowledge Discovery & Data Mining*. AAAI Press, Menlo Park, CA. 1995. p. 252-257.
- [107] KONAR, P. et CHATTOPADHYAY, P. Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs). *Applied Soft Computing*, 2011, vol. 11, no 6, p. 4203-4211.
- [108] ZHANG, Ying, ZUO, Hongfu, et BAI, Fang. Classification of fault location and performance degradation of a roller bearing. *Measurement*, 2013, vol. 46, no 3, p. 1178-1189.
- [109] CHENG, Junsheng, YU, Dejie, TANG, Jiashi, et al. Application of SVM and SVD technique based on EMD to the fault diagnosis of the rotating machinery. *Shock and Vibration*, 2009, vol. 16, no 1, p. 89-98.
- [110] KELLER, James M., GRAY, Michael R., et GIVENS, James A. A fuzzy k-nearest neighbor algorithm. *IEEE transactions on systems, man, and cybernetics*, 1985, no 4, p. 580-585.
- [111] CASIMIR, Roland. Diagnostic des défauts des machines asynchrones par reconnaissance des formes. 2003. Thèse de doctorat. Ecole centrale de Lyon.
- [112] PARZEN, Emanuel. On estimation of a probability density function and mode. *The annals of mathematical statistics*, 1962, vol. 33, no 3, p. 1065-1076.
- [113] COVER, Thomas et HART, Peter. Nearest neighbor pattern classification. *IEEE transactions on information theory*, 1967, vol. 13, no 1, p. 21-27.
- [114] FIX, Evelyn. Discriminatory analysis: nonparametric discrimination, consistency properties. USAF school of Aviation Medicine, 1985.
- [115] SIMARD, Patrice Y., LECUN, Yann A., DENKER, John S., et al. Transformation invariance in pattern recognition—tangent distance and tangent propagation. In: *Neural networks: tricks of the trade*. Springer, Berlin, Heidelberg, 1998. p. 239-274.
- [116] BEN AMARA, Najoua. Utilisation des modèles de Markov cachés planaires en reconnaissance de l'écriture arabe imprimée. Thèse de Doctorat. Université de Tunis II, 1999.
- [117] DASARATHY, Belur V. Nearest neighbor (NN) norms: NN pattern classification techniques. *IEEE Computer Society Tutorial*, 1991.

- 
- [118] WILSON, D. Randall et MARTINEZ, Tony R. Improved heterogeneous distance functions. *Journal of Artificial Intelligence Research*, 1997, vol. 6, p. 1-34.
- [119] BROWN, T. et KOPLOWITZ, Jack. The weighted nearest neighbor rule for class dependent sample sizes. *IEEE Transactions on Information Theory*, 1979, vol. 25, no 5, p. 617-619.
- [120] DEVROYE, Luc. A universal k-nearest neighbor procedure in discrimination. *Nearest Neighbor Pattern Classification Techniques*, 1978, p. 101-106.
- [121] WETTSCHERECK, Dietrich, AHA, David W., et MOHRI, Takao. A review and empirical evaluation of feature weighting methods for a class of lazy learning algorithms. *Artificial Intelligence Review*, 1997, vol. 11, no 1, p. 273-314.
- [122] ZADEH, Lotfi A. Fuzzy sets. In: *Fuzzy sets, fuzzy logic, and fuzzy systems: selected papers by Lotfi A. Zadeh*. 1996. p. 394-432.
- [123] EL-SHAL, Shendy M. et MORRIS, Alan S. A fuzzy expert system for fault detection in statistical process control of industrial processes. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2000, vol. 30, no 2, p. 281-289.
- [124] EL-GAMAL, M. A. et ABDULGHAFOR, M. Fault isolation in analog circuits using a fuzzy inference system. *Computers & Electrical Engineering*, 2003, vol. 29, no 1, p. 213-229.
- [125] CHEN, Hui-Ling, HUANG, Chang-Cheng, YU, Xin-Gang, et al. An efficient diagnosis system for detection of Parkinson's disease using fuzzy k-nearest neighbor approach. *Expert systems with applications*, 2013, vol. 40, no 1, p. 263-271.
- [126] CHEN, Hui-Ling, YANG, Bo, WANG, Gang, et al. A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 2011, vol. 24, no 8, p. 1348-1359.
- [127] BERNADETTE Bouchon-Meunier. *La Logique Floue. Que sais-je*, PUF Edition, 1999.
- [128] DERRAC, Joaquín, GARCÍA, Salvador, et HERRERA, Francisco. Fuzzy nearest neighbor algorithms: Taxonomy, experimental analysis and prospects. *Information Sciences*, 2014, vol. 260, p. 98-119.
- [129] MAILLO, Jesus, LUENGO, Julian, GARCÍA, Salvador, et al. Exact fuzzy k-nearest neighbor classification for big datasets. In: *2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. IEEE, 2017. p. 1-6.
- [130] JÓŹWIK, Adam. A learning scheme for a fuzzy k-NN rule. *Pattern Recognition Letters*, 1983, vol. 1, no 5-6, p. 287-289.



- 
- [131] SCHRIJVER, Alexander. Theory of linear and integer programming. John Wiley & Sons, 1998.
- [132] NOCEDAL, J.-WRIGHT. SJ Numerical optimization. 2nd printing. 2000.
- [133] BERTSEKAS, Dimitri P., BERTSEKAS, Dimitri P., BERTSEKAS, Dimitri P., et al. Dynamic programming and optimal control. Belmont, MA: Athena scientific, 1995.
- [134] NELDER, John A. et MEAD, Roger. A Simplex method for Function Minimization. The computer journal, 1965, vol. 7, no 4, p. 308-313.
- [135] AVRIEL, M. Nonlinear Programming: Analysis and Methods. Printice-Hall. Inc, Englewood Cliffs, New Jersey, 1976.
- [136] CORMEN, Thomas H., LEISERSON, Charles E., RIVEST, Ronald L., et al. Introduction to algorithms. MIT press, 2009.
- [137] BASIL, Victor R. et TURNER, Albert J. Iterative enhancement: A practical technique for software development. IEEE Transactions on Software Engineering, 1975, no 4, p. 390-396.
- [138] GLOVER, Fred. Future paths for integer programming and links to artificial intelligence. Computers & operations research, 1986, vol. 13, no 5, p. 533-549.
- [139] COLLETTE, Yann et SIARRY, Patrick. Optimisation multiobjectif. Editions Eyrolles, 2002.
- [140] GOLDBERG, David E., RICHARDSON, Jon, et al. Genetic algorithms with sharing for multimodal function optimization. In: Genetic algorithms and their applications: Proceedings of the Second International Conference on Genetic Algorithms. 1987. p. 41-49.
- [141] BRANKE, Jürgen. Optimization in dynamic environments. In: Evolutionary Optimization in Dynamic Environments. Springer, Boston, MA, 2002. p. 13-29.
- [142] TALBI, E.-G. A taxonomy of hybrid metaheuristics. Journal of heuristics, 2002, vol. 8, no 5, p. 541-564.
- [143] ALBA, Enrique. Parallel metaheuristics: a new class of algorithms. John Wiley & Sons, 2005.
- [144] DORIGO, Marco, MANIEZZO, Vittorio, et COLORNI, Alberto. Ant system: optimization by a colony of cooperating agents. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 1996, vol. 26, no 1, p. 29-41.
- [145] NORMAN, Will. A Survey of the Applications of Swarm Intelligence. Internal Report, Clemson University, 2006.

- 
- [146] EIBEN, Agoston E., SMITH, James E., et al. Introduction to evolutionary computing. 2003.
- [147] HOLLAND JOHN, H. Adaptation in natural and artificial systems. Ann Arbor: University of Michigan Press, 1975.
- [148] KOZA, John R. Genetic programming: on the programming of computers by means of natural selection. MIT press, 1992.
- [149] FOGEL, Lawrence J., OWENS, Alvin J., et WALSH, Michael J. Artificial intelligence through Simulated Evolution. 1966.
- [150] GOLBERG, David E. Genetic algorithms in search, optimization, and machine learning. Addison Wesley, 1989, vol. 1989, no 102, p. 36.
- [151] ARCHETTI, Francesco et SCHOEN, Fabio. A survey on the global optimization problem: general theory and computational approaches. Annals of Operations Research, 1984, vol. 1, no 2, p. 87-110.
- [152] LAYEB, Abdesslem. Utilisation des Approches d'Optimisation Combinatoire pour la Vérification des Applications Temps Réel. 2010. Thèse de doctorat. Université Mentouri de Constantine.
- [153] KENNEDY, James et EBERHART, Russell. Particle Swarm Optimization. In: Proceedings of ICNN'95-international conference on neural networks. IEEE, 1995. p. 1942-1948.
- [154] SHI, Yuhui et EBERHART, Russell C. Parameter selection in particle swarm optimization. In: International conference on evolutionary programming. Springer, Berlin, Heidelberg, 1998. p. 591-600.
- [155] EL HAMI, Nour el Islam. Contribution aux méthodes hybrides d'optimisation heuristique : Distribution et application à l'interopérabilité des systèmes d'information. 2012. Thèse de doctorat. INSA de Rouen ; École Mohammadia d'ingénieurs (Rabat, Maroc).
- [156] ZIELINSKI, Karin et LAUR, Rainer. Stopping criteria for differential evolution in constrained single-objective optimization. In: Advances in differential evolution. Springer, Berlin, Heidelberg, 2008. p. 111-138.
- [157] KHELIL, Jalel, KHELIL, Khaled, RAMDANI, Messaoud, et BOUTASSETA, Nadir. Bearing Faults Diagnosis Using Discrete Wavelets and Artificial Intelligence Approaches. 1<sup>st</sup> International Conference on Sustainable Renewable Energy Systems and Applications (ICSRESA 19), December 04-05, 2019, Tebessa, Algeria.

- [158] CHENG, Yao, WANG, Zhiwei, ZHANG, Weihua, et al. Particle swarm optimization algorithm to solve the deconvolution problem for rolling element bearing fault diagnosis. *ISA transactions*, 2019, vol. 90, p. 244-267.
- [159] TYAGI, Sunil et PANIGRAHI, Sashi Kanta. An improved envelope detection method using particle swarm optimization for rolling element bearing fault diagnosis. *Journal of Computational Design and Engineering*, 2017, vol. 4, no 4, p. 305-317.
- [160] KHELIL, Jalel, KHELIL, Khaled, RAMDANI, Messaoud, et BOUTASSETA, Nadir. Discrete Wavelet Design for Bearing Fault Diagnosis Using Particle Swarm Optimization. *Journal Européen des Systèmes Automatisés (JESA)*, 2020, vol. 53, no. 5, p. 705-713.

## Annexe

Article publié dans le Journal Européen des Systèmes Automatisés (JESA), intitulé :

### **Discrete Wavelet Design for Bearing Fault Diagnosis Using Particle Swarm Optimization**

**Résumé** Le secteur énergétique joue un rôle stratégique dans le développement des pays et le confort des populations à travers le monde entier. Parmi les axes principaux de ce secteur, l'électricité a investi de nombreux domaines comme l'industrie, les transports, l'éclairage domestique et public, etc. L'expansion rapide de ce secteur dans un monde concurrentiel, requiert de plus en plus une stratégie de maintenance fiable et efficace des machines électriques tournantes permettant d'augmenter la disponibilité des machines, de réduire le coût de production, diminuer le temps de réparation et éviter les grands endommagements. La surveillance et le diagnostic des défauts pouvant altérer le bon fonctionnement de ces machines, s'appuie essentiellement sur la surveillance de symptômes liés à différentes conditions de dégradation. Ces symptômes peuvent être tirés et extraits de diverses sources d'information, parmi lesquelles, l'analyse vibratoire occupe une place prépondérante. Cette thèse a pour objectif de combiner l'analyse vibratoire avec la méthode de reconnaissance des formes afin d'améliorer la détection précoce des différents défauts des machines tournantes d'une centrale électrique, d'une part, et de prévenir au mieux la dégradation du système surveillé d'autre part. Pour cela nous avons développé un système de diagnostic basé sur la reconnaissance des formes, et où l'analyse des signaux vibratoires est effectuée à travers une transformation d'ondelette discrète optimisée. Basé sur la représentation polyphase du banc des filtres d'ondelettes. Cette méthode permet de générer les coefficients des filtres à travers des paramètres angulaires. Enfin, l'algorithme d'optimisation par essaim particulaires (Partical Swarm Optimisation : PSO), a été utilisé pour la recherche des paramètres angulaires optimums à un problème spécifique.

**Mots-clés** : Machines tournantes, diagnostic, intelligence artificielle, vibration, représentation polyphase, optimisation.

**Abstract** The energy sector plays a strategic role in the development of countries and the comfort of populations throughout the world. Amongst the main axes of this sector, electricity has invested in many areas such as industry, transport, domestic and public lighting, etc. The rapid expansion of this sector in a competitive world increasingly requires a reliable and efficient maintenance strategy for rotating electrical machines to increase machine availability, reduce production cost, decrease repair time and avoid great damage. The monitoring and diagnosis of faults that may affect the proper functioning of these machines is based primarily on monitoring symptoms related to various degradation conditions. These symptoms can be drawn and extracted from various sources of information, among which, vibration analysis occupies a prominent place. This thesis aims to combine vibration analysis with the pattern recognition method in order to improve the early detection of the various faults of the rotating machines of a power plant, on the one hand, and to prevent the degradation of the monitored system on the other hand. For this we have developed a diagnostic system based on pattern recognition, where the analysis of vibrational signals is performed through an optimized discrete wavelet transformation. Based on the polyphase representation of the wavelet filter bank, this method allows generating the coefficients of the filters through angular parameters. Finally, the Partical Swarm Optimization (PSO) algorithm was used to find the optimum angular parameters for a specific problem.

**Keywords:** Rotating machines, diagnostics, Artificial intelligence, vibration, polyphase representation, Optimization

**ملخص** يلعب قطاع الطاقة دورًا استراتيجيًا في تنمية البلدان وراحة السكان في جميع أنحاء العالم. ومن بين المحاور الرئيسية لهذا القطاع، استثمرت الكهرباء في العديد من المجالات مثل الصناعة والنقل والإنارة المنزلية والعامة، إلخ. يتطلب التوسع السريع لهذا القطاع في عالم تنافسي بشكل متزايد استراتيجية صيانة موثوقة وفعالة للألات الكهربائية الدوارة لزيادة توافر الماكينة وتقليل تكلفة الإنتاج وتقليل وقت الإصلاح وتجنب حدوث أضرار كبيرة تعتمد مراقبة وتشخيص الأخطاء التي قد تؤثر على الأداء السليم لهذه الآلات في المقام الأول على مراقبة الأعراض المتعلقة بظروف التدهور المختلفة. يمكن استخلاص هذه الأعراض واستخراجها من مصادر مختلفة للمعلومات، من بينها تحليل الاهتزاز الذي يحتل مكانة بارزة. تهدف هذه الرسالة إلى الجمع بين تحليل الاهتزاز وطريقة التعرف على الأنماط من أجل تحسين الكشف المبكر عن الأعطال المختلفة للآلات الدوارة لمحطة توليد الكهرباء من جهة ومنع تدهور النظام المرصود من جهة أخرى. لهذا قمنا بتطوير نظام تشخيص يعتمد على التعرف على الأنماط، وحيث يتم إجراء تحليل الإشارات الاهتزازية من خلال تحويل موجي منفصل محسن. بناءً على التمثيل متعدد الأطوار لبنك مرشح الموجات. تتيح هذه الطريقة إمكانية إنشاء معاملات المرشحات من خلال المعلمات الزاوية. أخيرًا تم استخدام خوارزمية تحسين حشد الجسيمات (PSO) للعثور على المعلمات الزاوية المثلى لمشكلة معينة.

**الكلمات المفتاحية:** الآلات الدوارة، التشخيص، الذكاء الاصطناعي، الاهتزاز، التمثيل متعدد الأطوار، التحسين.